



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO®

INSTITUTO TECNOLÓGICO DE ORIZABA
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
OPCIÓN I.- TESIS
TRABAJO PROFESIONAL

**“EVALUACIÓN DEL IMPACTO AMBIENTAL Y PREDICCIÓN DEL
RENDIMIENTO EN LA PRODUCCIÓN DE NARANJA (JCOF) MEDIANTE
ANÁLISIS DE CICLO DE VIDA, SISTEMAS DE INFORMACIÓN
GEOGRÁFICA Y MODELOS DE APRENDIZAJE AUTOMÁTICO”**

QUE PARA OBTENER EL GRADO DE:
MAESTRO EN INGENIERÍA INDUSTRIAL

PRESENTA:
ING. QUÍM. MARTÍNEZ MALDONADO MARIANA

DIRECTOR DE TESIS:
DR. ALBERTO ALFONSO AGUILAR LASSERRE

CODIRECTOR DE TESIS:
DR. RAMIRO MEZA PALACIOS



ORIZABA, VERACRUZ, MÉXICO

JUNIO 2026



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, **12/mayo/2026**
Dependencia: **División de Estudios de
Posgrado e Investigación**
Asunto: **Autorización de Impresión**
OPCION: I

C. MARTÍNEZ MALDONADO MARIANA
Candidato(a) a Grado de Maestro(a) en:
INGENIERÍA INDUSTRIAL
PRESENTE

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


**EVALUACIÓN DEL IMPACTO AMBIENTAL Y PREDICCIÓN DEL RENDIMIENTO EN LA PRODUCCIÓN DE
NARANJA PARA JCOF MEDIANTE ANÁLISIS DE CICLO DE VIDA, SISTEMAS DE INFORMACIÓN GEOGRÁFICA Y
MODELOS DE APRENDIZAJE AUTOMÁTICO**

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

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



DR. OSCAR BAEZ SENTIES
**JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN**



OBS/JARH


OG-13-F06





Educación
Secretaría de Educación Pública



INSTITUTO TECNOLÓGICO
DE ORIZABA



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba Veracruz, 14/abril/2026
Asunto: Revisión de trabajo escrito

C. OSCAR BAEZ SENTIES
JEFE DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

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

MARTÍNEZ MALDONADO MARIANA

La cual lleva el título de:

**EVALUACIÓN DEL IMPACTO AMBIENTAL Y PREDICCIÓN DEL RENDIMIENTO EN LA PRODUCCIÓN
DE NARANJA PARA JCOF MEDIANTE ANÁLISIS DE CICLO DE VIDA, SISTEMAS DE INFORMACIÓN
GEOGRÁFICA Y MODELOS DE APRENDIZAJE AUTOMÁTICO**

y concluyen que se acepta.

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

PRESIDENTE: DR. ALBERTO ALFONSO AGUILAR LASSERRE

SECRETARIO: DR. RAMIRO MEZA PALACIOS

VOCAL: DRA. ALINA EVELYN BADILLO MARQUEZ

VOCAL SUP.: MII GERMAN DOMINGUEZ CARRILLO


FIRMA


FIRMA


FIRMA


FIRMA

TA-09-F18



2026
año de
Margarita
Maza



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

Agradecimientos

Agradezco a Dios por concederme la sabiduría y el entendimiento para la realización de esta tesis reconociendo que el escribirla ha producido grandes cambios en mi persona tanto que me hace sentir realizada como profesionista al tiempo que pongo mis conocimientos al servicio de la sociedad.

Así mismo me encuentro en gratitud con mi familia por su amor, gran apoyo y confianza aún en momentos de incertidumbre. A mi pequeña por ser el motor más grande de mi vida.

A mis amigas de siempre, pero de forma entrañable a Leslie y Lupita, gracias por hacer la carga más ligera.

A mi alma mater, el Tecnológico de Orizaba, por ser el espacio de mi formación. A mis asesores y maestros, quienes fueron faro en este camino: al Dr. Ramiro, por enseñarme el valor del orden; al Dr. Lassere, por impulsarme a salir de mi zona de confort; a la Dra. Evelin, por su constante motivación; y al Mtro. Germán junto al ITS de Álamo Temapache, por su apoyo incondicional en esta investigación.

Esta tesis es el resultado de esa mezcla entre la tecnología, la fuerza y el orgullo de mi tierra y así es como, entre códigos, números, satélites, líneas de letras y mucho café, este trabajo ha tomado forma.

Resumen

Debido al crecimiento poblacional, la demanda de alimentos se ha incrementado exponencialmente, generando que los recursos cada vez sean más limitados no solo en México sino a nivel mundial, por lo que Álamo Temapache, Veracruz, al ser una zona importante a nivel nacional con la aportación de más del 50% de la producción de naranja en el país e internacionalmente con la exportación en la producción de naranja y sus derivados, se considera necesario realizar un diagnóstico de esta cadena de suministro para hacer uso eficiente de los recursos utilizando para este cometido el análisis de ciclo de vida (ACV) cuantificando así los impactos ambientales de este sistema teniendo como límites de la cuna a la puerta de almacenamiento del Jugo de naranja concentrado (JCOF), así mismo se aplicarán modelos híbridos de georeferenciación con inteligencia artificial para el eslabón con mayor impacto de la cadena de suministro como el cultivo de la optimización de este sistema con redes neuronales para los pronósticos y mejora del uso de los recursos.

Este documento plantea una metodología integral de toda una cadena de valor donde lo primero a realizar es una evaluación de la cadena de suministro de la producción de jugo de naranja con el análisis de ciclo de vida, como segunda fase y buscando mejorar la gestión de recursos en este sistema, se realiza un modelo de inteligencia georreferenciada del eslabón con mayor impacto buscando una mejora para los usuarios principales, prosiguiendo con compactar todos los datos obtenidos de un principio buscando obtener un pronóstico de fertilización que reduzca el impacto ambiental en todo el sistema. Este trabajo se desarrolla con la ayuda del Instituto Tecnológico Superior de Álamo Temapache.

A continuación, se detalla brevemente cada capítulo que conforma esta investigación:

En el Capítulo I, se plantea la problemática con el fin de entender la situación de una forma profunda y clara, con una justificación que pueda sustentar la relevancia de solucionar esta cuestión, así mismo, se establecen los objetivos del trabajo los cuales son la brújula de este proyecto en todo momento.

Capítulo II, se describen los conceptos teóricos del desarrollo del proyecto, desde los términos de los análisis que se utilizarán como el diagnóstico del sistema, así como el estado actual de esta cadena de suministro dentro del país y a nivel mundial. Por último, se describirá una introducción a la Inteligencia artificial (IA), los Sistemas de Información Geográfica y la agricultura de precisión para la comprensión del proceso y optimización dentro del proyecto.

En el Capítulo III se encuentra el estado del arte conformada por un conjunto de trabajos que refieren metodologías, investigaciones y prácticas innovadoras y actuales disponibles en los temas selectos que se buscan desarrollar en este trabajo. Con el objetivo de proporcionar un panorama comprensivo de lo que se ha logrado en estos campos y con problemáticas parecidas, buscando conocer las tendencias actuales, destacar las áreas donde se han producido avances significativos, con el firme objetivo de que este proyecto sea sólido para aportar un granito de arena en las brechas o áreas identificadas en otros trabajos, incluso no dejar lagunas que mencionan en algunos casos recomendadas por los distintos autores.

Capítulo IV se describe la metodología llevada a cabo a partir de lo planteado en el Capítulo 1 de manera ordenada y estructurada, explicando en cada parte la motivación de aplicar estas herramientas.

El Capítulo V se muestran los resultados de las técnicas utilizadas, así como la forma en que fueron abordadas para la comprensión de los desafíos que conllevaron el trabajo, también se detalla una discusión de esta metodología con respecto a trabajos relevantes de investigadores que poseían un objetivo a fin, para concluir mencionamos la aportación de este proyecto desde este paradigma y las conclusiones a las que se llegaron.

Abstract

Due to population growth, the demand for food has increased exponentially, leading to increasingly limited resources not only in Mexico but worldwide. As Álamo Temapache, Veracruz, is a key region both nationally—accounting for more than 50% of the country’s orange production—and internationally—through the export of oranges and their derivatives— it is considered necessary to assess this supply chain to make efficient use of resources. For this purpose, a life cycle assessment (LCA) will be used to quantify the environmental impacts of this system, covering the entire process from cradling to the storage facility for concentrated orange juice (COJ). Likewise, hybrid georeferencing models with artificial intelligence will be applied to the link with the greatest impact in the supply chain as the foundation for optimizing this system, using neural networks for forecasting and improving resource use.

This document proposes a comprehensive methodology for the entire value chain, beginning with an assessment of the orange juice production supply chain using life cycle analysis as the second phase, with the aim of improving resource management within this system a georeferenced intelligence model is developed for the link with the greatest impact, aiming to improve outcomes for the primary users, followed by the consolidation of all data collected from the outset to generate a fertilization forecast that reduces the environmental impact across the entire system. This work is being carried out with the support of the Instituto Tecnológico Superior de Álamo Temapache.

Below is a brief overview of each chapter comprising this research:

Chapter I presents the problem statement to provide a thorough and clear understanding of the situation, along with a rationale that underscores the importance of addressing this issue. It also sets forth the objectives of the study, which serve as the guiding principles for this project throughout.

Chapter II describes the theoretical concepts underlying the project’s development, including the analytical methods that will be used to diagnose the system, as well as the current state of this supply chain both within the country and globally. Finally, it introduces Artificial Intelligence (AI), Geographic Information Systems, and precision agriculture to facilitate understanding of the process and optimization within the project.

Chapter III presents the state of the art, comprising a collection of works that address current and innovative methodologies, research, and practices available in the selected topics to be explored in this study. The aim is to provide a comprehensive overview of what has been achieved in these fields and with similar issues, seeking to understand current trends and highlight areas where significant progress has been made, with the firm objective of ensuring this project is robust enough to contribute to addressing the gaps or areas identified in other studies, including filling in the gaps mentioned in some cases by various authors.

Chapter IV describes the methodology carried out based on the framework established in Chapter 1 in an orderly and structured manner, explaining in each section the rationale for applying these tools.

Chapter V presents the results of the techniques used, as well as how they were applied to understand the challenges involved in the work. It also includes a discussion of this methodology in relation to relevant studies by researchers with similar objectives. Finally, we highlight the contribution of this project within this framework and the conclusions reached.

Contenido

Agradecimientos.....	II
Resumen	III
Abstract.....	V
Capítulo I Generalidades	- 5 -
Introducción	- 6 -
Planteamiento del problema	- 6 -
Hipótesis	- 7 -
Objetivo General.....	- 8 -
Objetivos Específicos.....	- 8 -
Justificación	- 9 -
Conclusiones	- 10 -
Capítulo II Marco Teórico	- 11 -
2.1 Industria del Jugo de Naranja.....	- 12 -
2.1.1 Naranja.....	- 12 -
2.1.2 Niveles de producción de naranja en el Mundo	- 13 -
2.1.3 Producción de Naranja en México.....	- 17 -
2.1.4 Retos de la Producción de Naranja en Álamo Veracruz	- 18 -
2.2 Análisis de Ciclo de Vida (ACV).....	- 19 -
2.2.1. Metodología ACV	- 20 -
2.2.2. Aplicaciones ACV	- 25 -
2.2.3. Software para análisis de ciclo de vida.....	- 25 -
2.3 Inteligencia Artificial	- 27 -
2.3.1 Machine Learning.....	- 27 -
2.3.2 Redes Neuronales Artificiales.....	- 33 -
2.4 Sistemas de Información Geográfica (SIG)	- 36 -
2.4.1. Aplicaciones del SIG	- 36 -
2.4.2. Google Earth Engine GEE	- 37 -
Conclusiones	- 39 -
Capítulo III Estado del Arte	- 40 -
3.1. Diagnóstico Ambiental.....	- 41 -
3.2. Teledetección y Monitoreo Espacial hacia la agricultura de precisión	- 44 -
3.3. ML hacia la Agricultura de Precisión	- 46 -

Conclusiones	- 48 -
Capítulo IV Metodología	- 49 -
4.1. Metodología General.....	- 50 -
1. Revisión del Edo. Del Arte	- 51 -
2. Definición del objetivo y alcance de proyecto.....	- 51 -
3. Inventario de Análisis de ciclo de vida.....	- 57 -
4. Evaluación de Análisis de ciclo de vida	- 61 -
5. Interpretación de indicadores.....	- 61 -
6. Sistema de inteligencia georreferencial	- 61 -
7. RNA para pronóstico de rendimiento	- 65 -
Conclusiones.....	- 70 -
Capítulo V Resultados	- 71 -
5.1 Resultados del ACV.....	- 72 -
5.2 Resultados del Modelo Híbrido.....	- 80 -
5.3 Resultados de Redes Neuronales	- 86 -
5.4 Resultados generales	- 92 -
5.5. Discusión	- 93 -
Conclusiones	- 96 -
Capítulo VI Conclusiones	- 97 -
6.1. Conclusiones	- 98 -
6.2. Aportaciones	- 99 -
6.3. Recomendaciones y líneas de investigación futuras.....	- 100 -
Referencias	- 101 -
Anexos	- 111 -

Figuras

Figura 2.1.1 Tamaño del Mercado de Naranjas.....	- 14 -
Figura 2.1.2 Producción de Naranjas en T mundialmente	- 15 -
Figura 2.1.3 Rendimientos de los 12 Principales productores de naranja	- 16 -
Figura 2.1.4 Producción mensual	- 18 -
Figura 2.2.1 Estructura del Análisis de Ciclo de Vida	- 20 -
Figura 2.2.2 Niveles del Indicador de categoría de nivel de impacto	- 23 -
Figura 2.2.3 Metodología Impact 2002+	- 24 -
Figura 2.3.1 Modelo simplificado de una neurona	- 34 -
Figura 2.3.2 Esquema de una RNA de dos capas.....	- 35 -
Figura 4.1.1 Metodología general.....	- 50 -
Figura 4.1.2 Límites del Sistema del ACV.....	- 53 -
Figura 4.1.3 Diagrama de flujo de las etapas1-3	- 54 -
Figura 4.1.4 Entradas y salidas del transporte	- 55 -
Figura 4.1.5 Diagrama de flujo de la producción de JCOF	- 56 -
Figura 4.1.6 Metodología Gral. de los SIG	- 62 -
Figura 4.1.7 Metodología Híbrida Propuesta	- 63 -
Figura 4.1.8 Metodología RNA.....	- 66 -
Figura 5.1.1 Mapa de Calor General Mid Point.....	- 73 -
Figura 5.1.2 Mapa de Calor de ACV end point	- 74 -
Figura 5.1.3 Gráfica de Cambio Climático	- 75 -
Figura 5.1.4 Diagrama de Red de Agroquímicos y Fertilizantes	- 76 -
Figura 5.1.5 Gráfica de Ecotoxicidad Terrestre	- 77 -
Figura 5.1.6 Gráfica de Ecotoxicidad Acuática	- 78 -
Figura 5.1.7 Gráfica de Toxicidad Humana	- 79 -
Figura 5.1.8 Diagrama de Árbol de Ocupación de Suelo.....	- 80 -
Figura 5.2.1 Interfaz del modelo híbrido.....	- 81 -
Figura 5.2.2 Validación.....	- 82 -
Figura 5.2.3 Resultados	- 82 -
Figura 5.2.4 NDVI en el tiempo	- 85 -
Figura 5.2.5 Mapas de Temperatura y NDVI.....	- 85 -
Figura 5.3.1 Gráfica de Regresión Lineal.....	- 87 -
Figura 5.3.2 Gráfica de Importancia Relativa.....	- 88 -
Figura 5.3.3 Diagrama de residuos.....	- 89 -
Figura 5.3.4 Interfaz Interactiva para el Usuario.....	- 89 -
Figura 5.3.5 Rendimiento Real vs Pronóstico	- 92 -

Tablas

<i>Tabla 2.2.1 Softwares especializados para ACV</i>	<i>- 26 -</i>
<i>Tabla 3.1.1 ACV Naranja.....</i>	<i>- 42 -</i>
<i>Tabla 3.1.2 Continuación ACV Naranja</i>	<i>- 43 -</i>
<i>Tabla 3.2.1 Sistemas de Georreferencia</i>	<i>- 44 -</i>
<i>Tabla 3.2.2 Continuación Sistemas de Georreferencia & ML</i>	<i>- 45 -</i>
<i>Tabla 3.3.1 Edo. del Arte de aplicaciones ambientales e IA</i>	<i>- 46 -</i>
<i>Tabla 3.3.2 ML & SIG</i>	<i>- 47 -</i>
<i>Tabla 4.1.1 Unidad Funcional por actividad</i>	<i>- 52 -</i>
<i>Tabla 4.1.2 Inventario de Entradas</i>	<i>- 59 -</i>
<i>Tabla 4.1.3 Salidas del sistema.....</i>	<i>- 60 -</i>
<i>Tabla 4.1.4 Variables del Sistema RNA</i>	<i>- 68 -</i>
<i>Tabla 5.2.1 Resultados del Modelo Híbrido ML & SIG.....</i>	<i>- 83 -</i>
<i>Tabla 5.3.1 Resultados de pruebas de arquitectura de RNA</i>	<i>- 86 -</i>
<i>Tabla 5.3.2 Datos para validación</i>	<i>- 90 -</i>
<i>Tabla 5.3.3 Continuación Datos para validación.....</i>	<i>- 91 -</i>

Capítulo I

Generalidades

En este apartado se constituye el cimiento estratégico y ético del proyecto, se describen las motivaciones de la investigación. También se plantea la problemática de la cadena de suministro y los retos que enfrenta el Municipio de Álamo Temapache con uno de sus múltiples cítricos famosos en México, a pesar de los desafíos históricos y las crisis que este sector ha enfrentado, la calidez y resiliencia de sus actores han preservado esta actividad que es patrimonio cultural vivo. No obstante, la sostenibilidad de este legado se ve amenazada por ineficiencias en el uso de recursos y la incertidumbre climática, por lo tanto, en las siguientes líneas se detallan los objetivos que nos guían a buscar soluciones para la sostenibilidad de la cadena de suministro mediante la ciencia de datos y el análisis ambiental, blindar el futuro de esta cadena de suministro, garantizando que el progreso tecnológico camine de la mano con el respeto a la tradición y el bienestar social, pero sobre todo de la trascendencia de toda una cultura...

Introducción

A pesar de sus orígenes asiáticos la Naranja ha logrado consolidarse como uno de los frutos más populares en México, afianzándose, así como un elemento central de la fruticultura nacional por su magnitud y alcance de cosecha con respecto a otros cítricos. Además, se encuentra disponible durante todo el año (PROFECO, 2023). La importancia del cultivo de naranja para el campo mexicano radica en el alto volumen de cosecha, por lo que, la aportación al valor de la producción citrícola del país es considerable, además, genera una buena cantidad de empleos (productores, cortadores, transportistas, etc.), y contribuye al ingreso de divisas por la venta tanto en fresco como en jugo concentrado, principalmente congelado (Rivera-López, Perales-Salvador, Del Valle-Sánchez, & Caamal-Cauich, 2020).

Sin embargo, este panorama no es del todo favorable, ya que los sistemas agroalimentarios presentan un desafío sin precedentes. Aunque existe un éxito histórico en la seguridad alimentaria mundial al cubrir la demanda de una población en constante aumento, el progreso agrícola de las últimas décadas ha comprometido la estabilidad de los ecosistemas, de acuerdo a la (FAO, 2018), la expansión de este sector ha intensificado problemas críticos como la pérdida de biodiversidad, la degradación de suelos y bosques, además de una presión hídrica insostenible, situando a la industria en un punto de quiebre ambiental y social.

Estas razones, son las que motivan a realizar un análisis de ciclo de vida que nos ayude a visualizar los impactos ambientales en la cadena de suministro de la naranja junto con modelos híbridos de sistema de georeferenciación e inteligencia artificial que consiga robustecer la información y así con inteligencia artificial mostrar cómo se comporta el sistema en conjunto para una toma de decisiones donde se planteen diferentes estrategias en la correcta distribución de los recursos naturales.

Planteamiento del problema

La producción de alimentos es una necesidad de todo ser humano, se estima que el mundo necesita producir un 60 por ciento más de alimentos para el 2050 y garantizar la seguridad alimentaria mundial, debe hacerlo al tiempo que conserva y mejora la base de recursos naturales (FAO, 2024). De ahí la relevancia de utilizar los recursos de forma eficiente, tal que la calidad de los alimentos sea buena con un menor impacto al ambiente.

México en el año 2022 produjo más de 4.8 millones de toneladas de naranja, lo que significó un aumento de la producción del 5.6% previo al año anterior y la cantidad más alta en los últimos diez años, lo que colocó a México como el cuarto productor de naranja a nivel mundial. Veracruz es el estado que ocupa el primer lugar en la producción de esta fruta con más de 2.5 millones de toneladas de naranja anualmente (Rural, 2024) que representa aproximadamente el 52% de la producción total anual en México. Ante esta situación el uso desmedido de agua para la producción de naranja suele ser una limitante en este proceso, sobre todo en lugares donde el agua es escasa, ya que la producción de una naranja requiere aproximadamente 50 litros de agua y un vaso de jugo de naranja alrededor de 170 litros de agua dependiendo de las características del proceso y el lugar (FAO, 2012).

Es fundamental calcular los impactos ambientales en la producción de naranja mediante el Análisis de ciclo de vida, ya que esto puede identificar áreas de oportunidad en el proceso. Actualmente, nuevas plagas amenazan las plantaciones, como la plaga del árbol triste, lo cual es una gran preocupación para los agricultores. Ante la falta de conocimiento y apoyo técnico y económico, muchos recurren al uso de herbicidas, plaguicidas y fertilizantes. Sin embargo, estos métodos a menudo resultan insuficientes y, en muchos casos, conducen a un uso excesivo de estos productos, lo que pone en riesgo la calidad y el rendimiento de la fruta (Fabián Enríquez, 2023). Por otra parte, el aumento en la siembra de árboles de naranjas también conlleva grandes consecuencias, ya sea por la deforestación de los terrenos, el monocultivo los cuales amenazan la vida de especies silvestres y fauna nativa, la variabilidad genética de las mismas y alterando así los ciclos de agua de la zona.

En el caso de los residuos del proceso, como son: aguas, bagazo y cascara de naranja; se requiere analizar la forma en que se disponen estos residuos, debido a que un mal manejo trae consecuencias significativas; como el lixiviado de los procesos los cuales por el pH y la temperatura de este componente los suelos se ven acidificados, afectando a estos fuertemente.

Hipótesis

Demostrar que una metodología con análisis de ciclo de vida que detecte la situación actual de la cadena de suministro, así como integrar técnicas de inteligencia artificial con los sistemas de información geográfica permitirán evaluar y visualizar el desempeño ambiental de

la cadena de suministro en la producción de jugo de naranja tipo JCOF. Esta combinación fomentará un uso más eficiente de los recursos naturales y la reducción de costos, apoyando de manera estratégica en el proceso de toma de decisiones.

Objetivo General

Desarrollar un modelo metodológico híbrido de la cadena de suministro en la producción de jugo de naranja (JCOF) en Álamo Temapache, Veracruz, con el Análisis de Ciclo de Vida (ACV) para el diagnóstico ambiental y la predicción de rendimiento con herramientas basadas en Machine Learning (ML) y Sistemas de Información Geográfico (SIG), con el propósito de promover una gestión eficiente, sostenible y económicamente viable de los recursos.

Objetivos Específicos

- Establecer un Inventario de Ciclo de Vida (ICV) de entradas y salidas del sistema a través de la recolección de datos, simulación o métodos de IA de la cadena de suministro de la producción de jugo de Naranja en Álamo, Veracruz que nos ayuden a modelar la incertidumbre dada la naturaleza del sistema.
- Desarrollar un Análisis de Ciclo de Vida que evalúe el desempeño ambiental en la cadena de suministro de la producción de jugo de naranja, considerando la incertidumbre del modelo e identificando cual es la actividad que contribuye más al impacto medio ambiental con ayuda del software AB con la metodología IMPACT 2002+.
- Crear un modelo híbrido de SIG y ML para la clasificación y obtención del Índice de Vegetación de Diferencia Normalizada (**NDVI**) como variable clave de salud del cultivo que consolide el modelo buscando estrategias que mejoren el uso de los recursos para la sostenibilidad de la etapa crítica.
- Pronosticar el rendimiento de la Naranja en Álamo con los datos históricos consolidados con el NDVI en el eslabón con mayor impacto de la cadena de suministro para la eficiencia en el uso de los recursos y una futura reducción de los impactos ambientales con un modelo de Redes Neuronales Artificiales (RNA).

Justificación

La creciente preocupación por el bienestar personal está transformando los hábitos de consumo, impulsando la demanda de bebidas con alto valor nutricional. Por lo que se prevé que la industria global de zumos hortofrutícolas mantenga una expansión sostenida, con una tasa de crecimiento anual compuesta estimada en el 4,85% para el próximo quinquenio (Mordor Intelligence, 2024). Este dinamismo comercial se debe primordialmente a la consolidación de una base de consumidores que prioriza opciones saludables, desplazando a las bebidas convencionales por alternativas más naturales y listas para consumir.

Sin embargo, la incertidumbre del cambio climático y los complejos bucles de retroalimentación entre el clima y la tierra presentan a la agricultura niveles de riesgo amplificados que deben ser gestionados. Una visión global apunta a una convergencia de factores que ejercen una presión sin precedentes sobre la tierra y los recursos hídricos, lo que conduce a una serie de impactos humanos y perturbaciones en el suministro de productos agrícolas, en particular alimentos. (FAO, 2022)

A pesar de que México es un productor de naranja con alto potencial, en solo unas cuantas décadas, México pasó de ser un país de alta disponibilidad de agua a uno de baja, debido al crecimiento demográfico, a la creciente demanda en los distintos usos y al manejo poco eficiente del recurso, lo cual ha derivado en una mayor presión a los recursos hídricos. (Vázquez del Mercado & Lambarri, 2017)

Álamo Temapache es el líder en producción de naranja con 718,860 toneladas (Diario del Istmo, 2022), debido a estas condiciones se encuentra ante grandes retos, por lo que se ve amenazada, ante esta situación se propone realizar un análisis de ciclo de Vida que tenga como objetivo cuantificar y clasificar los impactos de la producción de jugo de naranja en el suelo, agua, aire y a la salud humana.

Una vez que se realicen estos análisis se determinarán las etapas que requieran atención dado su alto grado de impacto al ambiente; se realizará una simulación con georeferenciación de esta cadena de suministro para optimizarla, mediante técnicas de Inteligencia Artificial buscando la rentabilidad y eficiencia de la cadena de suministro de la producción de jugo de naranja.

Conclusiones

Al finalizar el planteamiento de este apartado, se establece la hoja de ruta que guiara este proyecto, describiendo la situación actual de Álamo Temapache como principal productor Nacional de Naranja, así como las consecuencias y responsabilidades que conlleva esta cadena de suministro, definiendo un objetivo que no solo aspira a la eficacia de una cadena de suministro valiosa por su actores humanos y culturales, sino buscando ser un instrumento de protección a tal cadena, justificando la implementación de estas herramientas tecnológicas avanzadas no como un reemplazo del conocimiento tradicional, sino un soporte científico para robustecer la toma de decisiones en la etapa más crítica, el campo, buscando estrategias para la sostenibilidad de esta actividad tan importante en el municipio de Veracruz, donde la tecnología se ponga al servicio de la sostenibilidad y el orgullo de una identidad compartida.

Capítulo II

Marco Teórico

El análisis de la sostenibilidad de las cadenas de suministro cada vez suelen ser más complejas, debido a los múltiples retos que existen, por lo que en este capítulo se fundamentan todos los conocimientos teóricos y técnicos que se deben entender para el desarrollo del proyecto como una visión hacia la industria de la naranja, el análisis de ciclo de vida, así como las diferentes técnicas de inteligencia artificial y sistemas de georreferencias que forman parte de este trabajo multidisciplinario.

2.1 Industria del Jugo de Naranja

Para tener una idea de la relevancia del trabajo es necesario ahondar sobre los eslabones de la cadena de suministro que delimitarán el análisis, así como algunos conceptos para su entendimiento.

2.1.1 Naranja

La naranja es una fruta cítrica, típicamente redonda y de color amarillento anaranjado (Mordor Intelligence Research & Advisory, 2024). La naranja es el fruto de un ejemplar arbóreo perteneciente a la familia de las rutáceas, el cual puede alcanzar una altitud de hasta 10 metros. Morfológicamente, se caracteriza por un epicarpio (cáscara) cuya textura fluctúa entre lo terso y lo rugoso, con una coloración que transita por matices verdes, amarillos y anaranjados. Internamente, la estructura se compone de carpelos —o gajos— rellenos de una pulpa que oscila entre tonos naranja y rojizos. Más allá de su consumo, su corteza es valorada tanto en el ámbito gastronómico como en la extracción de aceites esenciales. (Procuraduría Federal del Consumidor, 2023)

Con un perfil de sabor que equilibra la acidez y el dulzor, este cítrico se aprovecha tanto para la ingesta directa como para el procesamiento agroindustrial. En este último sector, es un insumo clave para la producción de concentrados, mermeladas, jaleas y productos en almíbar. Asimismo, su versatilidad permite su incursión en mercados no alimentarios, destacando su uso en la fabricación de barnices, cosmética especializada y esencias aromáticas. (Procuraduría Federal del Consumidor, 2023)

La resiliencia climática de los cítricos ha permitido su expansión por diversas zonas del globo, situándose mayoritariamente en regiones tropicales y subtropicales dentro de la franja latitudinal de los 44° N y 41° S. No obstante, factores ambientales como la humedad y el calor son determinantes en la fenología de la planta, afectando desde la longevidad del fruto hasta su concentración de azúcares y ácidos. Metabólicamente, la planta entra en un estado de latencia o interrupción si se excede el umbral de los 39 °C o se desciende de los 10 °C. Se considera que el desarrollo vegetativo se optimiza en un intervalo térmico de 13 a 32 °C. La temperatura óptima varía entre 20 a 30 °C, la cual varía durante el día logrando su máximo

potencial fotosintético, siempre que el suministro hídrico sea constante (González Segnana & Tullo Arguello, 2019).

Las propiedades del fruto cítrico responden directamente a factores ambientales: mientras que el calor intenso promueve el desarrollo de grados Brix (dulzor) y una cosecha temprana, las temperaturas bajas intensifican el perfil ácido del jugo. En cuanto a la morfología externa, una elevada humedad ambiental incide directamente en la reducción del grosor de la cáscara.

En cuanto a los problemas fúngicos se ha observado que dependen de la variación de la temperatura diurna y nocturna: cuanto mayor sea la amplitud térmica más intensa será la coloración de la cáscara y del jugo. (Suarez García, 2011)

La versatilidad de los cítricos les permite establecerse en terrenos con propiedades fisicoquímicas heterogéneas. A pesar de su notable capacidad de adaptación a diversos sustratos, el éxito del cultivo citrícola depende de mantener un equilibrio químico específico en el suelo. Un pH de 5.5 a 6.5 garantiza un entorno edáfico favorable, donde los elementos minerales requeridos por la planta se encuentran en formas químicas asimilables, evitando carencias nutricionales derivadas de una excesiva acidez o alcalinidad. Los límites inferiores al mínimo indicado pueden ser corregidos con el agregado constante todos los años de materia orgánica y con la aplicación de cal agrícola (González Segnana & Tullo Arguello, 2019).

La demanda nutricional del cultivo citrícola es permanente, pero alcanza sus picos máximos en las etapas reproductivas y de desarrollo del fruto. Existe una distinción clara en la acumulación mineral: mientras que en el tejido vegetativo el calcio (Ca^{++}) sobresale ante elementos como el nitrógeno (N), potasio (K^{+}), magnesio (Mg^{++}), azufre (S) y fósforo (P), en la fruta la prioridad fisiológica se desplaza hacia el nitrógeno y el potasio, que son los macronutrientes más representativos en su composición final. Cerca del 30% del N total en la planta y el 70% del K^{+} se localizan en el fruto (Suarez García, 2011)

2.1.2 Niveles de producción de naranja en el Mundo

En la Figura 2.1.1 se estima en 3.840 millones de dólares en 2024 y se espera que alcance los 4.790 millones de dólares en 2029, creciendo a una tasa compuesta anual del 4,53% durante el período previsto (2024-2029). (Mordor Intelligence Research & Advisory, 2024)



Figura 2.1.1 Tamaño del Mercado de Naranjas

Fuente: (Mordor Intelligence Research & Advisory, 2024)

En la Figura 2.1.2 observan los 12 principales productores de Naranja en el mundo, a escala global, la región de Asia Pacífico lidera el sector citrícola; no obstante, Brasil mantiene un posicionamiento estratégico no solo como productor, sino como un mercado de consumo masivo. La demanda doméstica en el país sudamericano muestra una tendencia al alza, impulsada principalmente por la preferencia de las familias y el sector gastronómico (restaurantes y panaderías) por el consumo de zumos naturales recién procesados. (Mordor Intelligence Research & Advisory, 2024).




Figura 2.1.2 Producción de Naranjas en T mundialmente

Fuente: (Big, 2024)

Además, las principales industrias de jugos de Brasil exportan casi toda su producción a destinos internacionales. Los envíos internacionales de zumo de naranja concentrado experimentan un auge estacional antes del invierno, reportando cifras de 377,9 toneladas métricas en el segundo semestre de 2022. Cabe destacar que las 377.9 toneladas métricas mencionadas no solo representan un éxito estadístico, sino que en términos logísticos equivalen a la carga completa de aproximadamente 16 contenedores marítimos estándar. Esta comparación permite visualizar la magnitud del flujo comercial donde se tiene una oportunidad de expansión. No obstante, la prosperidad de esta industria no está garantizada solo por el clima o la tecnología; la producción actual se encuentra en una encrucijada debido a la influencia de patógenos, políticas agrarias y la inestabilidad climática que afecta las zonas de cultivo. A pesar de esto Brasil se consolida como uno de los principales productores mundiales de naranjas (Mordor Intelligence Research & Advisory, 2024). En la Figura 2.1.3 se muestran los rendimientos de la naranja en cada país que son potencias en la producción de naranja.




Figura 2.1.3 Rendimientos de los 12 Principales productores de naranja

Fuente: (Big, 2024)

El comercio internacional de naranjas gira principalmente en torno a los principales exportadores, como Brasil y otros países de la Unión Europea, representando casi el 60% del total del comercio internacional de naranjas. Algunos de los principales importadores son China, Estados Unidos y Turquía.

Con una cuota superior al 50% de la producción citrícola internacional, la naranja es el tercer cultivo frutal de mayor impacto global después de los plátanos y las manzanas. Su consumo presenta una marcada estacionalidad, alcanzando niveles máximos en los meses de invierno. Esta tendencia responde a una combinación de factores climáticos y una creciente valoración de los beneficios terapéuticos y el sabor natural del fruto, lo que asegura su demanda constante en mercados con características socioeconómicas diversas

Este cítrico es popular debido a su dulzura natural, bajo en calorías y altamente nutritivo que contribuye a una piel fuerte y clara y puede ayudar a reducir el riesgo de muchas afecciones de salud (Mordor Intelligence Research & Advisory, 2024).

2.1.3 Producción de Naranja en México

Aunque su origen se remonta al continente asiático, la naranja se ha consolidado como el cítrico de mayor relevancia en el agro mexicano. Su importancia es tal que representa casi la quinta parte (19.3%) de la producción frutícola total del país, con un consumo per cápita que alcanza los 36.9 kg anuales. En términos de variedades, el tipo Valencia domina el panorama productivo, concentrando el 95.2% del volumen obtenido en 2022 (Procuraduría Federal del Consumidor, 2023).

México en el 2022 produjo más de 4.8 millones de toneladas de naranja, lo que significó un aumento de la producción del 5.6% previo al año anterior y la cantidad más alta en los últimos diez años, lo que colocó a México en el cuarto productor de naranja a nivel mundial. Siendo Veracruz el estado en primer lugar en la producción de esta fruta con más de 2.5 millones de toneladas de naranja (Rural, 2024).

El sector de derivados cítricos ha mostrado un dinamismo notable en los mercados internacionales. De acuerdo con la (Secretaría de Agricultura y Desarrollo Rural, 2021), las exportaciones de jugo experimentaron un repunte del 36% durante los primeros siete meses de 2021, alcanzando un valor de 278.5 millones de dólares, cifra que supera significativamente los 204.8 millones registrados en el periodo previo. Este crecimiento subraya la competitividad del producto mexicano en el exterior.

La naranja al igual de otros productos perecederos, tiene meses de mayor disponibilidad como se observa en Figura 2.1.4. Sin embargo, la oferta de naranja fluctúa estacionalmente; el 70% de la cosecha se concentra en la primera mitad del año, siendo el periodo de febrero a junio el de mayor disponibilidad y calidad. Esta ventana productiva es clave para el comercio exterior, especialmente con Estados Unidos, mercado donde México satisface el 30.1% de la demanda externa de este fruto (Procuraduría Federal del Consumidor, 2023)



Figura 2.1.4 Producción mensual

Fuente: (Procuraduría Federal del Consumidor, 2023)

La relación comercial más estrecha se mantiene con el mercado vecino, donde la producción mexicana logra satisfacer poco más del 30% de los requerimientos de importación de dicho país. Más allá del ámbito económico, la naranja destaca por su aporte de vitamina C, nutriente crítico durante el cierre del ciclo anual para robustecer el sistema inmunológico frente a enfermedades respiratorias estacionales. Asimismo, el jugo posee un valor cultural intrínseco en la gastronomía regional, siendo un ingrediente clave para el marinado de recetas tradicionales en la época decembrina. (Procuraduría Federal del Consumidor, 2023)

2.1.4 Retos de la Producción de Naranja en Álamo Veracruz

En el norte de Veracruz, el cultivo de cítricos surgió como el nuevo modelo productivo tras el declive del tabaco y el plátano. A pesar de la integración de avances como la maquinaria de fumigación, infraestructuras de postcosecha (lavado y encerado) y el uso de patrones resistentes al Virus de la Tristeza de los Cítricos (VTC), estos esfuerzos no se han traducido en una mayor rentabilidad para el productor local. El sector aún enfrenta barreras críticas en la adopción de tecnologías de riego, gestión eficiente de agroquímicos y estrategias organizativas

para mitigar el impacto de intermediarios o combatir vectores como el HLB (Huanglongbing). Según (Oble Vergara, 2016) , la permanencia de los citricultores en el mercado depende de una transición efectiva hacia innovaciones tanto técnicas como de gestión colectiva.

Álamo Temapache se ostenta como la "capital de la naranja" al aportar el 16.5% de la oferta nacional; sin embargo, este liderazgo productivo conlleva serios desafíos ambientales. El uso intensivo de fertilizantes nitrogenados es una de las principales preocupaciones de sustentabilidad en la región. Se estima que apenas el 40% del nitrógeno aplicado es aprovechado por el cultivo, mientras que el excedente se convierte en un agente contaminante para los mantos freáticos, el aire y el suelo. Este manejo ineficiente no solo degrada el ecosistema y pone en riesgo la salud pública, sino que eleva drásticamente los costos operativos, asfixiando la economía de los pequeños productores que dependen de suelos cada vez más agotados. (Oble Vergara, Evelia; González Aguirre, Rosa Luz;, 2021)

2.2 Análisis de Ciclo de Vida (ACV)

El Análisis de Ciclo de Vida (ACV) es una herramienta de gestión medioambiental cuya finalidad es analizar de forma objetiva, metódica, sistemática y científica, el impacto ambiental originado por un proceso o producto durante su ciclo de vida completo (esto es, de la cuna a la tumba). (Leiva, 2016)

Esta metodología se fundamenta en la cuantificación y registro pormenorizado de los flujos energéticos, los insumos materiales y la generación de subproductos o vertidos que impactan el ecosistema. De acuerdo con (Aranda, Zabalza, & Martínez, 2006) el estudio abarca una visión "de la cuna a la tumba", examinando desde la obtención y refinamiento de materias primas hasta las fases de fabricación, logística y distribución. Asimismo, contempla la vida útil del producto (mantenimiento y reutilización) y su gestión post-consumo, ya sea mediante procesos de reciclaje o la disposición final de los desechos.

El propósito del ACV trasciende la simple medición, enfocándose en la optimización operativa y la competitividad responsable. Según (Sanes Arrego, 2012), sus metas principales incluyen:

- Optimización de procesos: Detectar áreas de oportunidad para reducir la huella ecológica en puntos críticos de la cadena de valor.

- **Gestión estratégica:** Servir como herramienta diagnóstica para la toma de decisiones corporativas e industriales con criterios de sostenibilidad.
- **Estandarización y métricas:** Establecer parámetros de desempeño ambiental y metodologías de medición precisas.
- **Diferenciación comercial:** Facilitar el acceso a certificaciones de "producción limpia" y estrategias de eco-etiquetado que agreguen valor a la marca en el mercado.

2.2.1. Metodología ACV

Con el fin de considerar sistemáticamente los impactos ambientales del ciclo de vida de un producto, se ha desarrollado la metodología de análisis del ciclo de vida (ACV). Esta es la única herramienta estandarizada que se utiliza actualmente para evaluar las cargas ambientales de los productos. (Sonnemann, Castells, & Schuhmacher, 2004)

Los pasos del ACV son: definición de objetivos y alcances, análisis de inventarios, evaluación de impacto e interpretación. El análisis de ciclo de vida se estandariza mediante la norma ISO 14040. (Aranda, Zabalza, & Martínez, 2006). En la Figura 2.2.1, se muestra las etapas que conforman el análisis de ciclo de vida



Figura 2.2.1 Estructura del Análisis de Ciclo de Vida

Fuente: (Galaz, Yamazaki, Ruiz Urquiza, 2012)

La definición de objetivos comprende la exposición de los motivos por los que se desarrolla el estudio y la descripción del destinatario de este. El alcance es la definición de la amplitud, profundidad y detalle del estudio (Leiva, 2016). Es importante definir, en esta fase, la unidad funcional que provee una referencia con la cual las entradas y salidas están relacionadas, y que debe ser coherente con el objetivo y alcance del estudio (EEAOC, 2014).

Debido a esto la fase inicial de cualquier estudio de impacto debe establecer una dirección precisa y congruente con su finalidad práctica. Según (Leiva, 2016), la estructuración de los objetivos requiere tener claro estos tres ejes fundamentales:

- Autoría y responsabilidad: Determinar quién encabeza la ejecución de la investigación.
- Justificación técnica: Exponer los motivos que fundamentan el análisis y la naturaleza de los datos que se pretenden recolectar.
- Proyección de resultados: Definir el uso estratégico de la información obtenida y su implementación en escenarios reales.

Para realizar la definición del alcance del ACV, hay que ser cuidadosos ya que, esta etapa es crítica para establecer el "horizonte" del estudio, detallando la profundidad y las fronteras de la evaluación. Los puntos neurálgicos que configuran el alcance incluyen:

- Modelado del sistema: Descripción detallada del flujo del producto y sus capacidades operativas.
- Unidad Funcional (UF): Selección del parámetro de medida que permitirá normalizar las entradas y salidas de energía y materia.
- Fronteras del estudio: Determinación de los límites del sistema (por ejemplo, "de la cuna a la puerta") para identificar qué procesos quedan fuera del análisis.
- Criterios de asignación e impacto: Establecimiento de protocolos para distribuir las cargas ambientales y selección de los indicadores o categorías de impacto a evaluar.
- Gestión de la información: Especificación de los estándares de calidad y las fuentes de donde se extraerán los datos del inventario.

Finalmente, el alcance debe prever si el documento requerirá una revisión crítica externa para validar su rigor científico, así como la estructura y el estilo del reporte final que se entregará a los interesados (Leiva, 2016).

Sin olvidar establecer los límites del sistema que definen los procesos y operaciones a considerarse dentro y fuera de él (EEAOC, 2014).

Análisis del Inventario de Ciclo de Vida: Esta etapa constituye el núcleo cuantitativo del estudio. En esta fase, se realiza un balance detallado de los flujos metabólicos del sistema, contabilizando tanto los ingresos (extracción de materias primas y demanda energética) como los egresos hacia el ecosistema. Estos últimos comprenden las emisiones, las descargas líquidas, los vertidos en el suelo y el volumen total de residuos sólidos generados durante el proceso para este caso el citrícola. Los datos obtenidos en esta fase son el punto de partida para la Evaluación de Impacto de Ciclo de Vida (Leiva, 2016)

Los pasos para llevar a cabo la fase del inventario son:

1. Construcción del diagrama de flujo (sistema, subsistemas, procesos unitarios)
2. Establecimiento de la calidad de los datos
3. Definición de los límites del sistema
4. Redefinición de objetivos y alcance. (EEAOC, 2014)

En cuanto a la **fase evaluación de impacto**, su finalidad es clasificar y evaluar los resultados del inventario, analizando cuáles son los impactos que los flujos inventariados producen en el ambiente (EEAOC, 2014). Con el fin de valorar la importancia de los potenciales impactos que generan (Leiva, 2016).

Para traducir los datos del inventario en indicadores de daño ambiental, la comunidad científica ha desarrollado diversos modelos de caracterización. Dependiendo del enfoque del estudio (ya sea orientado al punto medio o al punto final), existen metodologías robustas como ReCiPe, CML 2 y TRACI. Otros marcos de evaluación, como Eco-Indicator 99, IMPACT 2002+ y BEES, también proporcionan métricas estandarizadas para interpretar la carga ambiental y facilitar la toma de decisiones en el diseño de estrategias de mitigación, como se muestra en la Figura 2.2.2. (Vidal, Neumann, & y Hospido, 2022)




Figura 2.2.2 Niveles del Indicador de categoría de nivel de impacto

Fuente: (Vidal, Neumann, & y Hospido, 2022)

La evaluación del impacto se puede abordar desde dos perspectivas complementarias. El enfoque de punto intermedio (midpoint), orientado a la identificación de problemas específicos, cuantifica las alteraciones en categorías ambientales mediante unidades indicadoras; por ejemplo, el potencial de calentamiento global expresado en (CO₂ - equivalentes [kg]), la acidificación y la eutrofización en. Por otro lado, el enfoque de punto final (endpoint) traduce estas métricas en daños tangibles sobre áreas de protección crítica, tales como la integridad de la salud humana, la biodiversidad de los ecosistemas y la disponibilidad de recursos abióticos.

Los resultados de los puntos finales tienen un mayor nivel de incertidumbre en comparación con los resultados de los puntos intermedios, sin embargo, facilitan la interpretación y comparación de los resultados, debido a que los resultados son expresados en un único valor de eco-indicador. (Vidal, Neumann, & y Hospido, 2022)

La Interpretación representa la etapa de síntesis donde convergen los hallazgos del Inventario (ICV) y la Evaluación de Impacto (EICV). Su propósito es generar conclusiones que guarden una estricta correspondencia con las metas establecidas inicialmente. No se trata de un paso lineal, sino de un proceso iterativo; esto permite auditar la calidad de la información

recolectada y, de ser necesario, redefinir el alcance del estudio o actualizar la naturaleza de los datos para garantizar que el modelo final sea una representación fiel y coherente de la realidad citrícola bajo análisis.

Este análisis puede incluir medidas cualitativas y cuantitativas de mejoras, como cambios en el producto, en el proceso, en el diseño, sustitución de materias primas, gestión de residuos, etc. (Leiva, 2016)

La metodología IMPACT 2002+ que se eligió para este proyecto fue desarrollada en el École Polytechnique Fédérale de Lausanne (EPFL). Su principal innovación es la implementación de un enfoque basado en el daño que permite a los investigadores y tomadores de decisiones visualizar el impacto ambiental no solo en términos de sustancias emitidas (mid-point), sino en términos de sus consecuencias finales (end-point) (Jolliet, 2003)




Figura 2.2.3 Metodología Impact 2002+

Fuente: (Jolliet, 2003)

En la Figura 2.2.3 se observa la metodología que será utilizada, en este proyecto debido a la forma global en que aborda los impactos por analizar, donde el modelo conecta 14 categorías

de impacto de punto medio (como toxicidad acuática, calentamiento global o uso de suelo) con 4 categorías de punto final o de daño. Esta transición se realiza mediante factores de caracterización basados en el destino de los contaminantes, la exposición y el efecto, teniendo así una relación compleja pero completa de estos indicadores que se requieren para esta cadena de suministro debido a su complejidad, ayudando a la comprensión general, por lo que esta metodología IMPACT 2002+ LCIA propone una implementación atractiva de un enfoque combinado de punto medio/daño para los responsables de sistemas complejos.

2.2.2. Aplicaciones ACV

Más allá de su capacidad diagnóstica, el Análisis de Ciclo de Vida (ACV) constituye un pilar estratégico para la optimización de la cadena de valor. Su implementación permite a las organizaciones fundamentar procesos de toma de decisiones orientados a la sostenibilidad mediante estos tres ejes de acción: la mitigación de externalidades negativas de los bienes y servicios producidos, el rediseño incremental de productos vigentes para elevar su eficiencia ambiental, y la jerarquización de puntos críticos (hotspots) dentro del ciclo de vida, permitiendo concentrar esfuerzos en los procesos de mayor impacto ecológico, gracias a esto, sus resultados pueden tomarse en cuenta para el diseño o rediseño de productos, para la selección de materiales, la planeación estratégica e inclusive para el desarrollo de políticas (Galaz, Yamazaki, Ruiz Urquiza, 2012).

2.2.3. Software para análisis de ciclo de vida

Realizar un ACV puede ser agotador, no solo en la recopilación de datos, sino también en la gestión de todos los datos recopilados para evaluar los impactos ambientales. Por lo tanto, la mayoría de los estudios de ACV se realizan mediante el uso de “bases de datos de Inventarios de Ciclo de vida (ICV)” y “softwares de ACV” comerciales.

El “software ACV” es una herramienta que administra todos los datos de ACV. En este software, el usuario coloca los datos del inventario de ciclo de vida que recopiló de su estudio, utiliza las “bases de datos ICV” disponibles en el software y realiza la evaluación de impacto del ciclo de vida (EICV), ya sea a través de los métodos disponibles en el software o mediante los métodos incluidos por el investigador. Otras etapas del ACV, como análisis de incertidumbre, también

se pueden realizar en dichos softwares. Algunos de los softwares utilizados en el ACV se muestran a continuación en la Tabla 2.2.1 **¡Error! No se encuentra el origen de la referencia.** (Vidal, Neumann, & y Hospido, 2022)

Tabla 2.2.1 Softwares especializados para ACV

Software	Compañía	País	Sitio web
GaBi	Stuttgat University	Alemania	https://www.gabi-software.com
SimaPro	Pré-consultants	Holanda	https://www.pre-sustainability.com
Umberto	Ifu-hamburg	Alemania	https://www.ifu.com
TEAM	Ecobilan	Francia	https://www.ecobilan.pwc.fr
BEES 3.0d	National Institute of Standards and Technology (NIST)	Estados Unidos	https://www.buildinggreen.com
OpenLCA	Green Delta TC	Alemania	https://www.openlca.org

Fuente: (Vidal, Neumann, & y Hospido, 2022)

GaBi y SimaPro son los softwares que han dominado el mercado, ambos han estado en el mercado por más de 15 años. A pesar de que ambos presentan diferentes “estilos” en la modelación de un sistema producto presentan similitud en sus características e interfaz de modelación. (Vidal, Neumann, & y Hospido, 2022)

En el ámbito de la evaluación de sostenibilidad, el uso de plataformas especializadas como SimaPro permite la cuantificación sistemática de la huella ecológica asociada a diversos bienes y servicios. Esta herramienta destaca por su rigor metodológico, facilitando un análisis de impacto basado en la objetividad de los datos y en la trazabilidad de los procesos, factores críticos para garantizar la transparencia en los reportes de ciclo de vida. (SimaPro, 2011).

Para la modelación del Inventario de Ciclo de Vida (ICV) y la evaluación de impactos, se utilizó el software de código abierto *Activity Browser*, el cual actúa como una interfaz gráfica avanzada para el framework de cálculo *Brightway2* basado en el lenguaje de programación Python, debido a que es de código abierto y la robustez para manejar la incertidumbre del sistema.

2.3 Inteligencia Artificial

Si alguien te preguntara cuál es tu definición de la IA, ¿qué le dirías? La respuesta es complicada ya que la inteligencia artificial es un tema complejo. Por esa razón, podemos encontrar distintas definiciones acerca de ella.

La IA se define como la facultad de los sistemas computacionales para ejecutar algoritmos que procesan datos, extraen patrones de aprendizaje y automatizan la toma de decisiones mediante una lógica análoga a la humana. A diferencia de las capacidades biológicas, las arquitecturas basadas en IA permiten el análisis masivo y simultáneo de información sin las restricciones de fatiga temporal o periodos de inactividad, optimizando la velocidad y precisión en la resolución de problemas complejos. (Lasse, 2018)

La IA clásica, comprende un conjunto de modelos de sistemas inteligentes, caracterizados por:

- a) La representación formal del problema a resolver, como una red semántica; y,
- b) Su capacidad de procesamiento simbólico, basada en algoritmos de búsqueda de soluciones.

Por lo que, la computación simbólica trasciende el cálculo numérico tradicional al enfocarse en el diseño de algoritmos para la manipulación efectiva de objetos simbólicos. Su aplicabilidad es vasta, extendiéndose desde la modelación científica en áreas como la física y la biología, hasta soluciones industriales complejas que incluyen el diseño asistido por ordenador (CAD), la robótica y la optimización de redes de transporte y eléctricas. (Banda Gamboa, 2014)

2.3.1 Machine Learning

El aprendizaje automático permite una comprensión hasta ahora inaudita de conjuntos complejos de datos, lo que le está otorgando un creciente protagonismo en nuestra sociedad en general y en la neurociencia cognitiva en particular. El aprendizaje automático (“machine learning”, en inglés) especializado en el tratamiento de datos con patrones complejos siendo una rama de las ciencias de la computación. A diferencia de la programación clásica, en la que un programa ejecuta una y otra vez la misma (más o menos compleja) operación, la principal característica del aprendizaje automático es que sus programas consiguen extraer de forma

autónoma (es decir, sin ser programados específicamente para ello) información relevante en los datos que están siendo procesados. (González-García, 2018)

El eje central de esta disciplina es el desarrollo de arquitecturas computacionales capaces de autogestionar su conocimiento a partir de la experiencia algorítmica. Este procesamiento se estructura fundamentalmente en dos metodologías de entrenamiento que permiten a los sistemas evolucionar su capacidad de respuesta:

- Aprendizaje Supervisado: Este paradigma se basa en la construcción de una función de mapeo a partir de un corpus de datos previamente categorizados o "etiquetados". El algoritmo identifica la correlación entre variables de entrada y salidas deseadas, lo que le permite realizar inferencias o clasificaciones precisas sobre conjuntos de información inéditos.
- Aprendizaje No Supervisado: Se implementa en escenarios donde los datos carecen de metadatos o etiquetas predefinidas. En este caso, el sistema debe descubrir de manera autónoma la estructura intrínseca de la información, organizándola a través de la detección de analogías, densidades o agrupamientos (clustering) que revelen patrones de diferenciación latentes.
- El aprendizaje de refuerzo: es cuando los datos del sistema no están etiquetados, pero después realizar varias acciones y de cierto periodo, el sistema será retroalimentado mediante actualizaciones (Hinestroza Ramírez, 2018)

La tecnología neural trata de reproducir el proceso de solución de problemas del cerebro. En el caso de las redes neuronales operan bajo el principio de generalización de patrones, emulando la plasticidad de los sistemas biológicos para resolver problemáticas complejas. A través del procesamiento de un historial de casos resueltos (datos de entrenamiento), el sistema ajusta sus parámetros internos para construir un modelo predictivo robusto. Esta arquitectura permite que la red no solo replique soluciones conocidas, sino que ejecute clasificaciones y tome decisiones lógicas ante escenarios inéditos, fundamentando su respuesta en la correlación estadística de la información procesada previamente. Los problemas adecuados para la solución neural son aquellos que no tienen solución computacional precisa o que requieren algoritmos muy extensos como en el caso del reconocimiento de imágenes. (Ponce, 2010)

Series de Tiempo

En el estudio de los fenómenos dinámicos, las series de tiempo se definen como la crónica numérica de una variable cuantitativa capturada en instantes sucesivos. Estas observaciones, denotadas como $y_1, y_2, y_3 \dots y_t$ no son meros datos aislados; son el reflejo de un comportamiento que puede manifestar tendencias persistentes, oscilaciones cíclicas o variaciones estacionales (como los ritmos anuales de cada cosecha), aunque en ocasiones el azar dicta formas aleatorias difíciles de clasificar. Desde una perspectiva puramente predictiva, estos modelos buscan descifrar el futuro observando únicamente el eco del pasado. (Ríos & Hurtado, 2008)

Teóricamente, el comportamiento de estas series puede descomponerse en cuatro componentes no observables, de los cuales se obtienen estimaciones para el análisis predictivo:

- a) **Estacionalidad:** Se define como el componente que presenta fluctuaciones regulares en intervalos de tiempo menores o iguales a un año. Estas variaciones son de naturaleza exógena y suelen ser las más complejas de modificar, ya que dependen de factores climáticos (estaciones del año), factores institucionales o legales (periodos fiscales, gratificaciones) y costumbres sociales.
- b) **Tendencia:** Representa el movimiento de la serie a mediano y largo plazo. Este componente refleja la dirección subyacente de la variable, impulsada por factores estructurales que inciden de manera significativa en su evolución temporal.
- c) **Ciclo:** Se refiere a oscilaciones de larga duración que no tienen una periodicidad fija, generalmente asociadas a variaciones sistémicas o económicas de mayor escala. (Antunez-Irgoin, 2011)
- d) **Componente Aleatorio:** Movimientos erráticos e impredecibles que no siguen un patrón específico. Este elemento representa la variabilidad de la serie que no puede ser explicada por la tendencia, el ciclo o la estacionalidad.

Bajo esta premisa, la literatura técnica distingue dos senderos metodológicos principales:

- **Modelos Deterministas:** Se presentan como métodos de extrapolación cuya esencia radica en la simplicidad. Al no profundizar en la naturaleza de la aleatoriedad que habita en la serie, suelen sacrificar precisión en favor de una implementación ágil. Un

ejemplo clásico son los promedios móviles, donde el horizonte se vislumbra a través del valor medio de los eventos inmediatamente anteriores.

- Modelos Estocásticos: A diferencia de los anteriores, estos modelos intentan capturar la esencia del proceso aleatorio subyacente. Parten de la premisa de que cada observación es una extracción de un complejo conjunto de variables aleatorias. Ante la dificultad de definir una distribución conjunta perfecta, se construyen aproximaciones matemáticas robustas diseñadas específicamente para la generación de pronósticos. (Ríos & Hurtado, 2008)

Este campo de los modelos estadísticos ha crecido al mismo ritmo del desarrollo de los computadores de tal forma, que existe una gran cantidad de modelos de pronósticos. Sin embargo, para lograrlos, se necesita conocer y disponer de información confiable y suficiente del pasado; estudiarla y detectar tendencias, variaciones cíclicas y estacionales, con el fin de poderlas reproducir a través de modelos estadísticos. (Moreno-Sarmiento, 2008)

En la actualidad, las organizaciones emplean el análisis de series de tiempo como una herramienta estratégica para la planificación y prevención operativa. Su objetivo primordial es proyectar el comportamiento futuro de una variable basándose estrictamente en sus registros históricos. Esta capacidad predictiva es fundamental para la toma de decisiones a corto y mediano plazo en áreas críticas como la gestión de inventarios, la estimación de la demanda de productos y la planeación de insumos.

Debido a su versatilidad, las series de tiempo tienen aplicaciones en diversos campos del conocimiento:

- Análisis de índices de precios, tasas de inflación, comportamiento de ventas, utilidades y proyecciones de demanda.
- Monitoreo de temperaturas, velocidad del viento para energías renovables, pluviometría y análisis de señales sismológicas.
- Control de variables críticas como la viscosidad y temperatura en líneas de producción.
- Telecomunicaciones (análisis de señales), transporte (flujos de tráfico), medicina (bioseñales) y demografía (tasas de natalidad y mortalidad). (Ríos & Hurtado, 2008)

Random Forest

El algoritmo de Bosques Aleatorios (Random Forest) representa una de las arquitecturas de aprendizaje automático basadas en conjuntos (ensemble learning) más versátiles y robustas en la actualidad. Clasificado dentro de los modelos estadísticos avanzados, posee la capacidad intrínseca de modelar relaciones complejas y no lineales sin incurrir en supuestos rígidos de distribución paramétrica, siendo aplicable tanto a tareas de clasificación multifactorial como de regresión numérica. (Ahlawat, 2025) Su elevado pedigrí matemático radica en la combinación de múltiples árboles de decisión acting como "aprendices débiles" (aprendices débiles), cuya agregación sinérgica mitiga los problemas de alta varianza y sobreajuste (overfitting) típicos de los árboles individuales.

Esta técnica utiliza el concepto de árboles de decisión, construyendo una colección de árboles de decisión y agregando sus resultados para generar la predicción definitiva. Cada árbol de decisión dentro de un bosque aleatorio se construye usando subconjuntos aleatorios de datos, y cada árbol individual se entrena sobre una parte del conjunto de datos completo. Posteriormente, los resultados de todos los árboles de decisión se amalgaman para obtener la previsión definitiva. (Salman, Kalakech, & Steiti, 2024)

Desde una perspectiva operativa, esta técnica fundamenta su superioridad predictiva en la construcción de una colección densa de árboles de decisión independientes, amalgamando sus salidas individuales para converger en una predicción definitiva y estabilizada. (Salma, Kalakech, & Steiti, 2024) El proceso metodológico se rige bajo los siguientes principios:

- Muestreo por Arrastre (Bootstrapping): Cada árbol estructural dentro del bosque se entrena utilizando un subconjunto aleatorio de datos extraído del dataset global mediante muestreo con reemplazo. (Delgado-Ramirez & Bolaños-Gonzalez, 2025) Este mecanismo garantiza que cada componente del ensamble se exponga a una variante única de la información histórica.
- Agregación de Bootstrap (Embolsado): Una vez entrenados los K árboles de manera aislada, el modelo genera la previsión definitiva mediante un proceso de agregación. En problemas de clasificación, se utiliza un sistema de votación mayoritaria; en problemas de regresión predictiva (como el aforo y pronóstico de cosechas), se calcula

la media aritmética de los resultados vectoriales generados por la totalidad del bosque.
(Salma, Kalakech, & Steiti, 2024)

La estabilidad termodinámica y computacional del algoritmo está estrictamente gobernada por la calibración de sus hiperparámetros de diseño. De acuerdo con (Delgado-Ramirez & Bolaños-Gonzalez, 2025) , la arquitectura se encuentra estructurada matemáticamente por dos variables fundamentales:

1. La cantidad total de árboles de clasificación o regresión **K**: Define la dimensión del ensamble; un incremento en **K** estabiliza la aproximación del error de generalización, aunque eleva de forma proporcional el costo computacional.
2. El número de variables predictoras en cada división u hoja **m**: Representa el subconjunto aleatorio de variables analizadas en cada nodo para efectuar la partición óptima. Si el sistema original posee un total de **M** variables predictoras, la literatura formal sugiere establecer el umbral de selección en:

$$m = \sqrt{M} \text{ (para tareas de clasificación)}$$

$$m = \frac{M}{3} \text{ (para tareas de regresión)}$$

Este submuestreo de características garantiza la des correlación de los árboles, un factor crítico que eleva la precisión global del sistema y optimiza su rendimiento predictivo ante perturbaciones en los datos de entrada. (Parmar, Katariya , & Patel, 2019)

Desde el punto de vista de la ingeniería de software y la analítica predictiva, los bosques aleatorios han captado una atención prioritaria en la comunidad científica debido a sus sobresalientes atributos de eficiencia computacional. (Salman, Kalakech, & Steiti, 2024)

- Procesamiento de Alta Dimensión: Manejan de manera natural bases de metadatos masivas con una gran cantidad de variables de entrada, sin requerir pasos previos obligatorios de reducción de dimensionalidad espacial (como PCA).
- Paralelización Genérica: Debido a que la construcción de cada árbol de decisión es estadísticamente independiente de los demás, el algoritmo es altamente apto para arquitecturas de computación en paralelo y procesamiento distribuido en la nube.

- **Estimación Interna del Error (Out-of-Bag Error):** Al emplear bootstrapping, aproximadamente un tercio de los datos queda excluido del entrenamiento de cada árbol específico. Estas muestras remanentes, denominadas Out-of-Bag (OOB), se utilizan de forma automática para calcular una estimación insesgada del error de generalización del modelo, eliminando la dependencia estricta de una validación cruzada externa tradicional durante las fases iniciales de calibración.

Captando así, la atención de la comunidad investigadora debido a su alta precisión y superioridad, lo que además mejora su rendimiento (Parmar, Katariya , & Patel, 2019) La literatura científica reciente destaca que los Bosques Aleatorios superan a los modelos estadísticos tradicionales en dos frentes operativos fundamentales:

De acuerdo con (Salman, Kalakech, & Steiti, 2024)), Los bosques aleatorios son muy valorados como una de las técnicas más eficientes y potentes en el ámbito del aprendizaje automático. Por lo que su aplicación tan diversa va desde la categorización automática, la predicción de datos hasta el aprendizaje supervisado en diferentes ámbitos y especialidades.

2.3.2 Redes Neuronales Artificiales

Las RNA's se han convertido en una rama de estudio multidisciplinar en las ciencias en general actualmente. Incluso desde antes de que se construyera la primera computadora en 1946, el hombre se ha interesado en el estudio de las redes neuronales y la posibilidad de llevar este modelo de forma artificial para diferentes aplicaciones. Desde 1936 con Alan Turing se inicia la posibilidad de trabajar con redes neuronales de forma artificial cuando se encuentran relaciones entre el cerebro y el concepto de computación. (Acevedo, E., Serna, A., & Serna, E., 2017)

Las RNA's tratan de modelizar esquemáticamente la estructura hardware del cerebro, para reproducir sus características computacionales. Estos sistemas de procesamiento de información, paralelos, distribuidos y adaptativos, a partir de datos del entorno y empleando algoritmos numéricos, son capaces de aprender de la experiencia. (Martín Del Brío & Serrano Cinca, 1995)

Esta también puede ser vista como un sistema inteligente que lleva a cabo tareas de manera distinta a como lo hacen las computadoras actuales. Si bien estas últimas son muy rápidas en

el procesamiento de la información, existen tareas muy complejas, como el reconocimiento y clasificación de patrones, que demandan demasiado tiempo y esfuerzo aun en las computadoras más potentes de la actualidad, pero que el cerebro humano es más apto para resolverlas, muchas veces sin aparente esfuerzo. (Torres & Tablada, 2009)

Para comprender cuáles son los elementos básicos que compone una red neuronal, primero es necesario conocer el funcionamiento de una neurona. Las neuronas tienen tres componentes principales, las cuales son denominadas dendritas, el cuerpo de la célula o soma y el axón. El punto de conexión entre el axón de una célula y una dendrita de otra célula se llama sinapsis. En términos computacionales, las dendritas, son las receptoras de la red, que cargan de señales eléctricas el cuerpo de la célula. (Acevedo, E., Serna, A., & Serna, E., 2017)




Figura 2.3.1 Modelo simplificado de una neurona

(Torres & Tablada, 2009)

Si bien hay distintos tipos de neuronas biológicas, en la Figura 2.3.1 se muestra un esquema simplificado de un tipo particular que es muy común, donde la función principal de las neuronas es la transmisión de los impulsos nerviosos. Estos viajan por toda la neurona comenzando por las dendritas hasta llegar a las terminaciones del axón, donde pasan a otra neurona por medio de la conexión sináptica. (Torres & Tablada, 2009)

Una neurona como tal es diminuta en sí, pero cuando muchas se encuentran interconectadas, pueden formar toda una red de comunicaciones que pueden resolver problemas muy complejos. (Acevedo, E., Serna, A., & Serna, E., 2017) Por ejemplo, el cerebro de una persona tiene billones de neuronas (se calcula que hay aproximadamente 10 billones de neuronas en la corteza cerebral y 60 trillones de conexiones neuronales) (Torres & Tablada, 2009)

A la comunicación que existe entre todas estas neuronas se le denomina Red neuronal, por lo que, se puede decir, que una red neuronal está conformada por neuronas que se encuentran interconectadas y organizadas en tres capas. Los datos ingresan por medio de la “capa de entrada” (input), que pasan a través de la “capa oculta” (layer1, layer2) y salen por la “capa de salida” (output) como se observa en Figura 2.3.2 (Acevedo, E., Serna, A., & Serna, E., 2017)

Figura 2.3.2 Esquema de una RNA de dos capas

(Torres & Tablada, 2009)

Pero ¿Cómo funciona la red neuronal?, la capacidad de una red neuronal para «pensar» ha revolucionado la informática tal y como la conocemos. (Ortiz-Domínguez, 2025) Estas siguen unos pasos fundamentales para lograr alcanzar su máximo desempeño como:

- La asociación o entrenamiento permite a las redes neuronales «recordar» patrones. Por lo que a una neurona artificial se le asigna un peso sináptico a las entradas que provienen desde otras neuronas. Este procedimiento es similar al que se realiza en una neurona de un ser humano, a lo que normalmente en la medicina se le conoce como sinapsis. El peso sináptico entonces es un valor numérico y que puede ir cambiando durante la fase de entrenamiento. (Acevedo, E., Serna, A., & Serna, E., 2017)
- Clasificación u organización de datos o patrones en clases predefinidas. En un modelo neuronal, se debe disponer de una regla de propagación para combinar las salidas de cada neurona con las ponderaciones establecidas por el patrón de conexión, con eso se especifica la valoración de las entradas que recibe cada neurona
- Con el valor obtenido con la regla de propagación, esta se filtra con de una función conocida como función de activación. A través de esta función se da la salida de la neurona. Las funciones de activación se escogen dependiendo del objetivo de entrenamiento de la red neuronal (Acevedo, E., Serna, A., & Serna, E., 2017)
- Predicción, o producción de resultados esperados utilizando una entrada relevante, incluso cuando no se proporciona todo el contexto por adelantado. (Ortiz-Domínguez, 2025)

Las redes neuronales se clasifican en función de varios factores, como su profundidad, el tipo de rango en que se pueden clasificar, su tipo de aprendizaje, por su objetivo, etc.

Existen variadas aplicaciones de las redes neuronales artificiales en la actualidad, en donde puede apreciarse el gran potencial que tiene el uso de estas para la automatización de tareas o procedimientos a través de procesos de entrenamientos según el tipo de aprendizaje que se desee escoger. (Acevedo, E., Serna, A., & Serna, E., 2017) Por lo que, a medida que las redes neuronales sigan haciéndose más rápidas y precisas, en el futuro, el progreso tecnológico de la humanidad se verá reforzado de forma significativa. (Ortiz-Domínguez, 2025)

2.4 Sistemas de Información Geográfica (SIG)

Un Sistema de Información Geográfica (SIG) es un sistema de información digital que pertenece a la categoría de Sistemas de Información Espaciales (SIE). Un SIE tiene la capacidad de capturar, procesar, analizar, modelar y reportar en forma gráfica/tabular información de tipo espacial. (Guevara, 2017) Estos se han convertido en la nueva tecnología que permite no solo crear, organizar, y manipular en forma simultánea bases de datos gráficas y descriptivas, sino que presentan una serie de posibilidades orientadas hacia el análisis multicriterio de dicha información, con el fin de convertirla en elementos de juicio para ayudar a la toma de decisiones. (Saenz-Saavedra, 2012)

Un Sistema de Información Geográfica (SIG) se articula como una infraestructura multidimensional donde convergen cinco ejes operativos: los activos de datos, la plataforma tecnológica (hardware y software), las metodologías de análisis, los protocolos procedimentales y el capital humano especializado. La esencia de esta herramienta reside en su capacidad integradora, permitiendo la interoperabilidad de flujos de información heterogéneos. La ventaja competitiva de los SIG radica en su potencia para sintetizar y procesar volúmenes masivos de datos georreferenciados, lo que optimiza la toma de decisiones mediante consultas dinámicas y diagnósticos territoriales de alta precisión. Gracias a esto, los SIG se han convertido en una gran herramienta en la actualidad para la toma de decisiones y desarrollo de planes de actuación frente a diversas situaciones. (Flórez-Delgado & Fernández-García, 2017)

2.4.1. Aplicaciones del SIG

La operatividad de los Sistemas de Información Geográfica no es estática; por el contrario, su alcance está intrínsecamente ligado a la robustez de la infraestructura tecnológica, la especialización del personal técnico y la complejidad de las metas investigativas. Más que una herramienta rígida, el SIG se define por su flexibilidad funcional, donde el límite de su aplicación se expande según la profundidad de los objetivos estratégicos y la capacidad de integrar nuevas dimensiones de análisis espacial en el modelo. Por lo anterior, se les conoce como la "tecnología del conocimiento", por el gran potencial que ofrece para la gran variedad de disciplinas relacionadas. (Saenz-Saavedra, 2012)

A continuación, se presentan algunas de las principales aplicaciones de los SIG:

- Planificación hidrológica: Los SIG se han convertido en una potente herramienta para planificar y gestionar los recursos hídricos gracias a que disponen de múltiples opciones para su análisis y evaluación. (Flórez-Delgado & Fernández-García, 2017)
- Agricultura: Encuestas de zonificación agrícola, estimación de rendimiento de cultivos, la Agricultura de precisión, monitorear las tendencias del mercado, mejorar los rendimientos y predecir el clima, entre otros. (Pérez-Guerra, Sosa-Franco, Machado-García, & Ruíz-Pérez, 2022)
- Planes de emergencia: Elaboración en tiempo real de mapas de actuación en caso de incendios forestales, inundaciones y cualquier tipo de emergencia. (Flórez-Delgado & Fernández-García, 2017)

La expansión contemporánea de los Sistemas de Información Geográfica responde al alto grado de madurez alcanzado tanto en entornos propietarios como en ecosistemas de software libre. No obstante, la sofisticación técnica y la rigurosidad analítica que demandan estas herramientas han delimitado tradicionalmente su uso a especialistas en geomática y ciencias de la tierra. A pesar de esta barrera técnica inicial, la tendencia actual se inclina hacia la interdisciplinariedad, permitiendo que investigadores de otras áreas (como la ingeniería ambiental y la agronomía) adopten estas aplicaciones para el análisis espacial de datos complejos, siempre que exista una base sólida de capacitación en el manejo de capas y bases de datos georreferenciadas. Por esta razón, han sido desarrolladas algunas aplicaciones libres disponibles en Internet para su uso general, como son ArcGIS Earth y Google Earth, las cuales pueden ser utilizadas de manera intuitiva por un usuario no experto. (Cantón Sánchez, Inga Campoverde, Macías Hernández, & Martínez Carriel, 2022)

2.4.2. Google Earth Engine GEE

Los sistemas de teledetección llevan décadas recopilando enormes volúmenes de conjuntos de datos, cuya gestión y análisis no es práctico utilizando paquetes de software comunes y recursos de computación de escritorio. (Meisam, Arsalhan, & al, 2020) Por lo que Google Earth Engine (GEE) es una plataforma de procesamiento geoespacial basada en la nube para la monitorización y análisis ambiental a gran escala (Tamiminia, 2020) para abordar eficazmente

los retos del análisis de big data. (Meisam, Arsalhan, & al, 2020) En particular, esta plataforma facilita el procesamiento de grandes datos geográficos en grandes áreas y la monitorización del entorno durante largos periodos de tiempo. La integración de datos geoespaciales en esta investigación se apoya en la plataforma Google Earth Engine (GEE), un ecosistema de computación geoespacial que democratiza el acceso al análisis de datos masivos. Su arquitectura se fundamenta en tres capacidades críticas:

- Repositorio Masivo de Observación Terrestre: GEE centraliza una biblioteca multitemporal de petabytes de datos provenientes de misiones satelitales (como Landsat y Sentinel). Estos activos de teledetección están pre-procesados y listos para su análisis, eliminando la carga de descarga y almacenamiento local de información.
- Procesamiento de Alto Rendimiento: La plataforma permite la ejecución de algoritmos de procesamiento paralelo y modelos de Machine Learning distribuidos. Al utilizar los clústeres de servidores de Google, se reduce drásticamente el tiempo de cómputo para análisis multivariantes en grandes áreas geográficas, como la zona citrícola de Veracruz.
- Interoperabilidad mediante APIs Especializadas: GEE proporciona un entorno de desarrollo versátil a través de interfaces de programación (APIs). Aunque la consola web utiliza JavaScript, la capacidad de integración con Python es un factor determinante para este proyecto, ya que permite conectar los datos geoespaciales directamente con las librerías de ACV e IA desarrolladas en este estudio.

En conjunto, estas características principales permiten a los usuarios descubrir, analizar y visualizar big data geoespacial de formas potentes sin necesidad de acceso a superordenadores ni conocimientos especializados en programación. (Tamiminia, 2020)

La arquitectura distribuida de GEE facilita el despliegue de técnicas avanzadas de Machine Learning, destacando el uso de clasificadores de ensamblaje como Random Forest. Este algoritmo es fundamental para tareas de reconocimiento de patrones en coberturas vegetales, permitiendo una discriminación precisa de los suelos. Más allá de la cartografía básica, el potencial de esta plataforma se extiende a un espectro diverso de investigaciones, que abarcan desde el monitoreo hidrológico y la planificación del desarrollo urbano, hasta la modelación de fenómenos climáticos y la gestión de riesgos por desastres naturales. (Meisam, Arsalhan, & al, 2020)

Conclusiones

El marco teórico expuesto demuestra que se requiere de una integración robusta de diferentes técnicas para migrar hacia la agricultura de precisión, por lo que este capítulo tiene como objetivo describir los términos que soportan este proyecto para la comprensión de las diferentes técnicas que nos auxilian a fundamentar lo redactado en los objetivos, buscando una investigación ordenada y coherente para la investigación reafirmando que el uso de estas tecnologías innovadoras no son el fin, sino el medio que nos ayude a tomar decisiones sea informada y sostenible.

Capítulo III

Estado del Arte

En este capítulo se describen los trabajos que ayudaron a identificar la brecha de oportunidad, centrada en encontrar la intersección de la sostenibilidad de la cadena de suministro y el uso ético de las tecnologías de la información en la producción de jugo de naranja en Álamo, Veracruz, ofreciendo una revisión crítica de la literatura científica dividida en tres ejes principales ejes fundamentales: primero el uso del ACV como una herramienta diagnóstica en la naranja y otros cultivos; como segundo eje tenemos los sistemas de información geográfica y teledetección para la robustez del sistemas y el monitoreo de cultivos para finalizar con IA que nos ayudara a optimizar y pronosticar los sistemas productivos para una mayor rentabilidad. Con esta base documental transitaremos de un diagnóstico estático a una propuesta de gestión dinámica y predictiva.

3.1. Diagnóstico Ambiental

En estos trabajos que refieren al ACV de producción de naranja en la Tabla 3.1.1 ACV Naranja y la Tabla 3.1.2, donde se observó que todos realizaron un ACV de la cuna a la puerta, debido al fuerte trabajo que representa este tipo de análisis, así como la poca información que existe acerca de la trazabilidad del producto al final de la cadena de suministro, la importancia de esto reside en que para esta metodología el primer paso es delimitar el tipo de análisis que se realizará. Así mismo se visualizó que en cuanto a los trabajos: *(Koljonen, 2023)* *(Germer, 2009)* y *(Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022)* realizaron un Análisis de ciclo de vida en la agricultura de la naranja tomando como Unidad funcional una tonelada de naranja, mientras que en los trabajos que realizan un análisis de ciclo de vida con un análisis de costos o energía hacen uso de dos unidades funcionales como la tonelada, el kilogramo o inclusive un envase de jugo *(Pergola, y otros, 2013)*, *(Dwivedi, Spreen, & Goodrich-Schneider, 2012)*, *(Pergola, y otros, 2013)*

En cuanto los objetivos principales de los trabajos destacan el comparar el impacto ambiental de la naranja con otros cítricos como en *(Pergola, y otros, 2013)* donde se realiza la comparación entre la naranja y el limón de tipo orgánico y convencional, mientras que *(Yan, 2016)* realizan la comparación entre las 5 principales frutas consumidas en China buscando observar el beneficio nutrimental vs el impacto ambiental, del otro lado del mundo *(Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022)* realiza un análisis de ciclo de vida para comparar la producción de naranja por su forma de cultivo: orgánica y convencional, resulta interesante el trabajo de *(Germer, 2009)* donde realiza el análisis de ciclo de vida y compara las fincas de la zona buscando las de menor impacto y así adoptar mejores prácticas agrícolas; en *(Alzubi, 2024)* realizan un Análisis de ciclo de vida y propone el cierre de la cadena de suministro para reducir los problemas económicos y sociales de esa población, cosa que resulta relevante.

Se contabilizaron 8 tipos de metodologías utilizadas como Impact Word +, IPCC 2006, ReCipe 2016, EPD 2008, PAS 2050, etc. Tanto que en bases de datos utilizadas para la parte de agricultura la más usada fue EcolInvent, seguida de Agritfoodprint y otras, en cuanto a los algoritmos utilizados para realizar estos análisis el más utilizado fue SimaPro en sus diferentes versiones desde el 7.3.3 hasta la versión número 8.

Es relevante el hecho de que solo (Koljonen, 2023) realizó el análisis de sensibilidad, esto a causa de la poca información con que se cuenta y lo caro que resultan este tipo de proyectos. Así mismo, (Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro, 2019) parte de un ACV como diagnóstico siendo referente en este trabajo, aunque su aportación sea en la caña de azúcar el cual también es un cultivo referente en Veracruz.

Tabla 3.1.1 ACV Naranja

Trabajo	Autor	Aportación
Comparing apples to oranges – Evaluating the impacts of conventional and organic products on biodiversity using different LCIA methods.	(Koljonen, 2023)	Demuestra que la elección de técnica es importante con respecto a los resultados de ACV que quieran obtener, así como la incorporación de la biodiversidad.
Energy life-cycle assessment and economic analysis of sweet orange production in Nigeria	(Ogunlade, 2020)	Cálculo de los consumos de energía de la producción de naranja dulce.
Environmental and Economic Sustainability Assessment of Navel Oranges from the Cultivation to the Packinghouse According to Environmental Product Declarations System	(Nicolo, 2017)	Identificación de los puntos críticos de impacto ambiental, así como los costos del proceso.
Multiyear life energy and life cycle assessment of orange production in Iran	(Alishah, Motevali, Tabatabaeekoloor, & Hashemi, 2019)	Reconocimiento de los impactos ambientales en los primero 7 años de vida de los huertos de naranja.
Sustainability evaluation of Sicily's lemon and orange production: An energy, economic and environmental analysis	(Pergola, y otros, 2013)	Se detalló un análisis de ciclo de vida, de energía y costos para la comparación de la sustentabilidad en huertos de limón y naranja ecológico y convencional.
Life cycle assessment of cane sugar production: The environmental contribution to human health, climate change, ecosystem quality and resources in México.	(Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro, 2019)	Minimización de los Impactos ambientales dentro de los procesos en la producción de Azúcar.

Tabla 3.1.2 Continuación ACV Naranja

Trabajo	Autor	Aportación
Assessing the environmental profile of orange production in Brazil	(Germer, 2009)	Se modelo la producción de naranjas en los municipios más importantes de Brasil, de la naranja para jugo concentrado, haciendo una comparación de fincas utilizando el ACV para estandarizar en un futuro las prácticas agrícolas.
Farm and product carbon footprints of China's fruit production—life cycle inventory of representative orchards of five major fruits	(Yan, 2016)	Se describe la huella de carbono de las 5 principales frutas consumidas y producidas en china, así mismo se ve cual es la que aporta más beneficios y se saca un rendimiento de costos dependiendo de la huella de carbono vs producción.
Evaluating the environmental performance of orange production in Veracruz, Mexico: A life cycle assessment approach	(Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022)	Caracterización de los impactos ambientales con respecto al tipo de producción de naranja ya sea convencional u orgánica, así como el tamaño de la finca, mientras que se pudo ver los puntos más críticos del proceso.
Global warming impact of Florida's Not-From-Concentrate (NFC) orange juice	(Dwivedi, Spreen, & Goodrich-Schneider, 2012)	Creo un inventario importante para la estimación de impactos en la producción de Jugo en Florida.
Enhancing economic-social sustainability through a closed-loop citrus supply chain: A life cycle cost analysis	(Alzubi, 2024)	Realización de un análisis de costos a partir del análisis de ciclo de vida, donde se propone la circularidad de la cadena de suministro en la producción de naranja.
Peeling the orange: Delving into life cycle indicators for water footprint, ecosystem services, and biodiversity for orange cultivation in Uruguay	(Cabot, Lado, & Sanjuán, 2025)	Proporciona la primera aplicación de indicadores ambientales recientemente desarrollados para ACV agrícolas a la producción de frutas cítricas, con el objetivo de impulsar el desarrollo de estudios integrales

3.2. Teledetección y Monitoreo Espacial hacia la agricultura de precisión

En cuanto a la técnica de georreferenciación en la Tabla 3.2.1 y **¡Error! No se encuentra el origen de la referencia.** se observan los trabajos que soportan esta investigación, demostrando investigaciones recientes y no mayores a diez años, al ser herramientas hasta cierto punto nuevas y complejas se busca darle este sentido al ACV buscando una metodología complementaria con un modelo hibrido con inteligencia artificial geoespacial como se observa en estos trabajos con el fin de que sea útil para las personas interesadas como lo mencionan (Loures, 2020) y (Bamane, 2024), así mismo, se observa que no solo hay investigaciones de ACV sino también algunas ligadas a la Agricultura de Precisión buscando optimizar ese eslabón de la cadena de suministro de la naranja en Álamo Temapache, Ver.

Tabla 3.2.1 Sistemas de Georreferencia

Título del Trabajo	Autor	Aportación
Monitorización remota de sistemas agrícolas utilizando series temporales NDVI y métodos de aprendizaje automático: una herramienta para una política agrícola adaptativa	(Lebrini, 2020)	Demuestra la eficacia de utilizar índices de Vegetación NDVI con diferentes modelos de machine learning pueden crear un monitoreo dinámico que ajuste las prácticas agrícolas en tiempo real
Mapping the path to decarbonised agri-food products: a hybrid geographic information system and life cycle inventory methodology for assessing sustainable agriculture	(Martindale, Saeidan , Tahernezhad-Javazm, & Jagtap, 2024)	Presenta una metodología SIG-ICV que demuestra cómo el mapeo de la producción agrícola puede utilizarse para calcular las huellas de carbono regionales, de modo que la reducción de emisiones de GEI sea geográficamente estratégica.
Application of integrated LCA-GIS model in the agricultural sector: A brief overview	(Kaita & Harun, 2023)	Describe la situación actual de la técnica ACV-SIG en la agricultura buscando reducir las brechas en la investigación.

Tabla 3.2.2 Continuación Sistemas de Georreferencia & ML

Título de Trabajo	Autor	Aportación
Resultados de la implementación y funcionamiento del servicio de Ordenamiento Territorial en agricultura cañera	(Viñas-Quintero, Pérez-Herrera, Hernández-Macías, González-Dyer, & Lugo-Ruiz, 2024)	Expuso los principales resultados de la implementación y funcionamiento de un SIG en la agricultura cañera, que permite mayor fiabilidad en el control de la tierra y su uso, soporte para la toma de decisiones en los programas de siembra, variedades, cálculo de fertilizantes, herbicidas, etc.
Evaluación de la eficacia de los sistemas de gestión de la agricultura de precisión en pequeñas explotaciones mediterráneas	(Loures, 2020)	Expone la necesidad de utilizar tecnología para los pequeños productores es urgente y rentable, ayudando así al medio ambiente.
Estado de los principales índices de vegetación en estudios de agricultura de precisión indexados en Web of Science: Una revisión	(Radočaj, 2023)	Describe la situación actual del uso de NDVI, exponiendo a USA y China como los países con más explotación de estos temas para la transición a la Agricultura de precisión.
Enhancement in Multi Spectral Camera System for Precision Agriculture using NDVI Calculation Algorithm	(Bamane, 2024)	Desarrolla un modelo asequible para los pequeños productores con el cálculo de NDVI buscando una migración a la agricultura de precisión

3.3. ML hacia la Agricultura de Precisión

En la Tabla 3.3.1 se observan aquellos trabajos que utilizan las diferentes técnicas de Inteligencia Artificial con el mismo objetivo de este proyecto, el cual es el consumo eficiente de los recursos y del agua buscando la sostenibilidad de las actividades como (Ashkan, Nabavi-Pelesaraei; Reza, Abdi; Shahin, Rafiee, 2014), (Ashkan, Shahin, Seyed, Homa, & Kwok-wing, 2018) y realizan un análisis de energía el cual tiene como base el ACV, pero desde el uso de energías y combustibles.

Las técnicas más utilizadas fueron redes neuronales, ANFIS, y lógica difusa, en cuanto a bases de datos la única que utilizaron fue Ecolnvent en sus diferentes versiones, mientras los softwares utilizados fueron Excel, Matlab, SimaPro. La mayoría de estos trabajos realizaron un análisis de sensibilidad.

Tabla 3.3.1 Edo. del Arte de aplicaciones ambientales e IA

Título del Trabajo	Autores	Aportación
Neural network modeling of energy use and greenhouse gas emissions of watermelon production systems	(Ashkan, Nabavi-Pelesaraei; Reza, Abdi; Shahin, Rafiee, 2014)	Se utilizaron redes neuronales para predecir las emisiones y el rendimiento en la producción de sandía.
Comprehensive model of energy, environmental impacts and economic in rice milling factories by coupling adaptive neuro-fuzzy inference systems and life cycle assessment	(Ashkan, Shahin, Seyed, Homa, & Kwok-wing, 2018)	Reducción del uso de energía por medio de un modelo ANFIS, partiendo de la detección de las etapas con mayor impacto ambiental usando un ACV y energía.
Application of machine learning to predict of energy use efficiency and damage assessment of almond and walnut production	(Salimi Beni, Gholami Parashkoohi, Beheshti, Ghahderijani, & Bakhoda, 2023)	Caracterización de los impactos ambientales de la producción de nuez y almendras, para la reducción de cuellos de botella por medio de IA

En la última década, el paradigma de la evaluación agroindustrial ha transitado de modelos estadísticos empíricos aislados hacia marcos analíticos híbridos que fusionan el poder de la teledetección espacial con algoritmos avanzados de computación. La integración sinérgica entre los Sistemas de Información Geográfica (SIG) y las técnicas de Aprendizaje Automático

(Machine Learning) ha emergido como el estándar metodológico de vanguardia para resolver la incertidumbre inherente a los sistemas biológicos y optimizar las cadenas de suministro agrícolas a escala regional. Por lo que en la Tabla 3.3.2 se describen los trabajos que demuestran la viabilidad técnica de este enfoque metodológico ha sido validada con éxito en diversas regiones agrícolas de México y Sudamérica mediante investigaciones que guardan una estrecha homología estructural con el presente estudio.

Tabla 3.3.2 ML & SIG

Título del Trabajo	Autores	Aportación
Clasificación Supervisada para el Mapeo del Maíz Forrajero Mediante Teledetección en la Región Lagunera, México	(Delgado-Ramírez, Gerardo; Bolaños-Martín; González, Martín; Quevedo-Nolasco, Abel; López-Pérez, Adolfo; Estrada-Ávalos, Juan, 2025)	Demuestra la viabilidad técnica en el contexto mexicano de utilizar firmas espectrales satelitales para discriminar cultivos complejos y mapear su distribución dinámica, sirviendo como base operativa para la zonificación regional
Predicción del rendimiento del cultivo de arroz mediante imágenes Sentinel-2 y el algoritmo Random Forest	(Quille-Mamani, Ruiz, Carbonell-Rivera , & Ramos-Fernández, 2024)	Comprueba que la integración de imágenes satelitales multitemporales con el algoritmo Random Forest captura eficazmente la estructura no lineal del rendimiento biológico.
Machine learning empowered geographic information systems: Advancing Spatial analysis and decision making	(Protim Roy, Abdullah, & Siddique , 2024)	Este trabajo examina cómo la integración de algoritmos de ML (como redes neuronales, bosques aleatorios y clustering) transforma los SIG tradicionales en sistemas inteligentes y predictivos.

Conclusiones

El estado de arte revela que, aunque existen investigadores comprometidos realizando excelentes propuestas en la evaluación ambiental de las cadenas de suministro agrícolas, persiste una desconexión de los eslabones y sobre todo entre el diagnóstico y la capacidad predictiva de la IA en tiempo real, por lo que, esta investigación propone abordar estas brechas al proponer un sistema integral, fundamentada en metodologías ya validadas en esta región como lo demuestran algunos autores mexicanos, no solo buscando la eficiencia técnica, sino una herramienta de soporte para una cadena de suministro que permanece como una identidad .

Capítulo IV

Metodología

En el presente capítulo se describe el procedimiento que se desarrolló para abordar la complejidad de la cadena de valor citrícola en Alamo Temapache, Veracruz desde una perspectiva de sostenibilidad integral, proponiendo una ruta metodológica híbrida que donde convergen tres dimensiones críticas: la evaluación del impacto ambiental mediante el ACV, el monitoreo a través de la teledetección y el poder predictivo de la IA. Donde no solo se busca la precisión técnica sino en la necesidad de generar herramientas adaptativas que soporten la viabilidad económica y el patrimonio cultural de la producción local ante la incertidumbre de los cambios climáticos y el aumento poblacional.

4.1. Metodología General

Este proyecto es una investigación de tipo cuantitativa, aplicada y de diseño experimental, sostenida de diferentes herramientas tecnológicas, teniendo como estudio de caso la cadena de suministro del jugo de naranja en Álamo Temapache, Veracruz, por lo que, en la Figura 4.1.1 se observa la metodología que se desarrolló está conformada de dos partes generales, el diagnóstico de nuestra cadena de suministro y la segunda formada por estrategias que buscan el uso adecuado de los insumos para la sostenibilidad de los productos y 7 pasos generales, teniendo como herramienta de evaluación el ACV para la detección de las actividades que acumulan mayores impactos y con la aplicación de inteligencia geoespacial se complementen para tener un modelo más robusto e incluso didáctico que ayude a la mejora de la distribución de los recursos, buscando reducir la incertidumbre de la naturaleza de este proceso. Así mismo, se puede observar que el paso 5 y 6 en la Figura 4.1.1 no tiene conexión porque en realidad los datos que se utilizan para los modelos salen de los datos históricos de la agricultura y no de los resultados del ACV.




Figura 4.1.1 Metodología general

1. Revisión del Edo. Del Arte

Esta actividad comprende la revisión exhaustiva de la literatura, con el objetivo de definir claramente los alcances del estudio y mantenerse actualizados con los trabajos que se desarrollan a nivel Mundial. Se observa un interés creciente en este tipo de trabajos, debido a las limitantes y riesgos al que se enfrenta la agricultura, así como el crecimiento exponencial del uso de Inteligencia Artificial para la sostenibilidad de estas cadenas de suministro.

2. Definición del objetivo y alcance de proyecto

El objetivo y los alcances serán definidos junto con los organismos interesados, así como con los asesores involucrados en este proyecto, basado en la Norma ISO 14040.

Debido a la finalidad de este proyecto el objetivo principal del Análisis de ciclo de vida se describe a continuación:

Cuantificar los impactos ambientales de la cadena de suministro de la producción de jugo de naranja JCOF en Álamo, Veracruz, desde la agricultura hasta el Almacén del jugo, identificando las actividades con mayor impacto ambiental.

Alcances del ACV

Se busca que los límites sean de la Cuna a la Puerta, la cual será la puerta antes de salir al almacenamiento debido a que este tipo de jugo pasa a ser una materia prima para otro proceso, este producto ha sido elegido dado que es el producto de mayor venta y con mayor proceso de transformación.

Es así como este análisis comprenderá 5 eslabones de esta cadena de suministro, sin embargo, la etapa de producción de agroquímicos y transporte de la fábrica al campo se agregó a la agricultura, por lo cual a continuación solo se describen 3:

1. Agricultura: Este eslabón comprende la etapa de crecimiento y conservación de los árboles, debido a que la preparación de suelos de acuerdo con (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022) y expertos consideran que debido a la edad de los arbustos el impacto de preparación de suelo es amortizado en los años de producción, ya que existen arbustos de más de 20 años y la preparación de suelo solo

se realiza cuando se van a plantar los árboles, así mismo también comprende la cosecha de naranjas.

2. Transporte: En este bloque se agregarán los consumos de combustible fósil que se utilizan para la movilidad de la naranja en el campo a la planta como materia prima, tomando en cuenta las toneladas que los camiones tienen de capacidad y el kilometraje recorrido.
3. Fábrica: En esta última etapa se tomará en cuenta la clasificación de la materia prima, la extracción del jugo, filtración, evaporación, hasta antes del envasado ya que la mayoría del Jugo Concentrado suele ser una materia prima para otro proceso.

Unidad Funcional

Debido a la naturaleza del producto y a la extensión del estudio será una tonelada fresca de naranja producida, aunque, para fines prácticos ya han sido convertidos a dos unidades funcionales, por lo que, en la Tabla 4.1.1 se observa la unidad funcional de cada actividad que conforma el análisis para la comparabilidad con otros estudios.

Tabla 4.1.1 Unidad Funcional por actividad

Eslabón	Producto	Unidad
Agricultura	Naranja fresca	1 tonelada
Transporte	Naranja Fresca	1 tonelada
Producción	Jugo de Naranja	19 galones
	JCOF	

Así mismo, se nota que a comparación de otros estudios que solo es un galón o un bote de producto aquí son diecinueve galones con la finalidad de poder hacer una comparación y ver en qué parte de esta cadena de suministro es el impacto mayor, ya que el promedio de jugo concentrado que se extrae en la etapa de producción de jugo concentrado en promedio son esos 19 galones de una tonelada de naranja.

Límites

Es relevante elegir los límites del ACV, por lo que para este trabajo se tomara la delimitación de la cuna a la puerta de almacenamiento como se muestra en Figura 4.1.2.




Figura 4.1.2 Límites del Sistema del ACV

En lo que respecta la producción de agroquímicos, transporte de fabrica a campo y agricultura se unirán en un solo eslabón llamado agricultura por lo que en la Figura 4.1.3 se observa un diagrama de las etapas ya desarrolladas donde se visualizan que las entradas serán los fertilizantes que se utilizan comúnmente en la producción de este cítrico, así como los herbicidas y pesticidas, hasta el momento la parte de riego y preparación de la tierra sus valores son cero debido a que estos cultivos son de agua de lluvia y no de riego como lo comenta (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022), así mismo la preparación del suelo se desestimaré ya que el autor antes mencionado y (Alishah, Motevali, Tabatabaeeekoloor, & Hashemi, 2019) consideran que dado que este fruto solo requiere de una preparación de suelo cuando se planta y posteriormente en sus años productivos logra amortizar ese impacto ambiental generado, entonces, dado que los árboles dentro de este estudio tienen una edad promedio de 27 años se ha decidido omitir, sin embargo, para fines pedagógicos se ha dejado dentro del sistema.




Figura 4.1.3 Diagrama de flujo de las etapas 1-3

Mientras que en el transporte de la fábrica a planta de producción se considera el gasto de combustible para llevar la naranja a la planta de proceso de jugo como se muestra en la Figura 4.1.4.




Figura 4.1.4 Entradas y salidas del transporte

Fuente: Realización propia

Acerca del eslabón de la manufactura del jugo se define por las entradas y salidas del proceso de Jugo de Naranja tipo JCOF hasta antes de llegar al almacén de producto terminado, el diagrama de operaciones se observa la Figura 4.1.5 donde se muestra el resumen del proceso.




Figura 4.1.5 Diagrama de flujo de la producción de JCOF

3. Inventario de Análisis de ciclo de vida

En esta etapa se procedió a la estructuración de los datos para este ICV, consolidando datos primarios recolectados de empresas procesadoras de jugo ubicadas en Álamo Temapache, registros empíricos tomados directamente en campo con productores citrícolas de la región, y bases de datos institucionales facilitadas por el Instituto Tecnológico Superior de Álamo Temapache (ITSAT).

De acuerdo con los límites del sistema definidos previamente, el inventario se desglosó en tres eslabones operativos:

Eslabón Agricultura etapa 1-3

Para la etapa de producción en campo, los datos primarios se sustentan en un instrumento de evaluación tipo cuestionario aplicado por el ITSAT, el cual recopiló registros críticos sobre las dosis y tipos de fertilizantes utilizados, rendimientos históricos y propiedades edáficas generales de la región (como pH y niveles de drenaje). Debido a que los datos provenían de múltiples productores distribuidos en diversas localidades y con diferentes escalas de producción, estos presentaban una alta dispersión y no se ajustaban a ninguna distribución de probabilidad teórica tradicional.

Para resolver metodológicamente este comportamiento sin inducir a sesgos analíticos, se calcularon los valores mínimos, máximos y modas de las variables. Posteriormente, esta dispersión fue modelada en la plataforma Activity Browser (Steubing, De Koning, Haas, & Mutel, 2020). Dicho software de código abierto, diseñado como interfaz avanzada para el framework Brightway2, ofrece un abanico flexible de distribuciones estadísticas para la cuantificación de la incertidumbre en los sistemas (como la distribución triangular o uniforme), permitiendo ingresar de forma directa parámetros de límites (mínimo y máximo) y valores centrales (moda). Como complemento para aquellas variables secundarias o flujos remanentes en la zona, los datos se integraron y validaron a partir del estudio de ciclo de vida desarrollado por (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022), el cual fue ejecutado bajo las mismas condiciones geográficas y climáticas del municipio de Álamo.

Eslabón Transporte

En este apartado, el consumo de combustible diésel se determinó vinculando la base de datos de ubicación geográfica de los productores del ITSAT con la localización de la planta juguera.

Las distancias reales de recorrido (**km**) se estimaron mediante análisis de ruteo geográfico asistido por herramientas de mapeo digital.

A través de un muestreo dirigido, se determinó el tonelaje promedio transportado por viaje y el consumo de diésel asociado. Para estandarizar e indexar estos flujos al inventario, se aplicó un modelo determinista de intensidad logística, expresado bajo la siguiente relación matemática:

$$E_{Total} = \frac{\text{Gasto de combustible}}{\text{Capacidad del carro}} * \text{Factor de emisión}$$

Donde E_{Total} representa la intensidad de emisión por capacidad de carga $kgCO_2/T$, el gasto de combustible en el trayecto dado Lts, entre la capacidad de carga útil del vehículo expresada en Toneladas, y el factor de emisión físico del combustible dado en $kgCO_2/lts$. (IPCC, 2006)

Eslabón Transformación JCOF

Para la fase de procesamiento de la materia prima y obtención de Jugo Concentrado Congelado de Naranja (JCOF), los datos fueron recopilados in situ en las plantas de mayor relevancia operativa de la zona durante los periodos de máxima zafra de los años 2024 y 2025. Al disponer de registros de operación diarios, se calcularon los promedios aritméticos de los insumos químicos consumidos (detergentes y agentes sanitizantes) empleados en el lavado del fruto, la desinfección de las líneas de producción y las Buenas Prácticas de Fabricación (BPF). Dado que el proceso busca obtener un producto completamente natural y libre de conservadores químicos, no se identificaron otros compuestos aditivos dentro del jugo. El desglose elemental de los principios activos se realizó mediante la auditoría técnica de sus respectivas Hojas de Datos de Seguridad (HDS).

Respecto a los servicios auxiliares críticos de la planta, los datos de consumo energético de la caldera y el evaporador provienen de los balances de materia y energía del proceso industrial, complementados con los registros de bitácoras de operación térmica y consumo de Gas Natural de las empresas colaboradoras. Estos datos reflejan las demandas termodinámicas reales necesarias para los procesos de pasteurización, generación de vapor y concentración de sólidos solubles (Brix) bajo condiciones de operación estables. Es importante mencionar que las emisiones son resultado de todos los reportes de análisis de calderas y de sus tratamientos de agua en el lapso del 2021-2025.

Partiendo de este marco de cuantificación, a continuación, se presentan los flujos consolidados de entrada en la Tabla 4.1.2 y las salidas del sistema en la Tabla 4.1.3.

Tabla 4.1.2 Inventario de Entradas

Etapa	Cantidad Min	Cantidad Moda	Cantidad Máxima	Unidades	Fuente
Producción de fertilizante					
Urea (N)	4	10.393	14.306	Kg/T	Campo
Triple (17-17-17) (P2O5)	5.513	16.912	22.9	Kg/T	Campo
S	7	11.52	16.64	Kg/T	Campo
Ca	0.9	1.5	4.6	Kg/T	Campo
Crecimiento					
N	5.513	14.234	19.593	Kg/T	Campo
P	1.488	3.841	5.287	Kg/T	Campo
K	0	2.67	3.400	Kg/T	Campo
Ca	0.9	1.5	4.6	Kg/T	Campo
SO4	7	11.52	16.64	Kg/T	Campo
Diesel de tractor		0.712		km/T	Campo
Tierra	0.33333333	0.1	0.0625	Ha	Campo
Transporte a la fábrica					
Diesel de transporte		0.74074074		l/ton	Cálculo
Producción		Promedio			
Hidróxido de sodio		8.55		Kg/T	Fábrica
Meta silicato de sodio		0.24		Kg/T	Fábrica
Agua		620		Kg/T	Fábrica
Ácido acético		0.0305		Kg/T	Fábrica
Peróxido		0.23		Kg/T	Fábrica
Carbonato de sodio		0.66		Kg/T	Fábrica
Silicato de sodio		0.14		Kg/T	Fábrica
Sulfato de sodio		0.406		Kg/T	Fábrica
Gas natural		20		Kg/T	Fábrica
Hipoclorito de sodio		0.51		Kg/T	Fábrica

Tabla 4. 1.3 Salidas del sistema

Etapa	Cantidad Min	Cantidad Moda	Cantidad Máxima	Unidades	Fuente
Fertilizante					
Emission of dinitrogen monoxide to air		0.0513		Kg/T	Bonale (2022)
Emission of nitrogen oxides to air		0.0108		Kg/T	Bonale (2022)
Emission of ammonia to air		0.11		Kg/T	Bonale (2022)
Emission of nitrate to water		1.85		Kg/T	Bonale (2022)
Emission of phosphorous to water		0.00957		Kg/T	Bonale (2022)
Emission of cadmium to water		0.000000873		Kg/T	Bonale (2022)
Emission of zinc to water		0.000199		Kg/T	Bonale (2022)
Emission of lead to water		0.00000061		Kg/T	Bonale (2022)
Emission of cadmium to soil		0.0000248		Kg/T	Bonale (2022)
Emission of zinc to soil		0.000467		Kg/T	Bonale (2022)
Emission of lead to soil		0.000019		Kg/T	Bonale (2022)
Emission of nickel to soil		0.00005		Kg/T	Bonale (2022)
Transporte a la fabrica					
Co2	2.411	2.82	4.15	Kg/T	Cálculo
Planta de producción					
Emisión de bióxido de sulfuro	0.0003			Kg/T	Planta
Emisión de bióxido de carbono	43.75		4.26E-01	Kg/T	Planta
Mercurio al suelo agrícola	0.00005			Kg/T	Planta
Cadmio emisión al suelo agrícola	0.0003			Kg/T	Planta
Cobre al suelo agrícola	0.0031			Kg/T	Planta
Cromo al suelo agrícola	0.0033			Kg/T	Planta
Niquel al suelo agrícola	0.0011			Kg/T	Planta

Etapa	Cantidad Min	Cantidad Moda	Cantidad Máxima	Unidades	Fuente
Oxido de carbono al aire	0.0001			Kg/T	Planta
Bióxido de nitrógeno	0.0369			Kg/T	Planta

4. Evaluación de Análisis de ciclo de vida

Este apartado consiste en calcular los impactos ambientales generados en la cadena de suministro; a través de la clasificación, caracterización y evaluación, con el fin de conocer sus impactos ambientales apoyado en la metodología **IMPACT 2002+** (Jolliet, 2003), dada la necesidad de tener una visión global que conectara categorías de punto medio y de puntos finales de una manera general como lo es esta herramienta al tener toxicidad humana, calidad del ecosistema, cambio climático y recursos.

Así mismo, la aplicación de esta metodología asegura la consistencia con investigaciones importantes previas realizadas en la región como (Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro, 2019), siendo una guía para la interpretación técnica de los daños ambientales en caña.

5. Interpretación de indicadores

En este punto se interpretarán de los indicadores ambientales. De estos resultados, se identificarán la etapa(s) con mayor impacto ambiental en los ámbitos que contiene esta metodología de cuantificación de impactos que son la calidad del ecosistema, cambio climático, salud humana y uso de recursos.

6. Sistema de inteligencia georreferencial

Con los resultados de ACV se diagnosticó el eslabón que requiere atención para buscar estrategias que ayuden a mejorar la huella ambiental en esa etapa de la cadena de suministro, por lo tanto, tomando en cuenta a (Guevara, 2017) se utiliza la siguiente metodología, que se muestra en la




Figura 4.1.6. Esta metodología se rige fundamentalmente por la presentación de una hipótesis, la subsiguiente experimentación y la confirmación o rechazo de la misma para realizar una estrategia que ayude a fortalecer el sistema y funcione como una herramienta practica a las personas encargadas del eslabón con mayor impacto ambiental.




Figura 4.1.6 Metodología Gral. de los SIG

Sin embargo, debido a la complejidad de los modelos SIG y el objetivo de la Investigación se modificó la metodología para poder realizar un modelo híbrido, quedando de la siguiente manera en la Figura 4.1.7; **Error! No se encuentra el origen de la referencia.**, para facilitar la comprensión y practicidad tanto para el usuario como para los desarrolladores del sistema.




Figura 4.1.7 Metodología Híbrida Propuesta

1) Fundamento del sistema

El objetivo nace de la necesidad de transitar de la agricultura tradicional a una agricultura de precisión y que también ayude a robustecer la información que se tenía con las nuevas tecnologías, ya que, se observó que muchos agricultores hacen sus prácticas agrícolas a su experiencia, por lo que es una forma de mostrar cómo se está comportando su tierra para poder realizar una correcta fertilización ya que, en algunas situaciones en un solo terreno el suelo y sus características no son homogéneas, por lo que este modelo se diseña bajo un paradigma de tecnología abierta, usando la democratización de datos para ofrecer un sistema de apoyo a decisiones informadas y de bajo pro de los usuarios.

2) *Gestión del modelo*

Para lograr la finalidad y garantizar la potencia de cálculo sin comprometer recursos locales de almacenamiento se optó por dos plataformas importantes:

- Google Earth Engine (GEE): Al ser un repositorio de datos multiespectrales de sensores remotos (sentinel-2 y landsat) gratis para la investigación y con api incluida, evitando así la descarga local de archivos. (Google LLC, 2005)
- Google Colab: Se utilizó como entorno de ejecución para algoritmos de IA basados en Python, aprovechando su capacidad de procesamiento y potencia en la nube. (Google LLC, 2018)

3) *Arquitectura del modelo de Inteligencia Geoespacial*

Este modelo busca robustecer la información y tener una herramienta de fácil comprensión para los agricultores de las nuevas tecnologías centrándose en la interoperabilidad. Implementando un flujo de tratamiento de imágenes para el cálculo de series temporales del NDVI, como variable fundamental para medir el vigor fotosintético y la salud vegetal, se calculó el **Índice de Vegetación de Diferencia Normalizada (NDVI)** mediante la ecuación:

$$NDVI = \frac{NIR - RED}{NIR + RED}$$

Donde **NIR** corresponde a la banda del infrarrojo cercano y **RED** a la banda roja. Los valores resultantes (en un rango de -1 a 1) se exportaron como series de tiempo, los cuales actúan como el puente entre el impacto ambiental medido en la Fase I y el rendimiento real observado. (Lebrini, 2020)

4) *Integración de Machine Learning*

Se utilizó un enfoque híbrido de aprendizaje supervisado con las siguientes técnicas:

- Random Forest: Esta técnica se implementó en GEE para la clasificación de la cobertura de suelo, ya que muestra diferentes tonos entre el negro y el verde por lo que se requirió que aprendiera a clasificar por los colores del cultivo.

- Series de tiempo: Junto con el Random Forest la serie de tiempo determina el NDVI, este indicador es solo un indicador estático y en algunos casos solo color, al usar series de tiempo se volvió un numero dinámico.
Se estructuraron los datos históricos para alimentar el modelo, permitiendo aprender de estos.

5) Validación

Debido a la escasez de bases de datos locales públicas, la validación del modelo se realizó mediante métricas intrínsecas del sistema como son:

- Accuracy: Este indicador de exactitud en la clasificación del sistema
- AUC: Es utilizada para validar la capacidad de discriminación del modelo, el cual se traduce al área bajo la curva
- F1-score: Asegura un equilibrio entre precisión y sensibilidad de los pronósticos.

6) Resultados

El resultado del modelo hibrido más que un mapa, también es un tablero de diagnóstico predictivo que entrega al agricultor los siguientes indicadores agrometeorológicos:

- Pronóstico de NDVI, el cual proyecta la salud del cultivo.
- Variables climáticas como temperatura actual y precipitación acumulada (7 y 30 días).
- Índice de la aptitud operativa donde se recomienda si las condiciones son óptimas para fertilización o plantación, con una respuesta binaria, buscando reducir el desperdicio de insumos y la mejora de las prácticas agrícolas.

7. RNA para pronóstico de rendimiento

Para la mejora de la cadena de suministro se creó un modelo hibrido de IA que nos proporcionara un número de NDVI del modelo anterior y que fuera una entrada junto con las 17 variables de datos recolectados de los diferentes agricultores de la zona para realizar un modelo de redes neuronales que nos ayudara a pronosticar los rendimientos de las cosechas en Toneladas de naranja por hectárea con el objetivo robustecer el sistema.

Con el firme objetivo de aportar a la gestión ambiental, ya que, las estrategias derivadas de este modelo buscan la reducción de impactos críticos identificados en el (ACV). Por lo que, es importante precisar que estas estrategias actúan como recomendaciones técnicas basadas en la predicción del sistema; el protocolo metodológico establece que, tras su implementación, debe realizarse una reevaluación empírica para cuantificar la reducción neta del impacto ambiental junto con una evaluación para miras de una optimización integral de este eslabón, cerrando de esta forma el ciclo de mejora continua.

En la Figura 4.1.8 se detalla la metodología utilizada para la última parte del proyecto.




Figura 4.1.8 Metodología RNA

1) Formulación del problema

El entrenamiento de la RNA pretende otorgar predicciones sobre el comportamiento del rendimiento de la naranja a partir de las variables que componen al sistema partiendo de los datos obtenidos en cuestionarios y modelos realizados con apoyo de sistemas de información geografía e IA. Esta investigación se fundamenta en el uso de Python, utilizando la librería scikit-learn para la construcción de una arquitectura de tipo Perceptrón Multicapa (Multilayer Perceptron). Se seleccionó este entorno debido a su capacidad para modelar sistemas

complejos y no lineales, superando las limitaciones de los modelos estadísticos tradicionales en entornos agrícolas institucionales con alta incertidumbre. Esto es vital porque la agricultura no es lineal; hay factores climáticos y biológicos complejos que solo estas funciones pueden capturar debido a la gran incertidumbre que existe en estos sistemas.

Se utilizó la plataforma Colab (Google LLC, 2018) por las ventajas de ser un programa libre y potente al ser colaborativo.

2) Preprocesamiento de datos

Antes de la creación de la Red Neuronal en Colab, se realizó una preparación de datos como:

- Integración de datos, en una sola base de datos se consolidaron en una matriz única los datos del NDVI con los datos que se tenían del Inventario del Análisis de Ciclo de Vida
- Limpieza de datos, se eliminaron los valores atípicos y faltantes.
- Clustering, se aplicó esta técnica de IA para verificar que los datos fueran independientes y tener la certidumbre de que las 18 variables eran necesarias en el modelo dado su comportamiento en el sistema
- Partición de la Muestra, mediante `train_test_split`, se destinó un 85% de los datos para entrenamiento y un 15% para validación (`test_size=0.15`).
- Estandarización, se empleó `StandardScaler` para normalizar las variables a una media de cero y desviación estándar de uno. Esto garantiza que la red procese equitativamente variables de distintas magnitudes.

Una vez que se realizó todo el preprocesamiento de los datos las variables del sistema se describen a continuación en la Tabla 4.1.4 donde se describen las 18 variables de entrada y 1 de salida.

Tabla 4. 1.4 Variables del Sistema RNA

Variable	Atributo	Tipo	Unidad
X_1	Temperatura Anual	Continua	°C
X_2	Precipitación Anual	Continua	mm
X_3	Radiación solar	Continua	horas
X_4	Índice de severidad de sequia	Categórica	0 moderado 1 fuerte 2 muy fuerte
X_5	Pendiente	Continua	Porcentaje de inclinación
X_6	Altitud	Continua	Metros sobre nivel del mar
X_7	Drenaje Externo	Categórica	
X_8	Drenaje interno	Categórica	
X_9	Edad promedio de los arboles	Continua	Años
X_{10}	Textura	Categórica	
X_{11}	pH	Continua	Potencial de hidrogeno
X_{12}	Nitrógeno	Continua	Kg
X_{13}	Fosforo	Continua	Kg
X_{14}	Potasio	Continua	Kg
X_{15}	Calcio	Continua	Kg
X_{16}	Azufre	Continua	Kg
X_{17}	NDVI	Continua	NDVI
Y_1	Rendimiento	Continua	Toneladas

3) Construcción de la red neuronal

Se construyo una red neuronal en Colab con 154 datos bajo los parámetros técnicos que a continuación se detallan:

- Capas Ocultas: Estructura profunda con dos capas ocultas cuya cantidad de neuronas se determinó mediante ensayo y error, buscando el equilibrio entre precisión y generalización del modelo, configuradas para maximizar la capacidad de aprendizaje de este.
- Función de Activación: Se utilizó la tangente hiperbólica ($\tanh$) en las capas ocultas, permitiendo al modelo capturar la complejidad de los datos estandarizados.
- Algoritmo de Ajuste: Se implementó el solver L-BFGS, seleccionado por su eficiencia en la convergencia de pesos en conjuntos de datos estructurados.

4) Validación de datos

Debido a la distribución elegida para la arquitectura, el entrenamiento se detiene cuando el error de validación deja de disminuir, buscando garantizar que el modelo sea capaz de ser global.

5) Análisis de los resultados

La potencia de este software se observa en el sinfín de opciones y herramientas que se pueden programar, por lo que este modelo no solo genera predicciones, sino que se apoya de herramientas tecnológicas vanguardistas de diagnóstico como las que se detalla a continuación:

- Métricas de Desempeño como la evaluación mediante el Error Cuadrático Medio MSE y el coeficiente de determinación R^2 mediante Matplotlib.
- Análisis de sensibilidad, donde se analizó la matriz de pesos sinápticos para jerarquizar qué variables (clima, fertilizantes, NDVI) impactan con mayor fuerza en la producción.
- Graficas de regresión, donde se analizan los valores reales vs las predicciones.
- Interfaz Interactiva, mediante el uso de ipywidgets, se desarrolló un tablero de control dinámico. Esta herramienta permite a los tomadores de decisiones ajustar los parámetros de entrada y visualizar instantáneamente el pronóstico de producción, transformando el código en una herramienta de gestión operativa.

Conclusiones

En conjunto, esta metodología expuesta constituye un marco de análisis multiescalar donde se transforman datos crudos en conocimiento estratégico, buscando la comprensión sencilla del proyecto partiendo de algunos problemas que se fueron presentando y que cerrarán algunas brechas de conocimiento tanto para el desarrollador como para el usuario final, al centralizar el procesamiento en herramientas de vanguardia como Python y la nube de Google, buscando garantizar la reproducibilidad, mejora de la investigación y su escalabilidad a otras circunstancias. Por lo que, en ultimas instancias, la solidez de este flujo de trabajo permite que las conclusiones derivadas de tal estudio no sean meras observaciones estadísticas, sino propuestas de gestión resiliente donde la eficiencia de los recursos se priorice sin olvidar que esta cadena de suministro regional es orgullo de todo un pueblo.

Capítulo V

Resultados

En este apartado contiene los resultados obtenidos derivados de la implementación de la metodología híbrida, exponiendo los hallazgos de manera secuencial, comenzando con el perfil de impacto ambiental de la cadena citrícola, seguido por el comportamiento del espacio-temporal obtenido por vía satélite, culminando con el desempeño de una red neuronal. Permitiendo con esta integración identificar no solo cuanto contamina el sistema, sino, que nos ayuda a una toma informada de las decisiones teniendo en cuenta la salud real de los cultivos y los retos que asociados esta cadena de suministro.

5.1 Resultados del ACV

Para evaluar el perfil ambiental de la cadena de suministro citrícola en Álamo Temapache, Veracruz, se interpretaron los resultados analíticos obtenidos mediante el framework Brightway2 y la interfaz Activity Browser, aplicando el método de evaluación de impacto IMPACT 2002+. Los resultados se presentan normalizados y ponderados en mapas de calor, estructurados tanto para las categorías de daño finales (Endpoints) como para las categorías de impacto intermedias (Midpoints).

Esto con la finalidad de hacer un análisis general de este sistema, se utilizaron Puntos (Pt) porque, tal como lo establece la metodología de (Joliet, 2003), la cual permiten estandarizar e integrar magnitudes físicas dispares en un solo indicador dimensional común. Por lo que, simplifica la interpretación para la toma de decisiones estratégicas, permitiendo identificar visualmente los puntos críticos (hotspots) de la cadena sin perder el rigor del inventario, todo esto, debido a la naturaleza multifacética de la cadena de suministro citrícola, ya que el inventario crudo arroja una enorme dispersión de magnitudes físicas dispares (como masas de compuestos químicos, julios de energía o becquerels de radiación).

El primer contacto visual de este análisis se consolida con la Figura 5.1.1 de la caracterización relativa de los puntos medios de impacto de esta metodología, la cual al ser un mapa de calor que distribuye el 100% de la carga ambiental de cada categoría entre los procesos unitarios evaluados. Este diagrama permite identificar de manera visual e inmediata qué eslabón de la cadena actúa como el "hotspot" o punto crítico de control ambiental para cada indicador.

Este mapa de calor revela una polarización drástica de los impactos. Las categorías asociadas a la degradación química y ecotoxicidad (terrestre, acuática y toxicidad humana) se concentran con una tonalidad máxima en el eslabón de la Agricultura. Este comportamiento es un indicador inequívoco del peso que posee la etapa de campo debido al uso intensivo de insumos sintéticos. Por otro lado, los indicadores vinculados al consumo de recursos fósiles y al agotamiento de la capa de ozono desplazan su intensidad hacia los eslabones de Transporte y Proceso Industrial (JCOF), reflejando la alta dependencia energética y térmica de las fases de movilidad y manufactura. Esta distribución justifica la necesidad de desglosar cada categoría a nivel elemental para comprender los mecanismos cinéticos e industriales que provocan dichas coloraciones en el software.



Figura 5.1.1 Mapa de Calor General Mid Point

Al realizar un análisis del mapa de calor global de categorías finales Figura 5.1.2, se observa que persiste la asimetría marcada en la distribución de las cargas ambientales a lo largo de la cadena de suministro.

Donde el eslabón de Agricultura (que incluye el transporte de los agroquímicos, su producción y la fertilización) absorbe la mayor parte de la culpabilidad ambiental de la cadena. Su impacto más crítico se concentra en la categoría de Salud Humana (Human Health) con 0.55 Pt, seguido por Calidad del Ecosistema (Ecosystem Quality) con 0.027 Pt y Cambio Climático (Climate Change) con 0.021 Pt. Este comportamiento está directamente ligado al uso intensivo de fertilizantes sintéticos (Urea y Triple 17), cuya producción y volatilización en campo liberan compuestos altamente reactivos.

Mientras para el proceso JCOF (extracción de jugo) se posiciona como el segundo eslabón con mayor impacto, concentrando su daño principalmente en Calidad del Ecosistema (0.026 Pt). Esto se debe al uso intensivo de energía térmica y eléctrica (Gas Natural y electricidad de la red), así como al consumo de agentes químicos de limpieza (Hidróxido de sodio y ácidos) indispensables para cumplir con las Buenas Prácticas de Fabricación (BPF).

El eslabón de Transporte a la fábrica presenta valores prácticamente despreciables en comparación con los otros dos bloques (0.00011 Pt en Cambio Climático y 0 en las demás

categorías). Esto demuestra que, para la escala regional de Álamo Temapache, las distancias recorridas para trasladar la materia prima hacia la juguera no representan un punto crítico (hotspot) ambiental dentro del ciclo de vida “de la cuna a la puerta”.




Figura 5.1.2 Mapa de Calor de ACV end point

Al evaluar la categoría de daño a la salud humana y ecosistemas por Cambio Climático Figura 5.1.3, el modelo de ciclo de vida evidencia una coexistencia de vectores de emisión de gases de efecto invernadero (GEI) con naturalezas operativas completamente distintas.

El eslabón de Transporte ejerce una presión ambiental concentrada. Su contribución está determinada en un 100% por la logística regional de transporte del fruto. Este comportamiento responde directamente al consumo de combustible diésel en los vehículos de carga pesada y unidades medianas que trasladan la naranja desde las huertas locales hasta la báscula de la planta procesadora. Las emisiones asociadas corresponden a la combustión interna móvil del hidrocarburo, liberando dióxido de carbono, óxidos de nitrógeno y material particulado directamente a la atmósfera.

Por su parte, el Proceso JCOF exhibe un perfil dominado por el consumo de recursos energéticos estacionarios dentro de la planta industrial. La huella de carbono en este nodo está traccionada por la quema de Gas Natural para el funcionamiento de los servicios auxiliares críticos: la caldera de vapor y el sistema de evaporación multi-efecto. La demanda

termodinámica necesaria para la pasteurización térmica del jugo y la subsecuente concentración de sólidos solubles genera un flujo continuo de emisiones de dióxido de carbono de origen fósil en esta categoría.

Un comportamiento de gran interés para la ingeniería de la cadena de suministro ocurre en la Agricultura. La barra de contribución revela que la huella de carbono de la fase de campo no está determinada por las operaciones mecánicas locales (como el uso de tractores), sino por los procesos de manufactura industrial de los agroquímicos. Específicamente, se aprecia la presencia nítida del nitrógeno sintético a través de la producción de urea y amoníaco anhidro líquido. Lo que demuestra cuantitativamente que la carga de GEI de la naranja veracruzana está "heredada" desde las plantas petroquímicas de producción, donde se fijan los nutrientes a partir de combustibles fósiles antes de que el fertilizante llegue al suelo local, sin embargo, al ser una variable exógena, nos concentramos en lo que está dentro de nuestro sistema para cambiar las prácticas de agricultura y así reducir ese consumo.




Figura 5.1.3 Gráfica de Cambio Climático

Para descifrar el mecanismo por el cual los insumos químicos gobiernan el perfil de impacto en el campo, es necesario analizar el diagrama de red y flujos de corte (Sankey Network) provisto por el software Figura 5.1.4., donde este mapa de acoplamientos tecnológicos rastrea vectorialmente la cadena de suministro industrial de los fertilizantes utilizados en Álamo Temapache.

El análisis de la red demuestra que el flujo del indicador de nitrógeno inorgánico hacia el nodo de "Producción de fertilizante y pesticidas, Álamo, Veracruz" se encuentra controlado en un

De forma paralela, el segundo eje de suministro de nitrógeno inorgánico corresponde a la Urea, aportando de manera directa el 15.7% del flujo de nutrientes del inventario agrícola.



En el eslabón de la Agricultura, el perfil está dominado de forma mayoritaria por emisiones de Zinc II y Aluminio III directamente en el compartimento de suelo.

En contraste, el Proceso JCOF desplaza su perfil eco toxicológico hacia la emisión de Iones de Cobre y Cromo III en el suelo industrial. Este comportamiento es un reflejo directo de las operaciones de mantenimiento e higienización de la planta procesadora.




Figura 5.1.5 Gráfica de Ecotoxicidad Terrestre

La contaminación de los cuerpos de agua exhibe un comportamiento segregado por sustancias dominantes, como se ilustra en el perfil de Ecotoxicidad Acuática Figura 5.1.6.

En la Agricultura, el impacto ambiental está regido al 100% por flujos elementales de Cadmio II emitidos hacia el compartimento hídrico. Debido a los regímenes de precipitación pluvial característicos de Alamo Temapache, Veracruz, estos metales son arrastrados por procesos de escorrentía superficial hacia los arroyos locales o se lixivian a través del perfil del suelo hasta alcanzar los mantos acuíferos lo que representa un riesgo severo para la biodiversidad de los ecosistemas de la región.

Por el contrario, el Proceso JCOF concentra casi el 85% de su contribución eco toxicológica acuática en emisiones de Iones de Cobre, acompañados por una fracción menor de Cadmio en el agua de descarga. Las trazas de Cobre en los efluentes líquidos de la planta juguera provienen del lavado continuo de las superficies de transferencia de calor y de las líneas de pasteurización.




Figura 5.1.6 Gráfica de Ecotoxicidad Acuática

La evaluación del impacto en la salud de las comunidades rurales y de los trabajadores de la cadena agroindustrial se encuentra estrechamente vinculada a la persistencia ambiental de los flujos elementales metálicos. La categoría de Toxicidad Humana Figura 5.1.7 permitiría trazar las rutas de exposición potencial en la zona.

En la Agricultura, el perfil es gobernado en su totalidad por la emisión de Cadmio II en el agua, lo que confirma que el riesgo epidemiológico y de salud ocupacional en el sector citrícola no proviene de compuestos orgánicos volátiles de vida corta, sino de la persistencia de metales pesados. Al no ser biodegradable, el Cadmio vertido al agua por el lavado de fertilizantes.

Para el Proceso JCOF, la toxicidad humana se distribuye entre emisiones de Cadmio II en suelo agrícola (aproximadamente 70%) e Iones de Zinc II (12%). Esto demuestra que los lodos industriales o subproductos de desecho generados en las plantas de tratamiento de efluentes de las jugueras, al ser dispuestos en suelos o aprovechados de manera inadecuada, arrastran una carga de metales pesados concentrada durante el procesamiento del fruto, transfiriendo el riesgo toxicológico hacia los suelos colindantes a la zona industrial.




Figura 5.1.7 Gráfica de Toxicidad Humana

Finalmente, la categoría de Ocupación de Suelo (Land Occupation), evaluada mediante su estructura jerárquica expuesta en la Figura 5.1.8 demuestra que el impacto espacial de la cadena citrícola de Álamo no se limita a las hectáreas físicas de las huertas de naranja. El software rastrea de forma ramificada cómo la demanda de energía y materiales tracciona la ocupación indirecta de suelo a nivel global.

Las líneas de mayor espesor en la red evidencian que el nodo del mercado eléctrico de media tensión ramifica flujos de alta intensidad hacia los procesos de construcción de infraestructura industrial.

Ubicación:

Radio (km): 20

Fecha fin: 

Ubicación OK:

Texto: Álamo, Veracruz, México

Coordenadas: (20.41853, -97.17882)

Radio: 20 km

Fecha fin: 2025-11-05

Figura 5.2.1 Interfaz del modelo híbrido

Mientras que en la Figura 5.2.2 se muestra la validación de los datos y los cálculos del modelo, así como el intervalo de fechas que está tomando para el cálculo, cabe mencionar que se puso un intervalo semanal para que no fuera tan pesado, pero también existieran suficientes datos, se observa que los valores de la prueba todos son cercanos a uno por lo que se acepta el modelo debido a su cercanía a eso.

Recolectando datos semanales 2022-11-06 -> 2025-11-05 ...

Nulos por columna:

date	0
lat	0
lon	0
LST_C	0
NDVI	0
RAIN_7D	0
RAIN_30D	0
ET	0
month	0
weekofyear	0
label	0
y	0

dtype: int64

Tamaño dataset limpio: (157, 12)

Reporte test:

	precision	recall	f1-score	support
0	1.000	0.923	0.960	13
1	0.972	1.000	0.986	35
accuracy			0.979	48
macro avg	0.986	0.962	0.973	48
weighted avg	0.980	0.979	0.979	48

AUC: 1.0

Figura 5.2.2 Validación

En la Figura 5.2.3 se evidencia los resultados del modelo donde para el mes 5 que es mayo en la semana 17 del año existió una temperatura de 33.7° con un NDVI de 0.61 debido a que es menor a 0.7 se lee la etiqueta de no apto, por lo que se traduciría a que esa parte del cultivo esta estresado o se debería cambiar la fertilización de acuerdo con lo que recomienda el experto, así mismo, se agrega el índice de lluvia que tuvo esa zona en ese mes.

Valores actuales calculados:

{'LST_C': 33.786259043320186, 'NDVI': 0.6175734684387695, 'RAIN_7D': 0, 'RAIN_30D': 6.242605819425974, 'ET': nan, 'month': 5, 'weekofyear': 17}

Predicción semana que termina en 2025-05-02: No apto (score=0.07)

Variables actuales (usadas por el modelo):

	LST_C	NDVI	RAIN_7D	RAIN_30D	ET	month	weekofyear
0	33.786259	0.617573	0	6.242606	0.0	5	17

Figura 5.2.3 Resultados

Con el propósito de validar la robustez predictiva del algoritmo híbrido y demostrar su capacidad de pronóstico la variabilidad temporal y climática regional, se estructuró una matriz de simulación que recopila las series históricas de un punto citrícola en Álamo Temapache, Veracruz (21.050945, -97.664434). Este análisis integra variables de sensores remotos extraídas en un radio de influencia de 5 km, permitiendo correlacionar el Índice de Vegetación de Diferencia Normalizada (NDVI) con la Temperatura de la Superficie Terrestre (LSTC, por sus siglas en inglés) y los regímenes de precipitación acumulada a 7 y 30 días (RAIN 7 y RAIN 30).

A continuación, se presenta en la Tabla 5.2.1 la base de datos multivariable resultado del modelo híbrido.

Tabla 5.2.1 Resultados del Modelo Híbrido ML & SIG

Fecha	LSTC	NDVI	RAIN 7	RAIN 30
15/04/2022	37.17	0.4868	1.102	8.4
15/05/2022	35.66	0.6395	0	35.68
15/06/2022	35	0.678454	30.72	50.8
15/07/2022	32.7	0.650186	17.44	163.36
15/08/2022	34.53	0.697302	10.47	70.36
15/09/2022	30.11	0.705186	6.25	133.72
15/10/2022	29.63	0.63176	0	174.37
15/11/2022	28.18	0.796625	12.7	157.54
15/12/2022	26.1	0.72137	0	91.7
15/01/2023	25.91	0.706888	3.79	13.5
15/02/2023	28.28	0.6815	7.09	7.09
15/03/2023	34.1	0.58136	0	6.23
15/04/2023	29.89	0.541112	1.96	5.35
15/05/2023	32.23	0.689757	61.31	144.12
15/06/2023	36.19	0.593677	0	56.8
15/07/2023	35.36	0.679787	0	33.31
15/08/2023	32.34	0.765618	0	78.2
15/09/2023	34.03	0.716608	0	83.72
15/10/2023	29.60	0.705356	31.97	239.72
15/11/2023	27.06	0.798499	25.3	122.91
15/12/2023	22.71	0.799948	46.4	104.88
15/01/2024	21.64	0.767145	0	14.27
15/02/2024	26.29	0.78115	6.84	25
15/03/2024	30.86	0.738153	0.88	17.11
15/04/2024	33.42	0.567424	1.42	12.93
15/05/2024	37.12	0.555212	0.87	13.76
15/06/2024	38.1	0.480068	1.1	5.81

15/07/2024	29.88	0.774411	179.37	489.55
15/08/2024	29.58	0.764353	36.58	150.16
15/09/2024	28.22	0.671665	63.42	158.19
15/10/2024	29.07	0.797021	0	231.59
15/11/2024	26.41	0.764917	3.87	91.8
15/12/2024	25.27	0.779733	5.09	40.31
15/01/2025	22.56	0.724566	16.33	63.12
15/02/2025	23.17	0.642779	1.15	12.9
15/03/2025	28.58	0.674541	0	37.07
15/04/2025	31.19	0.589712	0	7.52
15/05/2025	37.17	0.510731	5.79	15.81
15/06/2025	33.62	0.226006	37.18	139.26
15/07/2025	27.44	0.763441	66.72	473.89
15/08/2025	28.96	0.797044	9.1	117.72
15/09/2025	28.51	0.763675	106.2	187.39
15/10/2025	27.49	0.812856	418.84	629.01
15/11/2025	26.23	0.795824	0	0
15/12/2025	23.4	0.751383	11.37	77.78
15/01/2026	21.14	0.796362	9.55	41.42
15/02/2026	23.89	0.771205	0	3.36
15/03/2026	25.66	0.576149	3.51	20.99
15/04/2026	27.31	0.756439	26.28	50.95

Los datos anteriormente descritos nos ayudaron a obtener una gráfica del comportamiento del Índice de vegetación en una finca de una zona de Alamo en un rango del 2022-2026 como se observa en Figura 5.2.4, Este comportamiento cinemático valida la integración de datos geoespaciales en el modelo; el algoritmo no realiza una predicción estática y aislada, sino que es capaz de interpretar que los incrementos rezagados en la precipitación mitigan el estrés térmico capturado por la temperatura, permitiendo una mayor fijación de biomasa foliar. Así mismo se puede observar como en los meses entre abril y julio en NDVI es menor lo cual es lógico con la opinión de los expertos, ya que estos meses son de poca producción de naranja, siendo en los últimos meses del año la temporada más alta de la cosecha.




Figura 5.2.4 NDVI en el tiempo

Para concluir con los resultados de este modelo, también se agrega la imagen de temperatura de lado izquierdo y el índice de vegetación de lado derecho como se observa en la Figura 5.2.5 esta imagen corresponde a una zona abarcando un radio de 20 km esto con el fin de demostrar su potencia, sin embargo el valor calculado solo es de la zona que se eligió, entre más verde este es mejor el índice de vegetación y entre más amarillo a negro sea el color de la imagen de la derecha será un manto de agua o zona urbana.




Figura 5.2.5 Mapas de Temperatura y NDVI

5.3 Resultados de Redes Neuronales

En cuanto al modelo de redes neuronales artificiales, el modelo de clustering realizado antes de la creación de la RNA confirmo que las 18 variables del sistema aportaban diferente información y eran independientes todas.

Mientras que, para determinar la configuración óptima de la RNA, se realizó un análisis comparativo de diversas arquitecturas, variando la profundidad y densidad de las capas ocultas. El desempeño de cada configuración se evaluó mediante el Error Cuadrático Medio (MSE) y R^2 , bajo las mismas condiciones de entrenamiento en Python.

Como se observa en la tabla Tabla 5.3.1 la combinación de capas de ocultas de 15 y 30 fueron las que generalizaron de mejor manera los pronósticos y con menor error de precisión. Así mismo, las combinaciones con más capas lejos de mejorar sus errores eran mayores lo que indica un sobreajuste.

Tabla 5.3.1 Resultados de pruebas de arquitectura de RNA

Nº	Capa 1	Capa 2	MSE	R^2
1	50	35	1.8	0.81
2	45	35	2.49	0.74
3	25	15	0.99	0.9
4	20	15	1.58	0.83
5	30	20	1.98	0.79
6	30	15	0.59	0.90
7	35	15	1.62	0.83
8	30	17	3.14	0.67
9	32	15	1.04	0.89
10	20	10	1.29	0.87
11	20	15	1.58	0.83
12	31	15	2.09	0.78
13	40	20	1.36	0.86
14	36	18	1.63	0.83

La validación se dio con las métricas de MSE el cual es muy pequeño 0.59 y el R^2 donde el modelo explica el 90% de las variaciones en el rendimiento citrícola, lo que demuestra una alta capacidad de generalización frente a las condiciones del entorno local tan complejo debido a su incertidumbre natural, así mismo, en la Figura 5.3.1 se observa un diagrama de regresión

lineal la cual confirma que la red no presenta sesgos significativos lo cual demuestra su capacidad para entender el modelo.




Figura 5.3.1 Gráfica de Regresión Lineal

Por otra parte, en la Figura 5.3.2 se presenta un análisis de sensibilidad a partir de la Ecuación de Garson, donde se revela que el índice NDVI y la cantidad de químicos usados como fertilizantes poseen la mayor importancia relativa. Esto corrobora los hallazgos del Análisis de Ciclo de Vida, donde estas variables también presentaron los mayores puntos críticos de impacto y productividad, así como también denotan la relevancia de trabajar sobre este eslabón de la cadena de suministro. Así mismo, se visualiza que la precipitación es relevante, sin embargo, es una variable exógena, por lo que se decide, abordar las variables endógenas como son los fertilizantes.




Figura 5.3.2 Gráfica de Importancia Relativa

En cuanto a la Figura 5.3.3 se observa que se centra en un rango cercano a 0.5 lo que indicaría que subestima el rendimiento real con ese margen, aunque también se visualiza que algunos datos se encuentra en -1, la mayoría se aglomeran cerca al cero sin tendencia en forma de embudo, y aunque no se encuentra en su totalidad a cero, el diagrama se observa similar a una campana de Gauss, sin embargo, en sistemas biológicos complejos como el de Álamo, esta distribución indica que el modelo ha capturado la estructura principal de los datos.




Figura 5.3.3 Diagrama de residuos

También a este modelo se adhirió una interfaz interactiva como se muestra en la Figura 5.3.4 con el objetivo de que pueda pronosticar el rendimiento de naranja por hectárea, por lo que se espera que esta interfaz desarrollada permita realizar ajustes paramétricos en tiempo real, sirviendo como un laboratorio virtual para prever caídas en la producción ante cambios en las variables de entrada, como un cimiento a las brechas de la poca información existente en este apartado de la cadena de suministro.

Temp:	28.083	Precip:	1374.4	RadSolar:	157.4
Sequia:	1	Pendiente:	0.048	Altitud:	30
DrenajeE:	1	DrenajeI:	1	Edad:	25
Textura:	0	pH:	7.1	N:	165
P:	118.125	K:	136.875	Ca:	10
SO4:	0	NDVI:	0.652		
Predict Yield					
Predicted Yield: 5.99					

Figura 5.3.4 Interfaz Interactiva para el Usuario

Para concluir se realizó una prueba de validación cruzada con datos que no se ocuparon en la arquitectura de la RNA para evaluar la capacidad de generalización real de la Red Neuronal Artificial (RNA) frente a escenarios productivos del entorno real, se realizó una validación externa utilizando un conjunto independiente de 17 casos de estudio que se describen en la Tabla 5.3.2, se puede observar que en la última columna se encuentra el rendimiento pronosticado por la interfaz creada en la RNA justo después del rendimiento real, esto con el objetivo de contrastarlo para la confirmación de todo este modelo propuesto.

Tabla 5.3.2 Datos para validación

Nº	T (°C)	P (mm)	RS	ISS	P	A	DE	DI	E	T	pH	N	P
1	25.8	1307.5	145.7	1	0.006	11	2	1	45	1	6.2	241	157.5
2	25.8	1307.5	145.7	1	0.010	14	2	1	20	1	6.3	241	157.5
3	25.8	1307.5	145.7	1	0.003	13	1	2	20	1	7.2	180.75	118.125
4	25.8	1307.5	145.7	1	0.006	10	1	2	25	0	6.6	101.25	100
5	25.8	1307.5	145.7	1	0.008	10	2	1	30	1	7.2	225.75	157.5
6	24.5	1305	145.8	1	0.017	85	2	2	60	2	6.5	353.5	200
7	24.5	1305	145.8	0	0.031	94	1	1	20	2	6.8	180.75	118.125
8	24.5	1305	145.8	1	0.019	85	2	2	25	0	6.8	293.5	200
9	24.5	1305	145.8	1	0.012	79	1	1	30	1	7	180.75	118.125
10	24.5	1305	145.8	1	0.023	77	0	1	30	2	7.1	165	118.125
11	24.5	1305	145.8	1	0.016	86	2	2	45	1	6.2	87.5	21.25
12	24.5	1305	145.8	1	0.010	89	2	1	50	1	7	101.25	100
13	24.5	1305	145.8	1	0.008	0	1	1	50	1	7.1	180.75	150
14	24.5	1305	145.8	1	0.028	93	1	1	15	2	6.2	225.75	157.5
15	24.5	1305	145.8	1	0.035	98	1	1	20	1	7.2	193.875	118.125
16	24.5	1305	145.8	1	0.019	97	0	1	20	1	7	101.25	100
17	24.5	1305	145.8	1	0.011	73	1	1	50	1	7.2	101.25	100

Tabla 5.3.3 Continuación Datos para validación

N°	K	Ca	SO4	NDVI	Rendimiento Real	Rendimiento Pronosticado
1	192.5	0	56	0.743	10	9.59
2	192.5	0	56	0.769	10	9.67
3	144.375	12	48	0.743	8	7.66
4	96.25	0	0	0.769	5	4.87
5	56.25	25	48	0.744	10	8.74
6	225	30	64	0.652	12	12.66
7	144.375	8	48	0.652	8	8.01
8	167.5	105	0	0.665	12	13.36
9	144.375	21	48	0.665	8	8.15
10	136.875	10	0	0.665	7	5.53
11	78.75	5	0	0.665	4	4.21
12	96.25	0	0	0.665	5	5.7
13	144.375	8	48	0.74	8	8.83
14	168.75	25	48	0.74	10	8.94
15	136.875	10	48	0.74	7	8
16	96.25	0	0	0.74	5	3.15
17	96.25	0	0	0.764	5	5.12

Al graficar los rendimientos reales frente a las predicciones del modelo Figura 5.3.5, se trazó una línea de tendencia lineal para cuantificar la paridad del sistema, donde el modelo matemático de la tendencia arrojó un Coeficiente de Determinación R^2 de 0.897. Lo que significa estadísticamente que la RNA es capaz de explicar el 89.7% de la variabilidad del rendimiento en parcelas que el algoritmo jamás había analizado previamente. Lo que reafirma la potencia del modelo, al ser la R^2 de la arquitectura de la RNA similar a la validación cruzada.




Figura 5.3.5 Rendimiento Real vs Pronóstico

5.4 Resultados generales

La integración de estas herramientas robustas permite transitar de un análisis descriptivo a uno predictivo. Donde los resultados generales se agrupan en tres ejes fundamentales:

1. Ambientalmente se modeló la cadena de suministro donde se determinó mediante IMPACT 2002+ que la etapa agrícola es el mayor contribuyente a la huella ambiental, especialmente en salud humana y calidad del ecosistema, debido al uso intensivo de fertilizantes. Este hallazgo valida la necesidad de transitar hacia un manejo de nutrientes más eficiente, confirmando que la sostenibilidad regional no depende del transporte, sino de la optimización técnica de los insumos en el huerto, tal como sugerían los modelos base de (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022)
2. El modelo híbrido en GEE demostró que es posible automatizar el diagnóstico de aptitud del suelo con un 97.9% de exactitud, permitiendo una gestión agrícola basada en datos satelitales y no solo en prácticas empíricas.
3. Se validó una RNA con una arquitectura (30,15) capaz de entender el y explicar el 89.7% de la variabilidad del sistema complejo en escenarios nuevos y reales para el algoritmo.

Así mismo, la integración del índice NDVI de MODIS como variable dinámica de entrada demostró ser un predictor biofísico robusto al combinarse con factores climáticos y operativos, logrando reducir la incertidumbre predictiva identificada en la literatura internacional

Poniendo esto sobre la mesa, se demuestra que el uso de herramientas de Ciencia Abierta (Python/GEE/Activity Browser/Colab) en conjunto permite crear soluciones de agricultura de precisión de bajo costo. Por lo que, esta sinergia despliega una plataforma de soporte a la decisión que pone tecnologías de vanguardia al servicio del sector agrícola regional, fusionando el conocimiento empírico del productor veracruzano con la analítica de datos para transitar hacia una gestión predictiva y sostenible de la cadena de suministro.

5.5. Discusión

Los resultados obtenidos mediante la metodología Impact 2002+ coinciden con lo expuesto por (Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro, 2019) quien sostiene que en este tipo de cadenas de suministro la etapa de la agricultura requiere gran atención debido a la fertilización nitrogenada como principal fuente de emisiones para el cambio climático, mientras que (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022) realiza el primer ACV en los diferentes zonas citrícolas debido a la importancia de esta cadena de suministro teniendo un inventario sólido.

Aunque al analizar el inventario de ACV se observaron algunas discrepancias entre los rendimientos de T/ha en las principales fuentes de literatura como (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022), los mismos registros del gobierno por región (Rural, 2024) y los datos obtenidos para este trabajo visibilizó la productividad real de los citricultores locales en Álamo Temapache oscila en un rango menor, situándose entre las 5 y 14 t/ha.

Esta discrepancia es un hallazgo crítico para la investigación y de ninguna manera invalida el modelo de ACV desarrollado, sino que sienta las bases del proyecto, buscando herramientas que cierren esta brecha y permitan que la herramienta de soporte a la decisión sea

verdaderamente fiel al contexto socioeconómico regional, evitando sesgos de sobreestimación logística y en un futuro alimenten una base de datos para mejora de este ACV.

Por otra parte, estudios en Brasil y Nigeria (Alishah, Motevali, Tabatabaeekoloor, & Hashemi, 2019), (Germer, 2009) enfatizan el gasto energético, los datos obtenidos en Activity Browser subrayan que en Veracruz el punto crítico es la toxicidad y el impacto a la salud derivado de los fertilizantes, superando incluso los impactos del transporte mencionados en estudios de Florida (Dwivedi, Spreen, & Goodrich-Schneider, 2012).

Este contexto nos impulsa a buscar una metodología dinámica debido a que las categorías de "Salud Humana" y "Calidad del Ecosistema" son las más afectadas por la etapa de campo.

Debido a la dificultad de encontrar datos de análisis de suelos, recurrimos a este tipo de herramientas con Google Colab y Gogle Earth tomando un poco de inspiración de (Lebrini, 2020) que propone que estos modelos deben servir para la toma de decisiones en tiempo real, basándonos en (Protim Roy, Abdullah, & Siddique , 2024) que valida que los algoritmos de aprendizaje automático acoplados a variables de teledetección espacial (SIG) son las herramientas idóneas para superar la naturaleza estática e inflexible de los modelos lineales tradicionales, demostrando su capacidad intrínseca para asimilar el ruido y la volatilidad biofísica del sector agrícola no tecnificado.

Por lo que este trabajo materializa una propuesta al demostrar que el modelo de Random Forest (97.9% Accuracy) puede identificar estados de no-aptitud de forma dinámica, cumpliendo con la premisa de Lebrini sobre la necesidad de sistemas que reaccionen a la variabilidad climática actual, así mismo, el éxito de transitar hacia esquemas no lineales para el aforo de cosechas converge con lo documentado por (Quille-Mamani, Ruiz, Carbonell-Rivera , & Ramos-Fernández, 2024), quienes mediante el uso de imágenes satelitales multitemporales y el algoritmo Random Forest demostraron que los modelos de aprendizaje avanzado capturan con alta precisión la estructura biológica del rendimiento, optimizando con semanas de anticipación la planeación logística de la cadena de suministro aguas abajo. . A diferencia de la revisión de (Meisam, Arsalhan, & al, 2020) sobre índices de vegetación, que se limita a describir el estado del arte. Por lo tanto, la integración metodológica de esta tesis no representa un esfuerzo aislado, sino una validación empírica regional alineada firmemente con el estado del arte internacional de la agricultura de precisión

Mientras que autores como (Bamane, 2024) proponen algoritmos complejos para cámaras locales, nuestra integración con la API de Google Earth Engine permite un escalamiento regional sin costo de hardware adicional. El uso de MODIS para calcular el NDVI semanalmente (2022-2025) proporciona una ventaja adaptativa que no se encuentra en los ACV estáticos tradicionales de cítricos, permitiendo una 'política agrícola dinámica' como la sugerida por los estudios de monitorización remota con la cual en un futuro podrían agregarse para un sistema con mayor robustez dada la incertidumbre de este tipo de sistemas.

A diferencia de los métodos tradicionales de zonificación agrícola que son estáticos, el modelo desarrollado en este trabajo ofrece una capacidad diagnóstica adaptativa. Al estar vinculado a la API de GEE, el sistema puede evaluar cualquier coordenada geográfica de forma instantánea, extrayendo datos satelitales actualizados sin intervención manual.

Al comparar este modelo con el de (Ashkan, Nabavi-Pelesaraei; Reza, Abdi; Shahin, Rafiee, 2014), se observa que la inclusión del NDVI y variables edafológicas (pH, Nitrógeno, Fósforo) como entradas incrementó significativamente la robustez del pronóstico. El hecho de que el modelo haya alcanzado un $R^2 = 0.897$ en un conjunto de pruebas independientes de datos de entrada y reales de citricultores de mediana y pequeña producción que conforman la realidad de esta región, lo que confirma su validez y capacidad de generalización de este sistema, superando así, los promedios reportados para modelos de ANFIS en arroz o almendras, reafirmando que la hibridación de datos químicos del suelo con datos satelitales ha resultado eficaz y compacto para predecir rendimientos en la citricultura veracruzana.

Aunque la recopilación de metadatos agrícolas representó un reto metodológico debido a la dispersión de la información en la región, ya que se requieren estudios de suelo para realizar los modelos de absorción de fertilizantes como los realizados por (Bonales-Revuelta, Musule, Navarro-Pineda, & García, 2022) y (Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro, 2019), mientras que el modelo híbrido puede resultar general, ya que al no contar con un modelo de discriminación de cultivos, se puede utilizar en cualquier lugar y cualquier fruto, por lo que se recomendaría realizar un modelo de ML encargado de reconocer los cultivos de naranja.

En conclusión, mientras la literatura internacional suele tratar el ACV, los SIG y la IA como entes aislados, este trabajo logra la convergencia de estas disciplinas. Donde ha pasado de “evaluar el desempeño ambiental” (como en los estudios de Sicilia o Brasil) a tener una

predicción de rendimiento de manera sostenible. Esta transición permite que el citricultor de Álamo no solo conozca el impacto de todas las actividades que realiza, sino que cuente con una herramienta de soporte que correlaciona la salud del árbol (NDVI) con la eficiencia de sus insumos para el éxito de su cosecha. Por lo que la relevancia de este trabajo no radica únicamente en la precisión numérica, sino en que esta sinergia despliega una plataforma de soporte a la decisión que pone tecnologías de vanguardia al servicio del sector agrícola regional, fusionando el conocimiento empírico del productor veracruzano con la analítica de datos para transitar hacia una gestión predictiva y sostenible de la cadena de suministro. Con esto se demuestra que las herramientas de código abierto son viables para democratizar la agricultura de precisión en comunidades en vías de desarrollo, es decir de un ACV descriptivo paso a ser un modelo predictivo funcional.

Conclusiones

Los resultados confirman que la integración de las técnicas de IA con datos geoespaciales y ambientales permiten una gestión de precisión que antes era inaccesible para muchos.

Demostrando que es posible reducir el impacto ambiental sin sacrificar los rendimientos agrícolas, garantizando así la citricultura como pilar económico y de idiosincrasia en la zona.

Buscando un enfoque donde se sienten las bases para una política agrícola basadas en datos reales y entregando la igualdad de los pueblos poniendo al servicio de los agricultores las tecnologías de vanguardia y abiertas al público para su uso y mejora.

Capítulo VI

Conclusiones

Este capítulo constituye la síntesis integradora de este trabajo, donde se contrastan los objetivos planteados al principio con los hallazgos derivados de la implementación de la metodología híbrida. Más allá de la validación técnica, estas líneas reflexionan sobre la trascendencia de los resultados en el contexto de la Naranja famosa de Álamo, evaluando como la unión tecnológica actúa como un catalizador de la sostenibilidad.

6.1. Conclusiones

Para la cuantificación de las cargas ambientales en la producción de naranja en Álamo Temapache, se utilizó el software de código abierto Activity Browser. Se aplicó la metodología de evaluación de impacto IMPACT 2002+, seleccionada por su capacidad de vincular indicadores de punto medio (midpoint) con categorías de daño (endpoint), permitiendo una visión holística del impacto citrícola. Los resultados obtenidos en Activity Browser revelan que la etapa de fertilización es el principal contribuyente al potencial de cambio climático.

Bajo el enfoque con el que abordamos esta cadena de suministro, el sistema desarrollado en esta investigación se clasifica como un ayudante experto, cuyo objetivo es asistir al citricultor veracruzano en la interpretación de los indicadores de sostenibilidad derivados del ACV, por medio del modelo de Inteligencia Georreferenciada donde se observa el índice NDVI en tiempo real, con el objetivo de tomar decisiones en favor de la sostenibilidad.

La integración del modelo de RNA bajo el entorno de Colab permitió validar que el comportamiento del sistema identificados en el ACV se logra predecir y robustecer a partir de las firmas espectrales satelitales. Esto demuestra que es factible transitar de un ACV estático a un modelo de monitoreo dinámico y automatizado para los productores de Veracruz sentando así, las bases operativas para una gestión agrícola guiada e informada por el análisis de datos.

Más allá de la precisión estadística, este trabajo representa una optimización crítica en la cadena de suministro citrícola. Al identificar con exactitud las áreas de mayor aptitud y los puntos de impacto ambiental, se propone una metodología que reduce desperdicios de insumos y mejora la eficiencia logística. Álamo Temapache, al ser el productor de naranja más importante de México, posee una identidad profundamente ligada a este fruto. Por ello, dotar a la región de herramientas de agricultura de precisión de código abierto es también un esfuerzo por fortalecer la economía local y preservar la vocación productiva de su gente, asegurando que el liderazgo nacional del municipio se sustente en una base tecnológica moderna y sostenible.

Por lo que, se concluye que la metodología desarrollada es un modelo altamente escalable y replicable para otras regiones agrícolas y diversos tipos de cultivos frutales en México. Este sistema no solo optimiza la producción, sino que sirve como un pilar para la identidad

colectiva de Álamo, protegiendo su principal motor económico mediante la ciencia. La transición hacia una citricultura inteligente permite que el conocimiento tradicional del campo veracruzano se potencie con la inteligencia artificial, garantizando la resiliencia de la cadena de suministro ante los retos del cambio climático y la demanda global.

6.2. Aportaciones

Se entrega un sistema integral, que involucra una metodología basada en ACV para el diagnóstico ambiental de la cadena de suministro de la producción de jugo de naranja. También, se utilizan herramientas innovadoras y eficaces para abordar este tipo de sistemas con incertidumbre alta y de naturaleza compleja, en miras a una transición hacia la agricultura de precisión de bajo costo, con las técnicas que a continuación se describen:

Modelo híbrido de SIG con IA: Permite la captura y análisis de datos geoespaciales en este caso el NDVI que junto a Random Forest y Series de Tiempo pasan de un número estático a uno dinámico que refleje los cambios del estado fenológico del cultivo lo más apegado a la realidad posible en el tiempo.

RNA procesa la complejidad de las variables climáticas, operativas y satelitales para generar pronósticos de rendimiento confiables en este cultivo y al mismo tiempo se genera una interfaz para el usuario final.

Buscando que esta herramienta proporcione al productor una base analítica para el uso eficiente de los recursos, la cual, en combinación con su conocimiento empírico, permite mitigar el desperdicio económico y fortalecer la resiliencia del pequeño agricultor ante la incertidumbre del sistema. Con ello, se sientan las bases para que, en etapas futuras, el sistema evolucione hacia modelos de prescripción que mejoren específicamente los planes de fertilización y nutrición vegetal, evitando el desperdicio económico y fortaleciendo la resiliencia del pequeño productor.

Por lo que, este trabajo también podría sentar las bases técnicas para el diseño de programas de apoyo alineados con la Agenda 2030 internacionalmente, así como los PRONACES de soberanía alimentaria y Sistemas Socio ecológicos y Sustentabilidad en el país.

6.3. Recomendaciones y líneas de investigación futuras

Partiendo de la literatura revisada y del trabajo llevado a cabo, dejo las siguientes recomendaciones para futuras líneas de estas vertientes de trabajo:

La incorporación de variables de suelo dinámica que integren datos de sensores de humedad, pH, en una parcela empleando técnicas de IA y Big data.

Buscar la escalabilidad del modelo en otros frutos y al mismo tiempo que se pudiera realizar particularmente con tratamiento de imágenes.

También la incorporación de naves no tripuladas que comparen modelos como el realizado para la mejora de indicadores y de prácticas agrícolas, de bajo costo y asequibles para los pequeños agricultores.

Así, como desarrollar aplicaciones sencillas que permitan al usuario monitorear sus parcelas desde algunos dispositivos

Culminando con módulos de Costo-Beneficio en el modelo para cuantificar el ahorro exacto por cada hectárea que sigue las recomendaciones, brindando mayor motivación a los agricultores. En cuanto a los siguientes eslabones de la cadena de suministro se recomienda realizar un diagnóstico de huella hídrica buscando la optimización del uso de agua tanto en la agricultura como en el proceso, debido a que la producción de jugo no conlleva ningún aditamento químico, el proceso requiere mucha agua para cumplir con las buenas prácticas de fabricación, por lo que un proyecto que conlleve una simulación junto con una optimización del agua sería interesante, así mismo debido a que este tipo de jugo suele ser materia prima en otros procesos para jugos, refrescos y otros, también podría agregarse ese eslabón junto con todos los proveedores de botellas, incluso comparando los empaques para una mejora ambiental.

Cabe resaltar que implementar este tipo de tópicos resultan bastante complejos debido a las barreras de la recolección y confidencialidad de los datos, sin embargo, abre un campo de investigación extenso y apasionante. El desarrollo de estas temáticas es clave para consolidar la competitividad y la resiliencia climática de la industria citrícola de esta región de Veracruz.

Referencias

- Banda Gamboa, H. A. (2014). *Inteligencia Artificial: Principios y Aplicaciones*. Quito. Recuperado el 27 de 05 de 2024, de https://www.researchgate.net/publication/262487459_Inteligencia_Artificial_Principios_y_Aplicaciones
- Bonales-Revuelta, J., Musule, R., Navarro-Pineda, F. S., & García, C. A. (20 de 03 de 2022). Evaluating the environmental performance of orange production in Veracruz, Mexico: A life cycle assessment approach. *Journal of Cleaner Production*. doi:<https://doi.org/10.1016/j.jclepro.2022.131002>
- Lasse, R. P. (2018). *Inteligencia Artificial* (1° ed.). España, España: Planeta S.A. Recuperado el 22 de 05 de 2024
- Protim Roy, P., Abdullah, M., & Siddique, I. (2024). Machine learning empowered geographic information systems: Advancing Spatial analysis and decision making. *World Journal of Advanced Research and Reviews*, 1387–1397.
- Acevedo, E., Serna, A., & Serna, E. (2017). Principios y características de las redes neuronales artificiales. *Desarrollo e innovación en ingeniería*, 173.
- Ahlawat, S. (2025). Bosque aleatorio. En: Métodos cuantitativos estadísticos en finanzas. *Apress, Berkeley*. doi:https://doi.org/10.1007/979-8-8688-0962-0_8
- Alishah, A., Motevali, A., Tabatabaeekoloor, R., & Hashemi, S. J. (01 de 11 de 2019). Multiyear life energy and life cycle assessment of orange production in Iran. *Environmental Science and Pollution Research*, 26, 32432–32445. doi:[10.1007/s11356-019-06344-y](https://doi.org/10.1007/s11356-019-06344-y)
- Alzubi, E. K. (2024). Enhancing economic-social sustainability through a closed-loop citrus supply chain: A life cycle cost analysis. *Resources, Conservation & Recycling Advances*, 21, 200199. doi:<https://doi.org/10.1016/j.rcradv.2023.200199>
- Ambientales, W. F. (2015). *Manual para la evaluación de la huella hídrica*. Recuperado el 06 de Junio de 2024, de <https://agua.org.mx/biblioteca/manual-para-la-evaluacion-de-la-huella-hidrica/>
- Antunez-Irgoin, C. H. (2011). Análisis de Series de tiempo. *Contribuciones a la Economía*, 47.
- AnyLogic. (2023). *The Art of Process-Centric Modeling*. AnyLogyc. Recuperado el 25 de 05 de 2024
- AnyLogic, & Grilgoryeb, I. (2015). *Anylogyc em tres dias* (2° ed.). AnyLogic. Recuperado el 27 de 05 de 2024
- Aranda, A., Zabalza, I., & Martínez, A. (2006). *El análisis del ciclo de vida como herramienta de gestión empresarial*. Madrid: FC editorial. Recuperado el 27 de febrero de 2024, de <https://books.google.com.mx/books?hl=es&lr=&id=QHUCoDKAaQsC&oi=fnd&pg=PA27&dq=analisis+de+ciclo+de+vida&ots=2AGl2OojHG&sig=8UCB1EsD13yBHKv4dCDFpjQO5T4#v=onepage&q=analisis%20de%20ciclo%20de%20vida&f=false>

- Arjen Y. Hoekstra, A. K. (2011). *The water footprint assessment manual : setting the global standard* (1° ed.). Washington: Earthscan Ltd. Recuperado el 04 de Mayo de 2024, de https://agua.org.mx/wp-content/uploads/2011/06/6-the_water_footprint_assessment_manual.pdf
- Ashkan, N.-P., Shahin, R., Seyed, S. M., Homa, H., & Kwok-wing, C. (2018). Comprehensive model of energy, environmental impacts and economic in rice milling factories by coupling adaptive neuro-fuzzy inference systems and life cycle assesment. *Journal of Cleaner Production*. doi:10.1016/j.jclepro.2019.01.228
- Ashkan, Nabavi-Pelesaraei; Reza, Abdi; Shahin, Rafiee. (2014). Neural network modeling of energy use and greenhouse gas emissions of watermelon production systems. *Journal of the Saudi Society of Agricultural Sciences*, 38-47. doi:<https://doi.org/10.1016/j.jssas.2014.05.001>
- Badaro, S., Ibañez, L., & Agüero, M. (2013). SISTEMAS EXPERTOS: Fundamentos, Metodologías y Aplicaciones. Ciencia y Tecnología. *Ciencia y Tecnología*, 13, 349-363. doi:10.18682/cyt.v1i13.122
- Bamane, K. K. (2024). Mejora en un sistema de cámaras multiespectrales para agricultura de precisión utilizando el algoritmo de cálculo NDVI. *Fronteras en la Informática Sanitaria*, 13. Obtenido de https://openurl.ebsco.com/EPDB%3Agcd%3A13%3A25686285/detailv2?sid=ebsco%3Aplink%3Ascholar&id=ebsco%3Agcd%3A184837791&crl=c&link_origin=scholar.google.com
- Behzad, E., Asadollah, A., & Majid, K. (2016). Optimization of energy consumption and environmental impacts of chickpea production using data envelopment analysis (DEA) and multiobjective genetic algorithm (MOGA) approaches. *INFORMATION PROCESSING IN AGRICULTURE*, 3, 190-205. doi:<http://dx.doi.org/10.1016/j.inpa.2016.07.002>
- Big, A. (2024). *Atlas Big*. Recuperado el 05 de Junio de 2024, de Atlas Big: <https://www.atlasbig.com/es-es/paises-por-produccion-de-naranja>
- Cabot, M. I., Lado, J., & Sanjuán, N. (2025). Peeling the orange: Delving into life cycle indicators for water footprint, ecosystem services, and biodiversity for orange cultivation in Uruguay. *Sustainable Production and Consumption*, 261-273.
- Cantón Sánchez, E. A., Inga Campoverde, J. A., Macías Hernández, D. J., & Martínez Carriel, T. (2022). Los sistemas de información geográfica aplicados a la agricultura de precisión. *Revista Científica Arbitrada Multidisciplinaria PENTACIENCIAS*, 62-76.
- Centro de Análisis de Ciclo de Vida y Diseño Sustentable CADIS, Embajada de Suiza en Colombia, Agencia Suiza para la. (2016). *Huella de Agua (ISO 14046) en América Latina, análisis y recomendaciones para una coherencia regional*. Suiza: COSUDE. Recuperado el 25 de Abril de 2024

- COSUDE. (2016). *Manual de Aplicación para la Evaluación de la Huella Hídrica acorde a la Norma ISO 14046* (1 ed.). Chile: Fundación Chile. Recuperado el 06 de Junio de 2024, de <https://sirse.info/wp-content/uploads/2016/04/Manual-aplicaci%C3%B3n-ISO14046.pdf>
- Delgado-Ramirez, G., & Bolaños-Gonzalez, M. (2025). Clasificación Supervisada para el Mapeo del Maíz Forrajero Mediante Teledetección en la Región Lagunera, México. *Tierra Latinoamericana*, 1-15.
- Diario del Istmo. (02 de 05 de 2022). Veracruz, líder en producción de naranja en México. *Imagen de Veracruz*. Recuperado el 12 de 05 de 2024, de <https://imagendeveracruz.mx/estado/veracruz-lider-en-produccion-de-naranja-en-mexico/50180607>
- Dwivedi, P., Spreen, T., & Goodrich-Schneider, R. (2012). Global warming impact of Florida's Not-From-Concentrate (NFC) orange juice. *Agricultural Systems*, 108, 104-111. doi:<https://doi.org/10.1016/j.agsy.2012.01.006>.
- EEAOC. (2014). El Análisis de Ciclo de vida: de la cuna a la tumba. *DOSSIER Avance Agroindustrial*, 34(4), 8.
- Fabián Enríquez, V. V. (01 de 07 de 2023). Veracruz: Problemática de la producción de cítricos. *Editorial Agrícola Tuxpan*, 165-160. doi:www.doi.org/10.47808/revistabioagro.v11i1.471
- FAO. (2012). *FAO*. Recuperado el 15 de Marzo de 2024, de FAO: <https://www.fao.org/assets/infographics/FAO-Infographic-Virtual-Water-es.pdf>
- FAO. (2018). Transformar la alimentación y la agricultura. En FAO, *Transformar la alimentación y la agricultura* (pág. 76). Roma: FAO.
- FAO. (2022). *The State of the World's Land and Water Resources for Food and Agriculture – Systems at breaking point*. Roma: FAO. doi:<https://doi.org/10.4060/cb9910en>
- FAO. (10 de Abril de 2024). *FAO*. Obtenido de FAO: <https://www.fao.org/land-water/water/en>
- Flórez-Delgado, D. F., & Fernández-García, D. K. (2017). The geographical information systems. A review. *FAGROPEC*, 9(1), 11-16.
- Galaz, Yamazaki, Ruiz Urquiza. (2012). El análisis del impacto empresarial en el medio ambiente como una oportunidad de mejora. *Deloitte*, 6. Recuperado el 28 de 05 de 2024, de [https://www2.deloitte.com/content/dam/Deloitte/mx/Documents/risk/Sustentabilidad/mx\(es-mx\)Boletin_Sustentabilidad_Nov12.pdf](https://www2.deloitte.com/content/dam/Deloitte/mx/Documents/risk/Sustentabilidad/mx(es-mx)Boletin_Sustentabilidad_Nov12.pdf)
- Germer, L. C. (04 de 06 de 2009). Assessing the environmental profile of orange production in Brazil. *Int J Life Cycle Assess*(14), 656-664. doi:DOI 10.1007/s11367-009-0097-1

- González Segnana, L. R., & Tullo Arguello, C. C. (2019). *Guía Técnica, Cultivo de Cítricos*. (L. R. González Segnana, Ed.) San Lorenzo, Paraguay: Universidad Nacional de Asunción. Recuperado el 27 de 05 de 2024
- González-García, C. (2018). En qué consiste el aprendizaje automático (machine learning) y qué está aportando a la Neurociencia Cognitiva. *Ciencia Cognitiva*, 12(2), 48-50. Recuperado el 04 de Junio de 2024
- Google LLC. (2005). *Google Earth Engine*. Obtenido de Google Earth Engine: <https://earthengine.google.com/>
- Google LLC. (2018). *Google Colab*. Obtenido de Google Colaboratory: <https://colab.research.google.com/>
- Guevara, A. (2017). Esquema Metodológico para el Diseño e Implementación de un Sistema de Información Geográfico. *V Coloquio de Geografía Cuantitativa*, (pág. 10). doi:10.26754/ojs_geoph/geoph.1992291832
- Hinestroza Ramírez, D. (2018). *EL MACHINE LEARNING A TRAVÉS DE LOS TIEMPOS, Y LOS APORTES A LA HUMANIDAD*. Pereira: UNIVERSIDAD LIBRE SECCIONAL PEREIRA. Recuperado el 07 de Junio de 2024, de <https://repository.unilibre.edu.co/bitstream/handle/10901/17289/EL%20MACHINE%20LEARNING.pdf?sequence=1>
- IPCC. (2006). *PCC Guidelines for National Greenhouse Gas Inventories*. Japan: IGES.
- Jolliet, O. M. (2003). IMPACT 2002+: Una nueva metodología de evaluación del impacto del ciclo de vida. *Int J LCA*, 324-330.
- Kaita, M. S., & Harun, S. N. (2023). Application of integrated LCA-GIS model in the agricultural sector: A brief overview. *IOP Conf. Series: Earth and Environmental Science*, 1-9.
- Koljonen, H. (2023). *Comparing apples to oranges – Evaluating the impacts of conventional and organic products on biodiversity using different LCIA methods*. Lappeenranta–Lahti University of Technology LUT. Finlandia: Lappeenranta–Lahti University of Technology LUT. Recuperado el 25 de 03 de 2024
- Lebrini, Y. B. (2020). Monitorización remota de sistemas agrícolas utilizando series temporales NDVI y métodos de aprendizaje automático: una herramienta para una política agrícola adaptativa. *Arabian Journal of Geosciences*, 13-16. Obtenido de <https://link.springer.com/article/10.1007/s12517-020-05789-7>
- Leiva, E. (2016). *EOI*. Recuperado el 27 de 04 de 2024, de EOI: https://www.eoi.es/sites/default/files/savia/documents/teoria_acv_migma1.pdf
- Leonard, J. e. (2020). Digital agriculture: A review of information systems. *Informatica y Electronica en Agricultura*. doi:<https://doi.org/10.1016/j.compag.2020.105543>
- Lourdes Gutierrez, V. (2016). *Huella Hídrica de Cítricos. Impacto sobre la disponibilidad de agua en la etapa de producción primaria de naranjas (Citrus sinensis) en la provincia*

de Entre Ríos, Argentina. Lujan de Cuyo: Facultad de Ciencias Agrarias. Recuperado el 28 de 05 de 2024

- Loures, L. C. (2020). Evaluación de la eficacia de los sistemas de gestión de la agricultura de precisión en pequeñas explotaciones agrícolas mediterráneas. *Sostenibilidad*. doi:<https://doi.org/10.3390/su12093765>
- Maier, M., Mueller, M., & Yan, X. (2017). Introducing a localised spatio-temporal LCI method with wheat production as exploratory case study. *Journal of Cleaner Production*, 492-501.
- Martín Del Brío, B., & Serrano Cinca, C. (1995). Fundamentos de redes neuronales artificiales: hardware y software. doi:<https://doi.org/10.54886/scire.v1i1.1036>
- Martindale, W., Saeidan, A., Tahernezhad-Javazm, F., & Jagtap, S. (2024). Mapping the path to decarbonised agri-food products: a hybrid geographic information system and life cycle inventory methodology for assessing sustainable agriculture. *International Journal of Food Science and Technology*, 6078-6086.
- Meisam, A., Arsalhan, G., & al, e. (2020). Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. *IEEE JOURNAL OF SELECTED TOPICS IN APPLIED EARTH OBSERVATIONS AND REMOTE SENSING*, G,.
- Meza-Palacios, Ramiro; Aguilar-Lasserre, Alberto A; Morales-Mendoza, Luis F; Pérez-Gallardo, Jorge R; Rico-Contreras, José O; , Alejandro. (2019). Life cycle assessment of cane sugar production: The environmental contribution to human health, climate change, ecosystem quality and resources in México. *Toxic/Hazardous Substances and Environmental Engineering*. doi:<https://doi.org/10.1080/10934529.2019.1579537>
- Miranda Ackerman, M. A. (2015). *OPTIMISATION MULTI-OBJECTIF POUR LA GESTION ET LA CONCEPTION D'UNE CHAÎNE LOGISTIQUE VERTE: APPLICATION AU CAS DE LA FILIÈRE AGROALIMENTAIRE DU JUS D'ORANGE*. Francia: Institut National Polytechnique de Toulouse (INP Toulouse). Recuperado el 2024
- Mordor Intelligence. (2024). *Mordor Intelligence*. Recuperado el 05 de Mayo de 2024, de Mordor Intelligence: <https://www.mordorintelligence.com/es/industry-reports/fruit-and-vegetable-juice-market-industry>
- Mordor Intelligence Research & Advisory. (2024). *Análisis de participación y tamaño del mercado de naranja tendencias y pronósticos de crecimiento (2024-2029)*. Recuperado el 5 de Junio de 2024, de Mordor Intelligence: <https://www.mordorintelligence.com/es/industry-reports/orange-market>
- Moreno-Sarmiento, E. (2008). Predicción con series de tiempo y regresión. *PANORAMA*, 36-58.
- Munera, L. E. (1990). *Inteligencia Artificial y Sistemas Expertos*. Facultad de Informática. España: ICESI. Recuperado el 04 de Junio de 2024, de

https://repository.icesi.edu.co/biblioteca_digital/bitstream/10906/4006/6/munera_Inteligencia_artificial_2010.pdf

- Nabor-Lagunes, A., Ochoa-Zezzatti, A., & Sandoval, L. (2023). Optimization of Water Use in the Washing Process of Industrial Orange Juice Extractors for a Circular Economy. *Benchmarks and Hybrid Algorithms in Optimization and*, 165-190. doi:https://doi.org/10.1007/978-981-99-3970-1_10
- Navarro Martínez, P. (2019). *Estimación de la Huella Hídrica en la Industrialización de Naranjas*. Universitat Politècnica de València, Escuela Técnica Superior de Ingeniería Agronómica y del Medio Natural. Valencia: Universitat Politècnica de València. Recuperado el 25 de 05 de 2024
- Nicolo, B. F. (Junio de 2017). Environmental and Economic Sustainability Assessment of Navel Oranges from the Cultivation to the Packinghouse According to Environmental Product Declarations System. *Calitatea*, 18(158), 108-112. Recuperado el 25 de 03 de 2024, de https://d1wqtxts1xzle7.cloudfront.net/53433328/Q-as_Vol.18_No.158_June-2017_p.108-112-libre.pdf?1496927433=&response-content-disposition=inline%3B+filename%3DFOOD_SAFETY_MANAGEMENT.pdf&Expires=1717376563&Signature=EdWMkwG4PT8sG~dB~hAl-CUi7RtxcDFWH71C-ZJnK
- Oble Vergara, E. (2016). *Innovación, capital social y rentabilidad de la Naranja en el Norte de Veracruz, México*. Universidad de Chapingo. Chapingo: Universidad de Chapingo. Recuperado el 29 de 05 de 2024
- Oble Vergara, Evelia; González Aguirre, Rosa Luz;. (Abril-Junio de 2021). Desafíos para la adopción de la agricultura 4.0 en el sector citrícola: caso de productores de naranja del estado de Veracruz, México. (G. Dutrénit Bielous, Ed.) *DEBATES SOBRE INNOVACIÓN.*, 6(2), 120-122. Recuperado el 29 de 05 de 2024, de <http://economiaeininnovacionuamx.org/secciones/debates-sobre-innovacion>
- Ogunlade, C. A. (Junio de 2020). Energy life-cycle assessment and economic analysis of sweet orange production in Nigeria. *AgricEngInt: CIGR Journal*, 22(2), 123-132. Recuperado el 21 de 03 de 2024, de https://www.researchgate.net/profile/Ogunlade-Clement-2/publication/342452508_Energy_life-cycle_assessment_and_economic_analysis_of_sweet_orange_production_in_Nigeria/links/5ef4f22ea6fdcc4ca430f67f/Energy-life-cycle-assessment-and-economic-analysis-of-sw
- Ortiz-Domínguez, M. (2025). Redes neuronales artificiales. *Ingenio y Conciencia Boletín Científico de la Escuela Superior Ciudad Sahagún*, 38-44.
- Parmar, A., Katariya, R., & Patel, V. (2019). Una reseña sobre Random Forest: Un clasificador de conjunto. *Conferencia Internacional sobre Tecnologías Inteligentes de Comunicación de Datos e Internet de las Cosas (ICICI) 2018*. Springer Charm. doi:https://doi.org/10.1007/978-3-030-03146-6_86

- Pérez Arcos , S. I. (2012). *Evaluación y análisis de la huella hídrica y agua virtual de la producción agrícola en el Ecuador*. 2012: Dpto. de Admón de Agronegocios. Recuperado el 04 de Junio de 2024
- Pérez González, Á. (2015). *Cálculo de la huella hídrica total en el cultivo de los cítricos de la Comunidad Autónoma Valenciana*. España: Universidad Carlos III de Madrid. Recuperado el 03 de Junio de 2024
- Pérez-Guerra, G. A., Sosa-Franco, I., Machado-García, N., & Ruíz-Pérez, M. E. (2022). GIS, characteristics, relationship with spatial databases . *Revista Ciencia Universitaria*.
- Pergola, M., D'Amico, M., Celano, G., Palese, A. M., Scuderi, A., Di Vita, G., . . . Inglese, P. (2013). Sustainability evaluation of Sicily's lemon and orange production: An energy, economic and environmental analysis. *Journal of Environmental Management*, 674-684. doi:<https://doi.org/10.1016/j.jenvman.2013.06.007>
- Ponce, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería* (1 ed.). México: Alfaomega Grupo Editor, S.A. de C.V. Recuperado el 05 de Junio de 2024
- Procuraduría Federal del Consumidor. (Diciembre de 29 de 2023). *Gobierno de México*. Recuperado el 05 de Junio de 2024, de Gobierno de México: <https://www.gob.mx/profeco/documentos/naranja-mas-que-un-jugo?state=published>
- PROFECO. (29 de 12 de 2023). *Gobierno Mexicano*. Obtenido de Gobierno Mexicano: <https://www.gob.mx/profeco/documentos/naranja-mas-que-un-jugo?state=published>
- Quille-Mamani, J., Ruiz, L., Carbonell-Rivera , J., & Ramos-Fernández, L. (2024). Predicción del rendimiento del cultivo de arroz mediante imágenes Sentinel-2 y el algoritmo Random Forest. *Teledetección y Cambio Global: Retos y Oportunidades para un Crecimiento Azul*, 365-368.
- Radočaj, D. Š. (2023). Estado de los principales índices de vegetación en estudios de agricultura de precisión indexados en Web of Science: A Review. *Agricultura*. *Agricultura*, 13. doi:<https://doi.org/10.3390/agriculture13030707>
- Renaud-Gentié, C., Teunis Johannes, D., Anders, B., & Morten, B. (2014). Modeling pesticides emissions for Grapevine LCA: adaptation of Pest-LCI model to viticulture. *Proceedings of the 9th International Conference on Life Cycle Assessment in the Agri-Food Sector*, 1075-1085.
- Ríos, G., & Hurtado, C. (2008). Series de Tiempo. *Tópicos en Minería de Datos* (pág. 52). Chile: Facultad de Ciencias Físicas y Matemáticas, Universidad de Chile.
- Rivera-Lopéz, S., Perales-Salvador, A., Del Valle-Sánchez, M., & Caamal-Cauich, I. (2020). Panorama of the production and commercialization of orange in Mexico. *Agro-Productividad*, 9-14.

- Rural, S. d. (Marzo de 18 de 2024). *Gobierno de México Secretaría de Agricultura y Desarrollo Rural*. Recuperado el 11 de Abril de 2024, de Gobierno de Mexico Secretaría de Agricultura y Desarrollo Rural: <https://www.gob.mx/agricultura/articulos/detras-de-la-naranja?idiom=es>
- Sabogal Ángel, J. S. (2015). *Evaluación de la huella hídrica para el cultivo de naranja (valencia) en un predio del municipio de puerto López – Meta*. Colombia: Universidad de la Salle. Recuperado el 03 de Junio de 2024, de <https://ciencia.lasalle.edu.co/>
- Saenz-Saavedra, N. (2012). Los Sistemas de Información Geográfica SIG una herramienta poderosa para la toma de decisiones. *Ingeniería Civil*, 31-41.
- Salimi Beni, M., Gholami Parashkoochi, M., Beheshti, B., Ghahderijani, M., & Bakhoda, H. (2023). Application of machine learning to predict of energy use efficiency and damage assessment of almond and walnut production. *Environmental and Sustainability Indicators*. doi:<https://doi.org/10.1016/j.indic.2023.100298>
- Salma, H., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning* , 69-79.
- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Resumen del algoritmo de bosque aleatorio. *Babylonian Journal of Machine Learning*, 67-19. doi: <https://doi.org/10.58496/BJML/2024/007>
- Sandria-Reynoso, J. (07 de 10 de 2000). Computación Evolutiva en Optimización de Proceso. *Book*, 8. Recuperado el 05 de Junio de 2024, de https://www.researchgate.net/publication/310771371_Computacion_Evolutiva_en_Optimizacion_de_Procesos
- Sanes Arrego, A. (2012). *El Análisis del Ciclo de Vida en el desarrollo sostenible*. Bogotá: Universidad Nacional de Colombia. Recuperado el 28 de 05 de 2024, de <https://repositorio.unal.edu.co/bitstream/handle/unal/11450/905079.2012.pdf?sequence=1>
- Sarmiento Vásquez, A., & López Sandoval, E. (Enero-Diciembre de 2017). Una comparación cualitativa de la dinámica de sistemas, la simulación de eventos discretos y la simulación basada en agentes. *Ingeniería Industrial*, 27-52. Recuperado el 28 de 05 de 2024, de <https://www.redalyc.org/articulo.oa?id=337453922002>
- Secretaría de Agricultura y Desarrollo Rural. (04 de Septiembre de 2021). *Gobierno de México*. Obtenido de Gobierno de México: <https://www.gob.mx/agricultura/prensa/aumentan-28-3-por-ciento-exportaciones-mexicanas-de-citricos-y-sus-derivados-entre-enero-y-julio-de-2021?idiom=es#:~:text=Por%20ejemplo%2C%20las%20exportaciones%20de%20jugo%20de%20naranja,pasado%20sumaron%20204.8%20mi>
- Seguí Amórtégui, L. A., García Vega, D., & Guerrero García Rojas, H. R. (Diciembre de 2016). Huella hídrica: análisis como instrumento estratégico de gestión para el

aprovechamiento eficiente de los recursos hídricos. *Ciencia Nicolaita*(69), 76-101.
Recuperado el 28 de 05 de 2024

SimaPro. (2011). *SimaPro*. Recuperado el 2 de Mayo de 2024, de SimaPro:
<https://www.simapro.mx/index.html>

Sonnemann, G., Castells, F., & Schuhmacher, M. (2004). *Integrated life-cycle and risk assessment for industrial processes*. Ohio, USA: CRC Press LLC . Recuperado el 07 de 05 de 2024

Steubing, B., De Koning, D., Haas, A., & Mutel, C. (2020). TheActivity Browser— An open source LCA software building on top of the brightway framework. *Software Impacts*, 100012.

Suarez García, G. (2011). *EXTRACCION DE NUTRIENTES POR COSECHA DEL CULTIVO DE NARANJA (Citrus sinensis) VARIEDAD VALENCIA EN CONDICIONES DEL VALLE DEL CAUCA*. Universidad Nacional de Colombia, Ciencias Agropecuarias. Palmira: Universidad Nacional de Colombia. Recuperado el 30 de 05 de 2024

Tamiminia, H. S. (2020). Google Earth Engine para aplicaciones de geo-big data: un metaanálisis y revisión sistemática. *Revista ISPRS de fotogrametría y teledetección*, 152-170. doi:<https://doi.org/10.1016/j.isprsjprs.2020.04.001>

Thaheer, H., Ikatinasari, Z., & Hasibuan, S. (2019). Environmental Burden Optimization in Distribution Pathways for Fruit Juice Product of Small Medium Enterprises Industry. *International Journal of Engineering and Technology*, 8, 42-47. doi:10.35940/ijrte.B1010.0782S719

Torres , G., & Tablada, J. (2009). Redes Neuronales Artificiales. *Revista de Educación Matemática (RevEM)*.

Unión Europea, Instituto Interamericano. (2017). Guía metodológica para la evaluación de la huella hídrica en una. *IICA*, 80. Recuperado el 30 de 05 de 2024, de <http://www.euroclima.iica.int>

Vázquez del Mercado, R., & Lambarri, J. (2017). Huella hídrica en México: análisis y perspectivas. En R. Vázquez del Mercado, & J. Lambarri, *Huella hídrica en México: análisis y perspectivas* (pág. 255). Jiutepec, Morelos, México: Instituto Mexicano de Tecnología del Agua. Recuperado el 04 de 05 de 2024, de <http://repositorio.imta.mx/handle/20.500.12013/1714>

Venkatesh, P., Vadivel, A., Amin, N., Bappa, D., & Sami, G. (2018). Optimization of energy consumption and environmental impacts of arecanut production through coupled data envelopment analysis and life cycle assessment. *Journal of Cleaner Production*. doi:<https://doi.org/10.1016/j.jclepro.2018.08.263>

Verdún, J. C. (1987). *Metodología para el desarrollo de sistemas expertos*. Recuperado el 05 de Junio de 2024, de

https://www.researchgate.net/publication/39425509_Metodologia_para_el_desarrollo_de_sistemas_expertos

- Vidal, G., Neumann, P., & y Hospido, A. (2022). *ANÁLISIS DE CICLO DE VIDA* (1 ed.). Concepción: Universidad de Concepción. Recuperado el 06 de Junio de 2024, de https://www.researchgate.net/profile/Beatriz-Rivela/publication/362407032_Perspectivas_y_reflexiones/links/62e872ca3c0ea8788775ab32/Perspectivas-y-reflexiones.pdf#page=13
- Viñas-Quintero, Y., Pérez-Herrera, E., Hernández-Macías, M. R., González-Dyer, L., & Lugo-Ruiz, I. (2024). Resultados de la implementación y funcionamiento del servicio de Ordenamiento Territorial en agricultura cañera. *Ingeniería Agrícola*, 1-8.
- Yan, M. C. (01 de 03 de 2016). Farm and product carbon footprints of China's fruit production—life cycle inventory of representative orchards of five major fruits. *Environmental Science and Pollution Research*, 23(5), 4681-4691. doi:10.1007/s11356-015-5670-5
- Zenil Chávez, H. (Abril-Junio de 2005). Computación evolutiva y sistemas complejos adaptativos. *Ciencia*, 70-80. Recuperado el 05 de Junio de 2024

Anexos

Anexo 1. Nomenclatura del Inventario de Ciclo de Vida ICV

Esta sección recopila la nomenclatura técnica, fórmulas químicas e identidades operativas de las variables e insumos incluidos en el ICV

Insumos Agrícolas e Industriales del Sistema

- Urea $CO(NH_2)_2$ (N): Fertilizante nitrogenado sintético de alta concentración. Fuente primaria de nitrógeno reactivo.
- Fertilizante Triple 17 — (17-17-17) (P_2O_5, N, K_2O): Complejo NPK balanceado utilizado para el aporte simultáneo de nitrógeno macronutriente, fósforo (evaluado como pentóxido de di fósforo) y potasio.
- Azufre (S): Elemento químico esencial utilizado como macronutriente secundario y corrector de pH edáfico.
- Calcio (Ca): Elemento utilizado para la enmienda de suelos y estabilidad de las paredes celulares en el fruto.
- Nitrógeno (N) / Fósforo (P) / Potasio (K): Tríada de macronutrientes primarios que rigen la etapa fenológica de crecimiento y desarrollo citrícola.
- Sulfato (SO_4^{2-}): Anión químico presente en fertilizantes, clave para la asimilación del azufre por la raíz.
- Diésel de Tractor / Diésel de Transporte: Carburante fósil compuesto por hidrocarburos de rango ($C_{10} - C_{15}$), evaluado para cuantificar el impacto del transporte a la fábrica y los trabajos mecánicos de labranza (tierra).
- Hidróxido de Sodio (NaOH): Álcali fuerte utilizado en los procesos de limpieza, desinfección y ajuste de pH en la planta de producción de jugo.
- Metasilicato de Sodio (Na_2SiO_3): Compuesto inorgánico utilizado como agente de limpieza industrial y protector contra la corrosión de equipos.

- Ácido Acético (CH_3COOH): Ácido orgánico débil utilizado en la formulación de soluciones sanitizantes en la industria agroalimentaria.
- Peróxido de Hidrógeno (H_2O_2): Agente oxidante de alta eficiencia empleado para los protocolos de Buenas Prácticas de Fabricación (BPF) y desinfección de agua de proceso.
- Carbonato de Sodio (Na_2CO_3) / Silicato de Sodio (Na_2SiO_3) / Sulfato de Sodio (Na_2SO_4): Sales inorgánicas e ingredientes auxiliares en detergentes industriales para el lavado de la fruta.
- Gas Natural: Combustible fósil gaseoso (predominantemente metano, CH_4) utilizado en el sistema para la generación de energía térmica en la planta industrial.
- Hipoclorito de Sodio ($NaClO$): Compuesto clorado utilizado para la cloración y desinfección microbiológica del agua de lavado de fruta.

Emisiones al Aire, Agua y Suelo Incorporadas al Inventario

- Monóxido de Di nitrógeno (N_2O) al aire: Gas de efecto invernadero (GEI) de alto impacto derivado de la desnitrificación microbiana de los fertilizantes nitrogenados.
- Óxidos de Nitrógeno (NO_x) al aire: Gases reactivos (NO y NO_2) precursores de la formación de ozono troposférico y de la acidificación atmosférica.
- Amoníaco (NH_3) al aire: Emisión gaseosa alcalina originada principalmente por la volatilización de la urea en suelos agrícolas.
- Nitrato (NO_3^-) al agua: Anión lixiviado hacia los cuerpos de agua dulce, principal responsable de la eutrofización acuática.
- Fósforo (P) al agua: Nutriente limitante emitido por escorrentía superficial, detonante de procesos de eutrofización en ecosistemas lénticos.
- Metales Pesados en Compartimentos Ambientales: Como Cadmio (Cd), Zinc (Zn), Plomo (Pb), Níquel (Ni), Cobre (Cu), Cromo (Cr), Mercurio (Hg). Los cuales terminan emitidos al agua, suelo agrícola o retenidos en suelo derivado del uso continuo de fertilizantes fosfatados y enmiendas minerales que contienen trazas de estos elementos.

- Dióxido de Carbono (CO_2) al aire: Emisión gaseosa fundamental procedente de la combustión de combustibles fósiles (diésel, gas natural) en los eslabones de transporte y en la planta de producción.
- Dióxido de Azufre (SO_2) al aire: Gas precursor de la lluvia ácida generado por la combustión de combustibles con trazas de azufre.
- Monóxido de Carbono (CO) al aire: Gas producto de la combustión incompleta en motores de combustión interna durante las fases logísticas.

ANEXO 2: Glosario de Conceptos Técnicos

De acuerdo con el modelo metodológico IMPACT 2002+, los impactos ambientales se estructuran bajo un enfoque secuencial que traduce las emisiones del inventario en categorías intermedias (midpoints) y, posteriormente, las agrupa en categorías de daño finales (endpoints).

Categoría de Daño (Endpoint)	Categoría de Impacto (Midpoint)	Definición Técnica Simple (Basado en Joliet et al.)	Sustancia de Referencia Equivalente
Salud Humana (Human Health)	1. Toxicidad Humana (Carcinogénica)	Potencial de sustancias químicas para inducir efectos cancerígenos en seres humanos tras su exposición.	g de (C_2H_3Cl)eq (Cloruro de vinilo)
	2. Toxicidad Humana (No Carcinogénica)	Potencial de sustancias para causar daños crónicos no tumorales (ej. daños renales o hepáticos).	g de (C_2H_3Cl)eq (Cloruro de vinilo)
	3. Efectos Respiratorios (Inorgánicos)	Impacto de partículas finas y gases precursores que causan enfermedades respiratorias crónicas.	g de (PM_3)eq (Partículas finas)

Calidad del Ecosistema (Ecosystem Quality)	4. Radiación Ionizante	Daño a la salud debido a la liberación de radionucleidos a la atmósfera o agua.	Bq de (C – 14)eq (Carbono-14)
	5. Disminución de la Capa de Ozono	Degradación de la capa de ozono estratosférico, aumentando la radiación UV perjudicial.	g de (CFC – 11)eq (Clorofluorocarbono)
	6. Oxidantes Fitoquímicos	Formación de ozono a nivel de suelo por reacción de (NO_x) y CO, generando esmog veraniego.	g de (C_2H_4) eq (Etileno)
	7. Ecotoxicidad Acuática	<i>Definición detallada al final de la tabla</i>	g de (TEG) eq al agua (Trietilenglicol)
	8. Ecotoxicidad Terrestre	Capacidad de contaminantes (como metales pesados en suelo) de intoxicar la flora y fauna edáfica.	g de (TEG) eq al suelo (Trietilenglicol)
	9. Acidificación Terrestre y Nutrición	Deposición de compuestos ácidos (SO_2 , NO_x) que alteran el pH y la química del suelo.	g de (SO_2) eq (Dióxido de azufre)
	10. Acidificación Acuática	Descenso del pH en cuerpos de agua debido a deposiciones ácidas, alterando la vida acuática.	g de (SO_2) eq (Dióxido de azufre)
	11. Ocupación de Suelo	Impacto por la alteración física y pérdida de biodiversidad debido	m^2 * año de suelo de suelo orgánico arable

		al uso de suelo agrícola o industrial.	
Cambio Climático (<i>Climate Change</i>)	12. Calentamiento Global	Retención de radiación térmica infrarroja en la atmósfera debido a la acumulación de GEI (CO_2, N_2O).	g de (CO_2) eq (Dióxido de carbono)
Recursos (<i>Resources</i>)	13. Energía No Renovable	Agotamiento de reservas energéticas fósiles por consumo de diésel, gas natural o electricidad.	MJ (Megajulios de energía primaria)
	14. Extracción de Minerales	Consumo y agotamiento de recursos minerales no renovables de la corteza terrestre.	MJ (Energía extra requerida por escasez)

- **Ecotoxicidad Acuática:** Es el indicador que mide el grado de afectación, estrés o letalidad que sufren los organismos que habitan en ecosistemas de agua dulce (peces, algas, crustáceos) debido a la liberación de sustancias químicas tóxicas al medio acuático.
- **Sustancias y Mecanismos de Representación:** En la metodología *IMPACT 2002+*, esta categoría está gobernada principalmente por la lixiviación y escorrentía de metales pesados procedentes de agroquímicos industriales. Químicamente, las sustancias clave con mayor factor de caracterización son el Zinc (Zn^{2+}) y el Cadmio (Cd^{2+}) emitidos al agua. El modelo matemático de Jolliet traduce estos impactos a la sustancia de referencia estándar: el Trietilenglicol ($C_6H_{14}O_4$) equivalente al agua ($g\ TEG\ w\ eq$).
- **ANFIS (Adaptive Neuro-Fuzzy Inference System):** El Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS) es una arquitectura híbrida de inteligencia artificial que combina las capacidades de aprendizaje adaptativo de las Redes Neuronales

Artificiales con la lógica difusa (*Fuzzy Logic*). Mientras que la red neuronal calibra los parámetros mediante el análisis de datos de campo, la lógica difusa permite manejar la incertidumbre e imprecisión intrínseca de los sistemas biológicos utilizando reglas lingüísticas. Actúa como un marco de referencia avanzado para la modelación de sistemas agrícolas de alta variabilidad.

ANEXO 3: Softwares y librerías utilizadas

Para garantizar la reproducibilidad científica de las plataformas automatizadas desarrolladas, se listan los recursos del ecosistema de software libre empleados:

- Google Earth Engine (GEE) API: Interfaz utilizada para la invocación y procesamiento en la nube del catálogo de imágenes del sensor **MODIS (MOD13Q1 V6)**, extrayendo el producto del Índice de Vegetación de Diferencia Normalizada (NDVI), eliminando fuentes de error local mediante scripts automatizados de calibración atmosférica.
- Brightway2: Framework avanzado de código abierto basado en Python para el cálculo de matrices de inventario e impacto ambiental en ACV, permitiendo la integración de las bases de datos de ecoinvent y la automatización de análisis de incertidumbre.
- Activity Browser: Interfaz de usuario de acceso abierto para *Brightway2*, utilizada para la estructuración del inventario citrícola regional y el mapeo de factores de emisión de la metodología *IMPACT 2002+*.
- scikit-learn: Librería base utilizada para el despliegue del algoritmo de regresión del Perceptrón Multicapa (MLPRegressor), la estandarización paramétrica (StandardScaler) y la partición aleatoria de muestras (train_test_split).
- ipywidgets: Biblioteca empleada para el diseño del código gráfico de la interfaz de usuario, permitiendo la generación de controles deslizantes interactivos para la simulación de escenarios de producción en tiempo real.
- numpy y pandas: Librerías fundamentales para la manipulación matricial de metadatos de campo y la estructuración de vectores numéricos de entrada.
- matplotlib.pyplot y seaborn: Motores gráficos de código abierto para el renderizado del histograma de residuos, diagramas de dispersión y análisis visual del ajuste del modelo.

ANEXO 4: Repositorio de Código

En este apartado se muestran los códigos que sostienen esta investigación

Modelo Híbrido para la generación del NDVI

```
# Paquetes base estables para este notebook
!pip -q install -U \
    numpy==2.1.3 \
    pandas==2.2.2 \
    scikit-learn==1.6.1 \
    earthengine-api==0.1.405 \
    geemap==0.32.0 \
    folium==0.16.0 \
    geopy==2.4.1 \
    shapely==2.0.4
import numpy as np, pandas as pd

import ee

ee.Authenticate() # si te lo pide
ee.Initialize(project="solid-sun-478119-p7")

print("GEE listo.")

!pip -q install -U earthengine-api geemap folium geopy shapely
scikit-learn pandas numpy shap

import ee, geemap, pandas as pd, numpy as np

from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import TimeSeriesSplit
from sklearn.metrics import classification_report, roc_auc_score
import shap, datetime as dt

from geopy.geocoders import Nominatim

import ipywidgets as widgets

from IPython.display import display, clear_output

import datetime as dt

from geopy.geocoders import Nominatim

txt_input = widgets.Text(
    value="Álamo, Veracruz, México", # o "20.9345, -97.6743"
```

```

        placeholder="Ej. '20.9345, -97.6743' o 'Álamo, Veracruz,
México'",

        description="Ubicación:",

        style={'description_width':'initial'},

        layout=widgets.Layout(width="600px"),

    )

    radio_km_w = widgets.IntSlider(value=12, min=5, max=30, step=1,
description="Radio (km):")

    fecha_fin_w = widgets.DatePicker(description="Fecha fin:",
disabled=False)

    btn = widgets.Button(description="Fijar ubicación",
button_style="success")

    out = widgets.Output()

def try_parse_latlon(texto: str):
    """
    Intenta parsear 'lat, lon' robustamente.
    Devuelve (lat, lon) si puede, o None si no es un par numérico
    válido.
    """
    # Reemplaza punto y coma por coma y normaliza espacios
    t = texto.strip().replace(";", ",")
    parts = [p.strip() for p in t.split(",")]

    # Solo considerar como coordenadas si hay exactamente 2
    valores numéricos
    if len(parts) == 2:
        try:
            lat = float(parts[0])
            lon = float(parts[1])
            if -90 <= lat <= 90 and -180 <= lon <= 180:
                return lat, lon
        except:

```

```

        return None

    return None

def geocode_name(texto: str):
    geolocator = Nominatim(user_agent="veracruz_lst_ndvi_ml")
    loc = geolocator.geocode(texto, timeout=10)
    if loc is None:
        raise ValueError("No se pudo geocodificar la ubicación.
Intenta con 'lat, lon'.")
    return loc.latitude, loc.longitude

state = {}

def on_click(_):
    with out:
        clear_output()
        try:
            texto = txt_input.value.strip()
            ll = try_parse_latlon(texto)
            if ll is not None:
                lat, lon = ll
            else:
                # Nombre de lugar con comas: usar geocodificación
                lat, lon = geocode_name(texto)

            # Fecha fin: si no eliges, usa hoy-3 días para evitar
            lag de publicación
            fecha_fin = fecha_fin_w.value or (dt.date.today() -
dt.timedelta(days=3))

            state["lat"], state["lon"] = float(lat), float(lon)
            state["radio_km"] = int(radio_km_w.value)

```

```

        state["fecha_fin"] = fecha_fin

    print("Ubicación OK:")
    print(f"    Texto: {texto}")
    print(f"    Coordenadas: ({state['lat']:.5f},
{state['lon']:.5f})")
    print(f"    Radio: {state['radio_km']} km")
    print(f"    Fecha fin: {state['fecha_fin']}")
except Exception as e:
    print("Error:", e)

btn.on_click(on_click)

display(widgets.VBox([txt_input, radio_km_w, fecha_fin_w, btn,
out]))

import ee
import pandas as pd
import numpy as np
import datetime as dt

MODIS_LST = "MODIS/061/MOD11A2"    # LST 8d 1km
MODIS_NDVI = "MODIS/061/MOD13Q1"   # NDVI 16d 250m
CHIRPS = "UCSB-CHG/CHIRPS/DAILY"   # lluvia diaria ~5km
MODIS_ET = "MODIS/061/MOD16A2"     # ET 8d (opcional)

def make_area(lat, lon, radio_km):
    p = ee.Geometry.Point([lon, lat])
    return p.buffer(radio_km * 1000).bounds()

def date_range_weeks(start_date, end_date, step_days=7):
    d = start_date
    while d <= end_date:

```

```

        yield d

        d += dt.timedelta(days=step_days)

def reduce_mean(img, geom, scale, band):
    try:
        v = img.reduceRegion(ee.Reducer.mean(), geom, scale,
maxPixels=1e9).get(band)

        return v.getInfo()
    except Exception:
        return None

def weekly_features_for_point(lat, lon, radio_km, start_date,
end_date):
    area = make_area(lat, lon, radio_km)
    rows = []
    for week_end in date_range_weeks(start_date, end_date, 7):
        week_start = week_end - dt.timedelta(days=7)

        lst = ee.ImageCollection(MODIS_LST).filterBounds(area)\
            .filterDate((week_start -
dt.timedelta(days=8)).isoformat(), (week_end +
dt.timedelta(days=8)).isoformat())\
            .map(lambda i:
i.select("LST_Day_1km").multiply(0.02).subtract(273.15))\
            .median().clip(area).rename("LST_C")

        ndvi = ee.ImageCollection(MODIS_NDVI).filterBounds(area)\
            .filterDate((week_start -
dt.timedelta(days=8)).isoformat(), (week_end +
dt.timedelta(days=8)).isoformat())\
            .select("NDVI").median().multiply(0.0001).clip(area).r
ename("NDVI")

```

```

rain7 = ee.ImageCollection(CHIRPS).filterBounds(area)\
    .filterDate((week_end -
dt.timedelta(days=7)).isoformat(), week_end.isoformat())\
    .select("precipitation").sum().clip(area).rename("RAIN
_7D")

rain30 = ee.ImageCollection(CHIRPS).filterBounds(area)\
    .filterDate((week_end -
dt.timedelta(days=30)).isoformat(), week_end.isoformat())\
    .select("precipitation").sum().clip(area).rename("RAIN
_30D")

et = ee.ImageCollection(MODIS_ET).filterBounds(area)\
    .filterDate((week_start -
dt.timedelta(days=8)).isoformat(), (week_end +
dt.timedelta(days=8)).isoformat())\
    .select("ET").median().clip(area).rename("ET")

row = dict(
    date=week_end.isoformat(),
    lat=lat, lon=lon,
    LST_C = reduce_mean(lst, area, 1000, "LST_C"),
    NDVI = reduce_mean(ndvi, area, 250, "NDVI"),
    RAIN_7D = reduce_mean(rain7, area, 5000, "RAIN_7D"),
    RAIN_30D = reduce_mean(rain30, area, 5000,
"RAIN_30D"),
    ET = reduce_mean(et, area, 500, "ET"),
    month = week_end.month,
    weekofyear = int(week_end.strftime("%U")),
)
rows.append(row)
return pd.DataFrame(rows)

```

```

def label_by_rules(df):
    def classify(lst, ndvi, r7, r30):
        if lst is None or np.isnan(lst): return None
        if 18 <= lst < 28: nivel = 0
        elif (28 <= lst < 32) or (15 <= lst < 18): nivel = 1
        else: nivel = 2

        if (r7 is not None and not np.isnan(r7) and r7 < 5) and
(ndvi is not None and not np.isnan(ndvi) and ndvi < 0.3):
            nivel = min(2, nivel + 1)

        if (r30 is not None and not np.isnan(r30) and r30 > 40)
and (28 <= lst < 32):
            nivel = max(0, nivel - 1)

        return ["Verde", "Amarillo", "Rojo"][nivel]

    df = df.copy()

    df["label"] = df.apply(lambda r: classify(r["LST_C"],
r["NDVI"], r["RAIN_7D"], r["RAIN_30D"]), axis=1)

    df["y"] = df["label"].map({"Rojo":0, "Amarillo":0, "Verde":1})

    return df

import pandas as pd, numpy as np

imp = pd.Series(rf.feature_importances_,
index=features).sort_values(ascending=False)

print("\nImportancias del modelo:")

print(imp)

# Variables actuales (misma lógica que usamos antes)

fecha_fin = state["fecha_fin"]

fecha_ini = fecha_fin - dt.timedelta(days=7)

area = ee.Geometry.Point([state["lon"],
state["lat"]]).buffer(radius_km*1000).bounds()

lst_week = ee.ImageCollection(MODIS_LST).filterBounds(area)\

```

```

        .filterDate((fecha_ini - dt.timedelta(days=8)).isoformat(),
(fecha_fin + dt.timedelta(days=8)).isoformat()))\

        .map(lambda i:
i.select("LST_Day_1km").multiply(0.02).subtract(273.15)).median().
clip(area).rename("LST_C")

ndvi_week = ee.ImageCollection(MODIS_NDVI).filterBounds(area)\

        .filterDate((fecha_ini - dt.timedelta(days=8)).isoformat(),
(fecha_fin + dt.timedelta(days=8)).isoformat()))\

        .select("NDVI").median().multiply(0.0001).clip(area).rename("N
DVI")

rain_7d = ee.ImageCollection(CHIRPS).filterBounds(area)\

        .filterDate((fecha_fin - dt.timedelta(days=7)).isoformat(),
fecha_fin.isoformat()))\

        .select("precipitation").sum().clip(area).rename("RAIN_7D")

rain_30d = ee.ImageCollection(CHIRPS).filterBounds(area)\

        .filterDate((fecha_fin - dt.timedelta(days=30)).isoformat(),
fecha_fin.isoformat()))\

        .select("precipitation").sum().clip(area).rename("RAIN_30D")

def r(img, band, scale):
    try:
        v = img.reduceRegion(ee.Reducer.mean(), area, scale,
maxPixels=1e9).get(band)
        return v.getInfo()
    except Exception:
        return None

row_now = dict(
    LST_C=r(lst_week, "LST_C", 1000),
    NDVI=r(ndvi_week, "NDVI", 250),

```

```

    RAIN_7D=r(rain_7d,"RAIN_7D",5000),
    RAIN_30D=r(rain_30d,"RAIN_30D",5000),
    ET=np.nan,
    month=fecha_fin.month,
    weekofyear=int(fecha_fin.strftime("%U")),
)
x_now = pd.DataFrame([row_now])[features].fillna(0)
score_now = rf.predict_proba(x_now)[:,-1][0]
pred_now = "Apto" if score_now >= 0.5 else "No apto"
print(f"\nPredicción semana que termina en {fecha_fin}: {pred_now}
(score={score_now:.2f})")
print("Variables actuales:\n", x_now)

Creación de Imágenes
!pip -q install -U \
    earthengine-api==1.5.7 \
    geemap==0.33.1 \
    folium==0.16.0

import ee, datetime as dt
from IPython.display import Image, display as ipy_display

# Parámetros desde state
lat, lon, radio_km = state["lat"], state["lon"], state["radio_km"]
fecha_fin = state.get("fecha_fin") or (dt.date.today() -
dt.timedelta(days=10))
if (dt.date.today() - fecha_fin).days < 7:
    fecha_fin = dt.date.today() - dt.timedelta(days=10)
fecha_ini = fecha_fin - dt.timedelta(days=7)
area = ee.Geometry.Point([lon,
lat]).buffer(radio_km*1000).bounds()

MODIS_LST = "MODIS/061/MOD11A2"

```

```

MODIS_NDVI = "MODIS/061/MOD13Q1"
CHIRPS = "UCSB-CHG/CHIRPS/DAILY"

def has_band(img, band):
    try:
        names = img.bandNames().getInfo() or []
        return band in names
    except Exception:
        return False

def safe_visualize(img, vis, label, band):
    if not has_band(img, band):
        print(f"⚠️ {label}: sin datos en el periodo. Intentando ampliar ventana...")
        return None
    try:
        return img.visualize(**vis)
    except Exception as e:
        print(f"⚠️ {label}: error al visualizar:", e)
        return None

# 1) LST (ampliamos ventana ±8 días sobre la semana)
lst_raw = ee.ImageCollection(MODIS_LST).filterBounds(area)\
    .filterDate((fecha_ini - dt.timedelta(days=8)).isoformat(),
                (fecha_fin + dt.timedelta(days=8)).isoformat())\
    .map(lambda i:
i.select("LST_Day_1km").multiply(0.02).subtract(273.15))
lst_img = lst_raw.median().clip(area).rename("LST_C")

# 2) NDVI
ndvi_raw = ee.ImageCollection(MODIS_NDVI).filterBounds(area)\

```

```

        .filterDate((fecha_ini - dt.timedelta(days=8)).isoformat(),
        (fecha_fin + dt.timedelta(days=8)).isoformat()))\

        .select("NDVI").map(lambda i: i.multiply(0.0001))
ndvi_img = ndvi_raw.median().clip(area).rename("NDVI")

# 3) Lluvia 7 días
rain_img = ee.ImageCollection(CHIRPS).filterBounds(area)\

        .filterDate((fecha_fin - dt.timedelta(days=7)).isoformat(),
        fecha_fin.isoformat())\

        .select("precipitation").sum().clip(area).rename("RAIN_7D")

# Visual params
lst_vis = dict(min=15, max=35, palette=['blue','yellow','red'])
ndvi_vis = dict(min=0, max=1, palette=['brown','yellow','green'])
rain_vis = dict(min=0, max=50,
palette=['white','lightblue','blue'])

thumb_params = {'dimensions': 512, 'region': area, 'format':
'png'}

# Visualizaciones seguras
lst_viz = safe_visualize(lst_img, lst_vis, "LST", "LST_C")
ndvi_viz = safe_visualize(ndvi_img, ndvi_vis, "NDVI", "NDVI")
rain_viz = safe_visualize(rain_img, rain_vis, "Lluvia 7d",
"RAIN_7D")

# Fallback: si alguna quedó None, ampliamos ventana/periodo
def fallback_if_none(viz_img, label):
    if viz_img is not None:
        return viz_img

    # Ampliar periodo 30 días hacia atrás
    start_fb = (fecha_fin - dt.timedelta(days=30)).isoformat()

```

```

    end_fb    = fecha_fin.isoformat()

    if label == "LST":

        img =
ee.ImageCollection(MODIS_LST).filterBounds(area).filterDate(start_
fb, end_fb)\

        .map(lambda i:
i.select("LST_Day_1km").multiply(0.02).subtract(273.15))\

        .median().clip(area).rename("LST_C")

        return img.visualize(**lst_vis) if has_band(img, "LST_C")
    else None

    if label == "NDVI":

        img =
ee.ImageCollection(MODIS_NDVI).filterBounds(area).filterDate(start
_fb, end_fb)\

        .select("NDVI").map(lambda i: i.multiply(0.0001))\

        .median().clip(area).rename("NDVI")

        return img.visualize(**ndvi_vis) if has_band(img, "NDVI")
    else None

    if label == "RAIN":

        img =
ee.ImageCollection(CHIRPS).filterBounds(area).filterDate(start_fb,
end_fb)\

        .select("precipitation").sum().clip(area).rename("RA
IN_7D")

        return img.visualize(**rain_vis) if has_band(img,
"RAIN_7D") else None

    return None

lst_viz  = fallback_if_none(lst_viz,  "LST")
ndvi_viz = fallback_if_none(ndvi_viz, "NDVI")
rain_viz = fallback_if_none(rain_viz, "RAIN")

# Obtener URLs (solo para las que existan)
if lst_viz:

```

```

    lst_url = lst_viz.getThumbURL(thumb_params)
    print("LST (°C):", lst_url)
    ipy_display(Image(url=lst_url, width=420))
else:
    print("✗ No se pudo generar miniatura LST.")

if ndvi_viz:
    ndvi_url = ndvi_viz.getThumbURL(thumb_params)
    print("NDVI:", ndvi_url)
    ipy_display(Image(url=ndvi_url, width=420))
else:
    print("✗ No se pudo generar miniatura NDVI.")

if rain_viz:
    rain_url = rain_viz.getThumbURL(thumb_params)
    print("Lluvia 7d (mm):", rain_url)
    ipy_display(Image(url=rain_url, width=420))
else:
    print("✗ No se pudo generar miniatura de Lluvia 7d.")

print("\nSugerencias si alguna capa sigue sin datos:")
print("- Elige una fecha fin de hace 2-4 semanas en el widget.")
print("- Aumenta el radio a 15 km.")
print("- Para NDVI/LST, ampliar más la ventana temporal suele funcionar en regiones nubosas.")

```

Modelo de RNA

```

import numpy as np
import matplotlib.pyplot as plt
from sklearn.neural_network import MLPRegressor

```

```

from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error, r2_score
import pandas as pd
from sklearn.preprocessing import StandardScaler
import ipywidgets as widgets
from IPython.display import display

entradas = np.array().T

salida = np.array().T

# Dividir datos
X_train, X_test, y_train, y_test = train_test_split(entradas,
salida, test_size=0.15, random_state=42)

# Escalar los datos de entrada
scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)

# Crear una versión escalada de 'entradas' para las predicciones
generales
entradas_scaled = scaler.transform(entradas)

mlp = MLPRegressor(
    hidden_layer_sizes=(30, 15),
    activation='tanh',
    solver='lbfgs',
    max_iter=1000000,
    tol=1e-6,
    random_state=1
)

```

```

# Entrenar con datos escalados
mlp.fit(X_train_scaled, y_train)

# Predicciones con datos escalados
y_pred = mlp.predict(entradas_scaled)

# 3. Análisis de Importancia Relativa (Algoritmo de Garson /
Weights Analysis)

# Obtenemos los pesos (W1 = entrada a oculta, W2 = oculta a
salida)
W1 = mlp.coefs_[0]
W2 = mlp.coefs_[1]

# Cálculo simplificado de importancia relativa basado en la
magnitud de los pesos
rel_importance = np.mean(np.abs(W1), axis=1)
rel_importance = (rel_importance / np.sum(rel_importance)) * 100

variables =
['Temp', 'Precip', 'RadSolar', 'Sequia', 'Pendiente', 'Altitud', 'Drenaj
eE', 'DrenajeI', 'Edad', 'Textura', 'pH', 'N', 'P', 'K', 'Ca', 'SO4', 'NDVI'
]

# Graficar Importancia
plt.figure(figsize=(10, 6))
plt.barh(variables, rel_importance, color='skyblue')
plt.xlabel('Porcentaje de Impacto (%)')
plt.title('Importancia Relativa de las Variables en el
Rendimiento')
plt.show()

y_pred_test = mlp.predict(X_test_scaled) # Use scaled test data
for prediction

```

```

mse = mean_squared_error(y_test, y_pred_test)
r2 = r2_score(y_test, y_pred_test)

plt.figure(figsize=(8, 6))
plt.scatter(y_test, y_pred_test, alpha=0.7)
plt.plot([min(y_test), max(y_test)], [min(y_test), max(y_test)],
'r--') # Línea de predicción perfecta
plt.xlabel('Valores Reales (y_test)')
plt.ylabel('Predicciones (y_pred_test)')
plt.title('Predicciones vs. Valores Reales en el Conjunto de
Prueba')
plt.grid(True)
plt.show()

# Calcular los residuos para el conjunto de prueba
residuals = y_test - y_pred_test

# Crear un gráfico de dispersión de residuos vs. valores predichos
plt.figure(figsize=(10, 6))
plt.scatter(y_pred_test, residuals, alpha=0.7)
plt.hlines(y=0, xmin=min(y_pred_test), xmax=max(y_pred_test),
color='red', linestyle='--')
plt.xlabel('Valores Predichos (y_pred_test)')
plt.ylabel('Residuos (y_test - y_pred_test)')
plt.title('Gráfico de Residuos: Residuos vs. Valores Predichos')
plt.grid(True)
plt.show()

# Crear un histograma de los residuos
plt.figure(figsize=(8, 5))
plt.hist(residuals, bins=10, edgecolor='black', alpha=0.7)
plt.xlabel('Residuos')

```

```

plt.ylabel('Frecuencia')
plt.title('Histograma de Residuos')
plt.grid(True)
plt.show()

y_pred_test = mlp.predict(X_test_scaled) # Use scaled test data
for prediction

mse = mean_squared_error(y_test, y_pred_test)
r2 = r2_score(y_test, y_pred_test)

print(f'Mean Squared Error (MSE) on Test Set: {mse:.2f}')
print(f'R-squared (R2) Score on Test Set: {r2:.2f}')

Introducción de pronósticos
nput_widgets = {}

# Iterate through the 'variables' list to create a FloatText
widget for each
for var in variables:
    input_widgets[var] = widgets.FloatText(
        description=f'{var}:',
        value=0.0, # Default value, adjust if sensible defaults
are known
        step=0.1,
        disabled=False
    )
output_widget = widgets.Output()
predict_button = widgets.Button(description="Predict Yield")

def on_predict_button_clicked(b):
    with output_widget:

```

```

        output_widget.clear_output()

        # Get values from widgets
        user_input_values = [input_widgets[var].value for var in
variables]

        # Convert to numpy array and reshape for single prediction
        user_input_array = np.array(user_input_values).reshape(1,
-1)

        # Scale the user input using the fitted scaler
        user_input_scaled = scaler.transform(user_input_array)

        # Make prediction using the trained MLP model on scaled
input
        predicted_yield = mlp.predict(user_input_scaled)[0]

        # Display the predicted yield
        print(f"Predicted Yield: {predicted_yield:.2f}")

predict_button.on_click(on_predict_button_clicked);

# Arrange widgets vertically and display
display(widgets.VBox(
    [widgets.HBox(list(input_widgets.values())[i:i+3]) for i in
range(0, len(variables), 3)] +
    [predict_button, output_widget]
));

```

