



**UNIVERSIDAD MICHOACANA DE
SAN NICOLÁS DE HIDALGO**

**FACULTAD DE INGENIERÍA QUÍMICA
DIVISIÓN DE ESTUDIOS DE POSGRADO**



**Incorporación del Aprendizaje Automático en la
Evaluación del Nexo WEF, la Planificación
Energética y la Sostenibilidad Global: Un Enfoque
desde la Ingeniería Química**

Tesis presentada por:

M.C. Alma Yunuen Raya Tapia

**a la División de Estudios de Posgrado de la
Facultad de Ingeniería Química
como requisito parcial para obtener el Grado de**

**DOCTORA EN CIENCIAS
EN
INGENIERÍA QUÍMICA**

Director de Tesis: Dr. José María Ponce Ortega

Morelia, Michoacán de Ocampo, Agosto de 2025.

Resumen

Incorporación del Aprendizaje Automático en la Evaluación del Nexo WEF, la Planificación Energética y la Sostenibilidad Global: Un Enfoque desde la Ingeniería Química

M.C. Alma Yunuen Raya Tapia

Dirigida por: Dr. José María Ponce Ortega

Entidad: Posgrado de la Facultad de Ingeniería Química

En la era actual, el mundo enfrenta desafíos críticos en la gestión de recursos esenciales, donde la creciente demanda poblacional, la urbanización acelerada y los efectos del cambio climático ejercen presión sin precedentes sobre los sistemas hídricos, energéticos y alimentarios. Estos tres pilares fundamentales para el desarrollo humano presentan interdependencias complejas que, cuando no son gestionadas adecuadamente, generan vulnerabilidades sistémicas, ineficiencias en el uso de recursos y riesgos para la seguridad global. Esta investigación aborda estos retos mediante el desarrollo de metodologías innovadoras basadas en inteligencia artificial y análisis de datos. El trabajo se estructura en cuatro ejes principales que permiten: evaluar la seguridad de recursos mediante indicadores compuestos, proyectar demandas futuras con modelos predictivos, analizar el progreso en sostenibilidad mediante técnicas de agrupamiento, y optimizar sistemas energéticos complejos. Los resultados proporcionan un marco cuantitativo para la toma de decisiones informadas, ofreciendo tanto avances metodológicos como aplicaciones prácticas para enfrentar los desafíos más apremiantes en la gestión sostenible de recursos. Este enfoque representa un paso significativo hacia sistemas más resilientes y eficientes, esenciales para garantizar el bienestar humano y ambiental en las próximas décadas.

Palabras Clave: Clustering; Sustentabilidad; Machine Learning; Recursos; Planificación Estratégica.

Abstract

In the current era, the world faces critical challenges in managing essential resources, where growing population demand, rapid urbanization, and the effects of climate change are placing unprecedented pressure on water, energy, and food systems. These three fundamental pillars of human development have complex interdependencies that, when not properly managed, generate systemic vulnerabilities, resource use inefficiencies, and risks to global security. This research addresses these challenges by developing innovative methodologies based on artificial intelligence and data analysis. The work is structured around four main axes that allow for: assessing resource security using composite indicators, projecting future demand with predictive models, analyzing progress in sustainability using clustering techniques, and optimizing complex energy systems. The results provide a quantitative framework for informed decision-making, offering both methodological advances and practical applications to address the most pressing challenges in sustainable resource management. This approach represents a significant step toward more resilient and efficient systems, essential for ensuring human and environmental well-being in the coming decades.

Keywords: Clustering; Sustainability; Machine Learning; Resources; Strategic planning.

Contenido

Resumen	2
Abstract	3
Contenido.....	4
LISTA DE FIGURAS.....	7
LISTA DE TABLAS.....	9
1. Introducción	10
2. Justificación.....	14
3. Planteamiento del problema	14
4. Hipótesis.....	15
5. Objetivos	15
5.1 Objetivo general	15
5.2 Objetivos particulares.....	15
6. Marco Teórico.....	16
6.1 Antecedentes del nexo agua, energía, alimentos	16
6.2 Los componentes del Nexo WEF.....	17
6.2.1 Agua	17
6.2.2 Energía	18
6.2.3 Alimentos	18
6.3 Interacciones a través del nexo WEF	20
6.3.1 Agua y Energía	20
6.3.1.1 Agua-Energía	20
6.3.1.2 Energía-Agua	21
6.3.2 Agua y Alimentos.....	22
6.3.2.1 Agua-Alimentos.....	22
6.3.2.2 Alimentos-Agua.....	23
6.3.3 Energía y Alimentos.....	24
6.3.3.1 Energía-Alimentos.....	24
6.3.3.2 Alimentos-Energía.....	25
6.4 Presiones del nexo WEF	26
6.5 Importancia de los Objetivos de Desarrollo Sostenible (ODS)	27
6.6 El Nexo Agua-Energía-Alimentos en los ODS.....	28

6.7 Importancia de la Planificación Energética en Sistemas con Alta Participación de Energías Renovables	29
6.8 Aprendizaje automático	30
6.8.1 Proceso de Aprendizaje Automático.....	31
6.8.2 Escalado.....	32
6.9 Tipos de aprendizaje automático	33
6.9.1 Aprendizaje automático supervisado	33
6.9.2 Aprendizaje profundo	35
6.9.2.1 Long Short-Term Memory (LSTM).....	35
6.9.2.2 Gated Recurrent Units (GRU).....	37
6.9.3 Aprendizaje automático no supervisado.....	37
6.9.3.1 Clustering K-means	39
7. Metodología general.....	39
7.1 Fase 1: Evaluación cuantitativa de la seguridad del nexo WEF y residuos mediante el índice compuesto WEF-Waste (Caso: España).....	41
7.1.1 Metodología	41
7.1.2 Caso de estudio.....	46
7.1.3 Resultados.....	47
7.2 Fase 2: Proyección del nexo WEF mediante redes neuronales profundas (LSTM y GRU)	60
7.2.1 Metodología	60
7.2.2 Caso de Estudio	64
7.2.3 Resultados.....	65
7.2.3.1 Aprendizaje profundo	65
7.2.3.2 Indicadores	68
7.3 Fase 3: Clasificación de regiones según vulnerabilidad en el cumplimiento de los Objetivos de Desarrollo sostenible (SDG) mediante clustering.....	78
7.3.1 Metodología	78
7.3.1.1 Estudio de caso.....	78
7.3.1.2 Recolección de datos	80
7.3.1.3 Matriz de correlación	80
7.3.1.4 Preparación de datos	81
7.3.1.5 Validación de grupos.....	81
7.3.1.5.1 Método de codo	81

7.3.1.5.2 Método de silueta	81
7.3.2 Resultados.....	82
7.3.2.1 Correlación	82
7.3.2.2 Validación	84
7.3.2.2.1 Método de codo	85
7.3.2.2.2 Metodo de silueta	85
7.3.2.3 Análisis de grupos.....	88
7.3.2.3.1 Base de datos de los 17 SDGs	88
7.3.2.3.2 Base de datos de los 17 SDGs y el indicador de desperdicio de alimentos..	90
7.3.2.4 Clasificación de países	91
7.4 Fase 4. Comparación de Métodos para Seleccionar Semanas Representativas en Planificación Energética con Energías Renovables.....	94
7.4.1 Metodología	94
7.4.2 Calculo del NLDC de cada nodo.....	95
7.4.3 Clustering	96
7.4.4 Modelo Matemático	97
7.4.5 Caso de estudio	108
7.4.6 Resultados.....	110
7.4.6.1 Selección de semanas	110
7.4.6.2 Modelo de GAMS.....	113
8. Conclusión	127
8.1 Evaluación Cuantitativa del Nexo WEF en España.....	128
8.2 Proyecciones del Nexo WEF en México mediante Aprendizaje Profundo	128
8.3 Análisis de los ODS y su Relación con el Desperdicio de Alimentos.....	128
8.4 Selección de Semanas Representativas para la Planificación Energética	128
9. Nomenclatura	130
10. Referencias	137
Apéndice A. Caratulas de artículos científicos publicados en este proyecto	150

LISTA DE FIGURAS

Figura 1. Objetivos de desarrollo sostenible.....	28
Figura 2. Proceso del aprendizaje automático.....	32
Figura 3. Proceso de Aprendizaje supervisado.....	34
Figura 4. Redes LSTM y GRU.....	37
Figura 5. Proceso de aprendizaje no supervisado	38
Figura 6. Mapa de calor que representa el valor del índice WEF-Waste para cada comunidad autónoma de España.	47
Figura 7. Puntuaciones de cada comunidad autónoma para los indicadores de a) Disponibilidad hídrica W_1 y b) Independencia hídrica W_2	50
Figura 8. Puntuaciones de cada comunidad autónoma de 2009 a 2020 para los indicadores de a) Agua tratada W_3 y b) Agua reutilizada W_4	52
Figura 9. Puntuaciones de las comunidades autónomas de 2010 a 2021 para los indicadores de a) Disponibilidad energética E_1 y b) Energías renovables E_2	54
Figura 10. Puntuaciones de las comunidades autónomas de 2010 a 2021 para los indicadores de a) Independencia energética E_3 y b) Disponibilidad alimentaria F_1	56
Figura 11. Puntuaciones de las comunidades autónomas para los indicadores a) F_2 y b) F_3	57
Figura 12. Puntuaciones de las comunidades autónomas de 2010 a 2020 para el indicador F_4	58
Figura 13. Puntuaciones de las comunidades autónomas de 2010 a 2020 para los indicadores a) R_1 y b) R_2	59
Figura 14. Metodología específica de la fase 2	61
Figura 15. Comparación de los valores reales frente a los valores predichos por los modelos para el conjunto de validación.	68
Figura 16. Consumo de agua proyectado, agua renovable per cápita y el indicador WW_1 de disponibilidad de agua.	70
Figura 17. Proyección de población con y sin acceso al agua e indicador de accesibilidad al agua WW_2	71
Figura 18. Producción y consumo de electricidad proyectados e indicador de disponibilidad energética E_1	72
Figura 19. Proyección de población con y sin acceso a electricidad y el indicador E_2 de accesibilidad energética.....	73
Figura 20. Producción y consumo de alimentos proyectados e indicador de disponibilidad de alimentos F_1	74
Figura 21. Proyección de la población con y sin acceso a alimentos y el indicador F_2 de accesibilidad a los alimentos.	75
Figura 22. Puntuación del índice de nexo WEF proyectada.	76
Figura 23. Metodología específica de la fase 3.	78
Figura 24. Matriz de correlación de los 17 SDG y el indicador de desperdicio de comida en los hogares (Food-Waste).....	83
Figura 25. Gráfico de codo para los 17 SDG (izquierda) y 17 SDG + indicador de desperdicio de comida (derecha).....	85
Figura 26. Graficas de coeficiente promedio de silueta para los 17 SDG (izquierda) y 17 SDG + indicador de desperdicio de comida (derecha).....	86

Figura 27. Visualizador de silueta de agrupamiento de k-means para 17 SDG en k grupos, k=2, 3, 4 y 5.....	87
Figura 28. Visualizador de silueta de agrupamiento de k-means de 17 SDG e indicador de desperdicio de comida en k grupos, k=2, 3, 4 y 5.....	88
Figura 29. Clasificación de países de acuerdo con su nivel de sostenibilidad (Base de datos de 17 SDGs).....	92
Figura 30. Clasificación de países de acuerdo con su nivel de sostenibilidad (Base de datos de 17 SDGs e indicador de desperdicio de alimentos).	93
Figura 31. Metodología de la fase 4	94
Figura 32. Perfil de carga neta aproximado de 4 semanas representativas del conjunto total de 52 semanas.	95
Figura 33. Representación esquemática de la metodología general implementada.....	99
Figura 34. Regiones de transmisión del modelo estudiado en México.	110
Figura 35. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 41.....	111
Figura 36. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 42.....	112
Figura 37. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 43.....	112
Figura 38. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 44.....	113
Figura 39. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 45.....	113
Figura 40. Evolución de las emisiones durante cada año de planificación en el conjunto de semanas A, B y C.....	115
Figura 41. Evolución del uso de gas natural en cada nodo en el conjunto de semanas A, B y C.	116
Figura 42. Evolución del uso de combustóleo en cada nodo en el conjunto de semanas A, B y C.	117
Figura 43. Energía producida, transmitida y restringida durante el horizonte de 10 años para cada conjunto de semanas representativas.	122
Figura 44. Estructura de generación total y generación para abastecer demanda interna	123
Figura 45. Electricidad transmitida de cada nodo.....	125
Figura 46. Energía desperdiciada de cada nodo.	126

LISTA DE TABLAS

Tabla 1. Riesgos e impactos del nexo agua-energía / energía-agua. (IRENA, 2015).....	21
Tabla 2. Riesgos e impactos dentro del nexo agua-alimentos / alimentos-agua (IRENA, 2015)....	24
Tabla 3. Riesgos e impactos dentro del nexo energía-alimentos / alimentos-energía	26
Tabla 4. Impacto de los riesgos relacionados con las presiones del nexo del WEF	27
Tabla 5. Espacio de búsqueda de hiperparámetros para el algoritmo de optimización	66
Tabla 6. Resultados obtenidos después de la optimización de hiperparámetros.	66
Tabla 7. Métricas de error obtenidas para datos de entrenamiento y validación.	68
Tabla 8. Pares de objetivos de desarrollo sostenible e indicador con mayor correlación positiva y negativa.	84
Tabla 9. Caracterización de grupos.....	88
Tabla 10. Puntajes promedio de los 17 SDGs de cada grupo.....	89
Tabla 11. Puntajes promedio de los 17 SDGs e indicador de desperdicio de alimentos de cada grupo	90
Tabla 12. Parámetros de capacidad instalada de las tecnologías de generación y costos de almacenamiento	109
Tabla 13. Resultados de los tres métodos en la selección de semanas representativas	111
Tabla 14. Resultados obtenidos para los conjuntos de semanas A, B y C, minimizando costos....	118
Tabla 15. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas A	119
Tabla 16. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas B	120
Tabla 17. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas C	121
Tabla 18. Almacenamiento de electricidad total durante 10 años en el nodo 39.	127

1. Introducción

El siglo XXI se caracteriza por desafíos globales sin precedentes en la gestión de recursos naturales, marcados por una creciente tensión entre las demandas humanas y los límites planetarios. Las proyecciones más recientes indican que la población mundial alcanzará los 8,500 millones de habitantes en 2030 y podría superar los 11,200 millones para 2100 (United Nations Department of Economic and Social Affairs, 2015). Este crecimiento demográfico, acompañado de una expansión económica global que podría triplicar el PIB mundial para 2050 (OCDE, 2016), está generando presiones insostenibles sobre los sistemas hídricos, energéticos y alimentarios. Los modelos sectoriales tradicionales han demostrado ser insuficientes para capturar las interacciones complejas del nexo agua-energía-alimentos (WEF), especialmente en contextos de alta incertidumbre climática y social (Albrecht et al., 2018; Daher et al., 2019). Por lo que la complejidad de estas interacciones demanda nuevos marcos analíticos que trasciendan los enfoques sectoriales tradicionales y capturen las dinámicas sistémicas del nexo agua-energía-alimentos (WEF), un concepto que ha ganado relevancia en la última década como paradigma integrador para abordar estos desafíos interconectados (Hoff, 2011; Smajgl & Ward, 2013).

La interdependencia entre estos recursos fundamentales es profunda y multifacética. A nivel global, el sector agrícola consume aproximadamente el 70% de las extracciones de agua dulce (FAO, 2019), mientras que el 30% del consumo energético mundial está vinculado a la producción y suministro de alimentos (Chang et al., 2016). Dichas conexiones dan lugar a una estructura interdependiente, donde las acciones en un ámbito afectan de forma notable a los otros. Como señalan Zhang et al. (2018), el aumento en la producción de biocombustibles, que es una estrategia común para descarbonizar el sector energético, puede competir directamente con tierras agrícolas y recursos hídricos necesarios para seguridad alimentaria. Estas compensaciones se ven exacerbadas por el cambio climático, que está alterando los patrones de disponibilidad hídrica y productividad agrícola en múltiples regiones del mundo (IPCC, 2021), creando un escenario donde las políticas sectoriales aisladas resultan cada vez más inadecuadas para garantizar la seguridad de estos tres recursos críticos.

La gestión tradicional de estos recursos, caracterizada por enfoques fragmentados y políticas sectoriales aisladas, ha demostrado ser insuficiente para abordar estos desafíos

interconectados. Como señalan Ji et al. (2020), el agua, la energía y los alimentos frecuentemente son administrados por instituciones separadas con marcos regulatorios independientes, lo que dificulta la identificación de sinergias y la mitigación de conflictos. Esta falta de coordinación tiene consecuencias tangibles: se estima que el 30% de los alimentos producidos globalmente se pierde o desperdicia cada año (FAO, 2012), representando no solo un fracaso en la seguridad alimentaria sino también un despilfarro masivo de los recursos hídricos y energéticos invertidos en su producción. Esta situación evidencia la necesidad urgente de enfoques integrados que puedan capturar las complejas interacciones entre estos sistemas (Albrecht et al., 2018).

Ante esta complejidad, el enfoque del nexo WEF emergió como un paradigma clave para entender y gestionar estas interrelaciones. Su conceptualización formal en la Conferencia de Bonn de 2011 (Naranjo & Willaarts, 2020) marcó un punto de inflexión al reconocer que las soluciones sostenibles requieren necesariamente de perspectivas integradas. Como argumentan Smajgl y Ward (2013), el nexo no es simplemente la suma de sus componentes, sino un sistema complejo donde las intervenciones en un ámbito generan efectos en los otros. Esta visión ha sido respaldada por proyecciones que indican aumentos del 55% en la demanda hídrica global, 50% en energía y 70% en alimentos para 2050 (PNUMA, 2011), cifras que resultan imposibles de alcanzar sin mejorar radicalmente la eficiencia en las interconexiones del sistema. Sin embargo, como señalan Daher et al. (2019), la implementación operativa del enfoque de nexo sigue enfrentando importantes desafíos metodológicos, particularmente en el desarrollo de herramientas cuantitativas que puedan capturar adecuadamente estas dinámicas complejas.

La evaluación cuantitativa de estas dinámicas ha motivado el desarrollo de diversas herramientas analíticas. Modelos como WEAP (SEI, 2014) para la planificación hídrica y LEAP (SEI, 2013) para sistemas energéticos han permitido avanzar en el entendimiento de subsistemas específicos. Sin embargo, como señalan Albrecht et al. (2018), estas herramientas presentan limitaciones significativas cuando se trata de capturar las retroalimentaciones complejas entre sectores. La WEF Nexus Tool 2.0 (Mohtar & Daher, 2016) representó un avance importante al incorporar explícitamente estas interacciones, pero su aplicación sigue siendo computacionalmente intensiva y requiere datos detallados que no

siempre están disponibles, especialmente en escalas regionales y locales (Daher et al., 2019). Esta brecha analítica ha impulsado la exploración de enfoques alternativos basados en técnicas de aprendizaje automático, que pueden ofrecer soluciones innovadoras para superar estas limitaciones.

El crecimiento exponencial en la disponibilidad de datos y la capacidad computacional ha abierto nuevas posibilidades para abordar estos desafíos mediante técnicas de aprendizaje automático. Como destacan Tiwari y Adamowski (2017), los métodos basados en datos (data-driven) presentan ventajas significativas en contextos con alta incertidumbre y relaciones complejas, características típicas de los sistemas del nexo WEF. Las redes neuronales artificiales, por ejemplo, han demostrado éxito en la predicción de demandas hídricas a nivel de cuencas (Akhter et al., 2019), mientras que las máquinas de vectores de soporte han sido aplicadas para optimizar sistemas de riego energéticamente eficientes. No obstante, como advierten Mentch y Hooker (2016), estos enfoques deben ser implementados con cautela, asegurando que las predicciones sean interpretables y estén fundamentadas en el entendimiento de los procesos subyacentes. Este equilibrio entre el poder predictivo de los algoritmos y la comprensión de los mecanismos físicos representa un desafío clave en la aplicación de estas técnicas al estudio del nexo WEF.

En el ámbito de las series temporales, arquitecturas avanzadas como LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Units) han revolucionado la capacidad para modelar dependencias a largo plazo en sistemas complejos. Desarrolladas originalmente para superar el problema del gradiente descendente en redes neuronales recurrentes tradicionales (RNN) (Hochreiter & Schmidhuber, 1997), estas técnicas han encontrado aplicaciones prometedoras en la predicción de variables climáticas, demandas energéticas y producción agrícola (Rajagukguk et al., 2020). Paralelamente, los algoritmos de agrupamiento (clustering) han emergido como herramientas valiosas para simplificar problemas complejos sin perder información crítica. En la planificación energética, métodos como k-means y k-medoides han permitido identificar patrones estacionales en la generación renovable y seleccionar períodos representativos que capturan la variabilidad del sistema (Helistö et al., 2020). Como demuestra Kotzur et al. (2018), estas técnicas son particularmente útiles para sistemas con

alta participación de energías renovables variables, donde la gestión óptima requiere entender tanto los extremos como los comportamientos típicos del recurso.

La creciente disponibilidad de datos ha sido un factor clave para habilitar estas aplicaciones. Iniciativas como los sistemas de monitoreo hídrico de Maupin et al. (2014) o las bases de datos energéticas de Department of Energy (DOE) Office of Energy Policy and Systems Analysis (EPSA) han proporcionado los insumos necesarios para entrenar y validar modelos avanzados. Sin embargo, como señalan Endo et al. (2015), persisten importantes desafíos en términos de calidad, consistencia y accesibilidad de los datos, particularmente en regiones en desarrollo donde los sistemas de monitoreo son menos robustos. Además, la interpretabilidad de los modelos complejos sigue siendo una preocupación relevante, particularmente cuando sus resultados deben informar políticas públicas o decisiones de inversión en infraestructura crítica (Molajou et al., 2021). Estos desafíos técnicos y metodológicos subrayan la necesidad de desarrollar enfoques híbridos que combinen el poder predictivo del aprendizaje automático con el conocimiento experto de las disciplinas tradicionales.

La convergencia entre métodos data-driven y modelos físicos tradicionales ofrece un marco poderoso para abordar los desafíos interconectados del nexo agua-energía-alimentos (WEF). En este contexto, la ingeniería química se posiciona como una disciplina clave, al integrar el análisis de flujos de materia y energía, la optimización de procesos, el tratamiento de residuos y los principios de economía circular en contextos complejos y con alta incertidumbre (El-Halwagi, 2017). Como afirman Namany y Al-Ansari (2021), esta disciplina está particularmente capacitada para articular herramientas computacionales avanzadas con fundamentos fisicoquímicos. El aprendizaje automático, por su parte, permite complementar los modelos tradicionales, facilitando la identificación de patrones no lineales y la predicción en sistemas donde las relaciones entre variables son difusas o incompletas. Esta sinergia es especialmente relevante en la mejora de procesos industriales intensivos en recursos o en el diseño de sistemas sostenibles de producción de alimentos (El-Halwagi, 2017). Bajo este enfoque, el presente proyecto propone integrar herramientas como redes neuronales recurrentes, clustering y análisis multivariable para evaluar y proyectar la seguridad de recursos clave, orientando intervenciones tecnológicas alineadas con los ODS y una visión sistémica propia de la ingeniería química.

2. Justificación

El aprendizaje automático se posiciona como una herramienta fundamental para abordar los complejos desafíos del nexo Agua-Energía-Alimentos (WEF), ofreciendo capacidades analíticas sin precedentes. Las redes neuronales recurrentes (LSTM/GRU) demuestran superioridad en modelar series temporales complejas, capturando no linealidades y patrones estacionales en la demanda de recursos que los métodos estadísticos tradicionales no pueden identificar. Por otro lado, las técnicas de clustering permiten descubrir estructuras ocultas en datos multidimensionales, siendo cruciales para: (1) optimizar la planificación energética mediante la identificación de períodos representativos, y (2) analizar el progreso en ODS mediante agrupamientos que revelen patrones geopolíticos y socioeconómicos. Desde la perspectiva de la ingeniería química, estas técnicas permiten diseñar sistemas de gestión de recursos con enfoque circular, donde el análisis de big data se combina con principios de optimización de procesos para maximizar la eficiencia global.

3. Planteamiento del problema

La creciente presión sobre los recursos naturales ha expuesto las limitaciones de los modelos convencionales para abordar el nexo WEF de manera integral. Los principales desafíos incluyen: la falta de herramientas estandarizadas para evaluar la seguridad de recursos en diferentes escalas, la incapacidad de los métodos tradicionales para proyectar demandas futuras considerando variables climáticas y socioeconómicas, y la dificultad para integrar energías renovables variables en los sistemas energéticos. Debido a que la optimización de sistemas energéticos con múltiples variables (tecnologías, regiones, restricciones) y la intermitencia de energías renovables supera los límites computacionales de los métodos convencionales. Además, el avance hacia los ODS se ve obstaculizado por la ausencia de metodologías que analicen sistemáticamente las interrelaciones entre las distintas metas, particularmente en lo que respecta a la reducción de pérdidas alimentarias y su impacto en otros objetivos. Estos desafíos exigen enfoques innovadores que combinen técnicas de aprendizaje automático con los principios de la ingeniería química y el análisis sistémico, generando evidencia robusta para la transición hacia sistemas más sostenibles.

4. Hipótesis

La aplicación de algoritmos de aprendizaje automático permite mejorar significativamente la evaluación, predicción y planificación de la seguridad de los recursos vinculados al nexo agua-energía-alimentos, facilitando el diseño de estrategias más sostenibles y eficientes desde la perspectiva de la ingeniería química.

5. Objetivos

5.1 Objetivo general

Desarrollar y aplicar metodologías basadas en aprendizaje automático para evaluar la seguridad de los recursos del nexo agua-energía-alimentos y residuos, así como para optimizar la planificación energética y el cumplimiento de los ODS, desde una perspectiva de sostenibilidad e ingeniería química.

5.2 Objetivos particulares

- Desarrollar un índice compuesto multivariable que integre indicadores de disponibilidad y accesibilidad de agua, energía y alimentos, complementado con indicadores de residuos sólidos urbanos, evaluando su comportamiento espacial y temporal en un caso de estudio nacional y/o regional.
- Implementar modelos de aprendizaje profundo que proyecten la demanda y disponibilidad de agua, energía y alimentos, evaluando la seguridad de los recursos a largo plazo ante variabilidad climática y cambios poblacionales en un contexto nacional.
- Aplicar técnicas de aprendizaje no supervisado como clustering para clasificar países según su avance en los Objetivos de Desarrollo Sostenible (ODS) y su gestión de residuos y desperdicio de alimentos, con el fin de identificar tipologías que permitan estrategias diferenciadas.
- Comparar métodos de selección de semanas representativas mediante algoritmos de aprendizaje no supervisado como clustering, para mejorar la precisión y eficiencia computacional de modelos de planificación energética en sistemas complejos.

- Analizar la aplicabilidad de los resultados desde la ingeniería química, proponiendo acciones orientadas a la mejora de procesos de gestión de recursos y a la reducción de impactos ambientales.

6. Marco Teórico

6.1 Antecedentes del nexo agua, energía, alimentos

El agua, la energía y los alimentos (FEW) están inextricablemente conectados, lo que se denomina "Nexo" (Reinhard et al., 2017). "Nexo" se define como "un vínculo o vínculos que conectan dos o más sectores"

Esto significa que FEW Nexus es aplicable a diferentes conexiones como agua-energía, energía-alimento, alimento-agua y alimento-energía-agua (Endo and Oh, 2018) (Salam et al., 2017).

Con respecto a la revisión histórica de las actividades de nexos, se han realizado diversos estudios y proyectos del nexo agua-energía-alimentos, basados en los intereses de una variedad de actores en diferentes escalas alrededor del mundo desde que la terminología de nexo apareció por primera vez en 1983, cuando las Naciones Unidas (UNU) lanzó un Programa Nexo entre Alimentos y Energía para reconocer la importante interconexión entre los problemas de alimentos y energía.

El concepto del nexo agua-energía-alimentos se lanzó en Bonn en 2011, cuando el gobierno federal alemán organizó una conferencia internacional titulada "El nexo entre agua, energía y seguridad alimentaria: soluciones para la economía verde" (en adelante, la Conferencia de Bonn 2011) para contribuir a la Conferencia de las Naciones Unidas sobre el Desarrollo Sostenible (Río + 20). El "enfoque del nexo" se introdujo en un documento de antecedentes para la conferencia con el fin de mostrar la dirección de los estudios del nexo para una sociedad sostenible. Este enfoque tiene como objetivo aumentar la eficiencia de la utilización de los recursos, reducir las compensaciones entre los recursos, sinergizar la utilización de diferentes recursos y mejorar la gobernanza en todos los sectores. Esto fue impulsado por el aumento de compensaciones y posibles conflictos en la utilización de estos recursos, que tienen interacciones complejas y son interdependientes, en el contexto del cambio climático y social. El enfoque del nexo se centra en la eficiencia del sistema más que en la

productividad de sectores aislados (Hoff, 2011). El Mapa de Interconexiones de Riesgos Globales publicado por el Foro Económico Mundial (WEF) en 2016 identificó las crisis alimentarias, las crisis del agua y los choques de precios de la energía como riesgos globales interconectados (World Economic Forum, 2016).

6.2 Los componentes del Nexo WEF

6.2.1 Agua

El agua es uno de los recursos más valiosos del planeta y es vital para sustentar el ecosistema (Amer et al., 2016). Hay suficientes fuentes de agua dulce en el mundo para satisfacer la demanda mundial, pero la distribución desigual y no uniforme de las reservas de agua ha provocado escasez (Salam et al., 2017). Aproximadamente una quinta parte de la población mundial trata con problemas de escasez (Amer et al., 2016). Se estima que el 50% de la población mundial se enfrentará a un alto estrés hídrico con un alto efecto en la seguridad alimentaria y energética. Aunque el agua es una fuente renovable y hay mucha disponible para satisfacer la creciente población mundial, el suministro de agua no satisface la demanda en la mayoría de las áreas del planeta, que se observa principalmente en el norte de África y Oriente Medio (Lotfi et al., 2020).

La escasez de agua afecta principalmente al consumo humano; sin embargo, tiene otros efectos en el ecosistema, suministro de energía y producción de alimentos (Salam et al., 2017). La gestión y la gobernanza deficientes, que empeoran la calidad de los recursos hídricos naturales, se han hecho evidentes en las últimas décadas. La escasez de agua es uno de los asuntos más desafiantes en estas regiones, que presentará una amenaza real que seguramente afectará los desarrollos socioeconómicos (Amer et al., 2016).

El crecimiento de las necesidades de agua es casi dos veces mayor que el aumento de la población en el siglo XX y los altos niveles de vida en combinación con el crecimiento económico podrían ser la razón (Salam et al., 2017).

El agua, a diferencia de cualquier otro recurso natural, afecta todos los aspectos de la sociedad y el medio ambiente y es esencial para el bienestar humano. Específicamente, el agua está integrada en todos los aspectos del desarrollo, incluida la seguridad alimentaria, la salud y la reducción de la pobreza, y en el sostenimiento del crecimiento económico en la agricultura, la industria y la generación de energía (Global Water Partnership, 2012).

La seguridad hídrica es la capacidad de una población para salvaguardar el acceso sostenible a cantidades adecuadas de agua de calidad aceptable para sustentar los medios de vida, el bienestar humano y el desarrollo socioeconómico, para garantizar la protección contra la contaminación transmitida por el agua y los desastres relacionados con el agua, y para la preservación de los ecosistemas en un clima de paz y estabilidad política (Brears, 2016).

6.2.2 Energía

La demanda de energía está creciendo principalmente debido al aumento de la población y al PIB. El aumento del PIB proviene principalmente del crecimiento de la población y la mejora de la productividad, que representan el 20% y el 80%, respectivamente. El crecimiento de la economía mundial requiere energía adicional y se estima que el consumo de energía aumentará en un 34% entre 2014 y 2035 (British Petroleum, 2016).

Se prevé que los combustibles fósiles serán la principal fuente de la mayoría de las actividades humanas y proporcionarán casi el 80% del suministro energético mundial para 2035. Se espera que la energía renovable sea más popular, pero representará menos del 10% del suministro total de energía en 2035 (Salam et al., 2017). La mayor parte del crecimiento del sector energético se utiliza para la generación de energía. Para 2035, la proporción del consumo de energía para la generación de electricidad aumentará un 45% (British Petroleum, 2016).

La energía sustenta el crecimiento económico en todos los países, independientemente de los niveles de desarrollo, siendo clave en la producción de todo tipo de bienes y servicios, incluidos los alimentos y el suministro de agua. Mientras tanto, el combustible energético permite el movimiento de bienes manufacturados, personas, servicios e ideas. Como tal, el uso de energía y el crecimiento económico están estrechamente relacionados con una relación lineal clara entre el consumo de energía y la riqueza, medidos en el PIB de las naciones (PNUMA, 2011). La seguridad energética se conoce como las acciones de seguridad que una comunidad debe seguir para mantener un suministro de energía adecuado (Cuberos-Balda et al., 2017). La OCDE considera que la mejora del rendimiento medioambiental de la energía es la piedra angular de cualquier intento de crecimiento ecológico.

6.2.3 Alimentos

Existe una creciente preocupación por la capacidad mundial para producir alimentos y satisfacer la demanda de la población en aumento. La cantidad de suelo cultivable está

disminuyendo mientras se enfrenta a la industrialización y urbanización que requieren los mismos activos. La forma más popular de calificar el consumo mundial de alimentos y las condiciones de disponibilidad es en kcal/persona/día. La disponibilidad media mundial de alimentos para el consumo humano directo fue de 2770 kcal/persona/día en 2005-2007 (Salam et al., 2017). Se proyecta que en 2050 casi el 52% de la población mundial vivirá en regiones con un promedio de más de 3000 kcal / persona / día, lo que equivale al 28% para el mismo consumo actual. Además, las personas que viven en regiones con un consumo medio inferior a 2500 kcal disminuirán del 35% al 2,6% hasta 2050. La oferta y la demanda de productos agrícolas también se ven afectadas por usos no alimentarios como los biocombustibles (Alexandratos y Bruinsma, 2012).

La Organización de las Naciones Unidas para la Agricultura y la Alimentación (FAO) define la seguridad alimentaria como “las personas tienen en todo momento acceso físico, social y económico a alimentos suficientes, inocuos y nutritivos para satisfacer sus necesidades dietéticas y preferencias alimentarias para una vida activa y saludable” (FAO, 1996).

El Informe mundial sobre crisis alimentarias de 2018 demuestra la última aproximación de la necesidad severa de alimentos en el mundo. Se estima que 124 millones de personas en 51 países se enfrentan ahora a la inseguridad alimentaria. La inseguridad y los conflictos siguieron siendo los principales impulsores de la inseguridad alimentaria en 18 países, donde casi 74 millones de personas que padecen inseguridad alimentaria necesitan ayuda urgente (United Nations, 2018).

Un aspecto clave para lograr la seguridad alimentaria es reconocer que, si bien la intensificación de la producción agrícola puede impulsar la seguridad alimentaria de millones de personas en todo el mundo, el aumento de la producción de alimentos puede contribuir a problemas como la degradación de la tierra, la contaminación del agua y el agotamiento de los recursos hídricos, todos los cuales, a su vez, amenazan la seguridad alimentaria (UNEP, 2011).

6.3 Interacciones a través del nexo WEF

6.3.1 Agua y Energía

6.3.1.1 Agua-Energía

La accesibilidad al agua y la energía es vital para lograr el desarrollo. Si existe escasez de agua en un área, eventualmente ocurre la falta de acceso a la electricidad, por lo tanto, esta sección se centra en cómo los recursos hídricos pueden afectar los sistemas energéticos. La caída de la disponibilidad de agua dulce afectará en gran medida la generación de energía. El consumo energético de las economías emergentes como Brasil e India se duplicará y debido al aumento de la energía eléctrica en América Latina se triplicará la necesidad de agua para 2060. Por lo tanto, la gestión del suministro de agua será de suma importancia, especialmente en las regiones en las que el estrés hídrico es enorme (Zwaan et al., 2014).

Se necesita agua para producir casi todas las formas de energía. Se estima que la demanda de electricidad aumentará hasta en un 70% para 2035 lo cual provocará un aumento del 20% en la extracción de agua dulce para el 2035. También se estima que el uso de agua aumentará en un 85%, lo que definitivamente cambiará la generación de energía hacia plantas de energía más eficientes con alta tecnología en sistemas de refrigeración (UNESCO, 2015). Dado que el 90% de los sistemas energéticos mundiales dependen del agua, la gestión del consumo de agua y la planificación de una manera más eficiente es muy notoria. Es necesario dividir dos tipos de uso del agua en la extracción de agua, que es el agua extraída de la fuente de agua y el consumo de agua, que es el agua que no se devuelve a la fuente de agua original (Zwaan et al., 2014).

Además, se introduce otra categoría, el primer grupo es el agua para el ciclo del combustible que comprende la extracción de combustible, la producción de combustible convencional y el cultivo de biocombustible. El segundo grupo se denomina agua para la conversión de energía y consiste en el uso del agua en la generación de electricidad y el transporte (Laspidou et al., 2017).

El consumo de agua en la generación de energía eléctrica se basa en la tecnología de generación. En la generación de energía hidroeléctrica, el consumo de agua depende principalmente del tipo de planta de energía y las pérdidas por evaporación. En las centrales térmicas, el uso del agua debe evaluarse en términos de consumo y extracción. En este caso, la cantidad de agua utilizada se basa en la tecnología de la central térmica y la tecnología de

refrigeración. En algunos sistemas de refrigeración, el agua extraída es alta y el agua consumida es baja. Mientras tanto, en otros sistemas de enfriamiento lo contrario podría ser cierto. Sin embargo, una alta extracción de agua no significa necesariamente un alto consumo (Laspidou et al., 2017).

6.3.1.2 Energía-Agua

A continuación, demuestra cómo la energía puede afectar los sistemas de agua. Los detalles se clasifican en tres partes: funcionamiento de los sistemas de agua, uso del agua y el impacto del sector energético en los sistemas de agua (Brears, 2018).

La energía eléctrica es necesaria para impulsar las bombas que extraen (de fuentes terrestres y superficiales), transportan, distribuyen y recolectan agua. La cantidad de electricidad requerida depende de la distancia o profundidad de la fuente de agua. Los procesos de tratamiento de agua que convierten varios tipos de agua (dulce, salobre, salina y residual) en agua apta para un uso específico requieren electricidad y, en ocasiones, calor.

Los informes muestran que, en 2014, el 4% de la energía eléctrica mundial se utiliza en agua, que se duplicará para 2040 debido al aumento en el servicio de aguas residuales y la desalinización, particularmente en las economías emergentes (Siddiqi y Anadon, 2011). Se estima que para 2040, casi el 16% de la energía eléctrica total en Oriente Medio se consumirá en el sector del agua (Brears, 2018).

Cada vez más, la producción de energía afecta la calidad del agua a través de la contaminación por fluidos que contienen contaminantes o la alteración física del medio ambiente natural. Además, el agua que se usa para enfriar en las centrales eléctricas a menudo se devuelve a los ríos o lagos a alta temperatura, lo que disminuye el contenido de oxígeno en el agua y causa contaminación térmica y daña los ecosistemas (IEA, 2012) (GWP, 2014). La construcción de presas y embalses para la generación de electricidad también puede afectar la calidad del agua, lo que a su vez impacta en los ecosistemas acuáticos al alterar las temperaturas que pueden dañar los ecosistemas. En la **Tabla 1** se muestran los riesgos e impactos del nexo agua y energía.

Tabla 1. Riesgos e impactos del nexo agua-energía / energía-agua. (IRENA, 2015)

	Riesgos	Impactos
Riesgos relacionados con el agua	Cambios en la disponibilidad y la calidad debido a razones naturales o humanas.	Disminución de la disponibilidad de suministro y dependencia de formas de generación más caras.

para la seguridad energética		• Posibilidad de precios económicos del agua que aumentan los costos de producción de energía. • Disminución de la disponibilidad de agua para las etapas de extracción y procesamiento de combustibles que conducen a una producción reducida
	Aumento de la demanda de energía para la producción, el tratamiento y la distribución de agua.	Tensiones en el sistema energético y eficiencias reducidas de diferentes perfiles de demanda de agua y energía.
Riesgos relacionados con la energía para la seguridad hídrica	• Acceso limitado o poco confiable a energía asequible para extraer agua • Reasignación de recursos hídricos de otros usuarios finales a la energía	• Interrupción en el suministro de agua a los usuarios finales o desvío de recursos de otras actividades básicas, por ejemplo, la agricultura. • Cambios en los costos de suministro de agua debido a los costos fluctuantes de los insumos de energía.
	Contaminación de los recursos hídricos por procesos de extracción y transformación de energía	Los recursos hídricos, incluida el agua potable, se contaminan y requieren un tratamiento adicional.

6.3.2 Agua y Alimentos

6.3.2.1 Agua-Alimentos

Debido al aumento de la población mundial y, por lo tanto, al crecimiento del consumo de alimentos, para 2050, se necesita un aumento del 60% en el suministro de alimentos para satisfacer la demanda mundial, lo que provocará un crecimiento del 11% en el consumo de agua en la agricultura. Esto dará lugar a que el volumen mundial de agua extraída para riego aumente de 2,600 millones de kilómetros cúbicos en 2005-2007 a 2,900 millones de kilómetros cúbicos en 2050 (FAO WWC, 2015). Este crecimiento de la demanda de agua ejercerá presión sobre los sectores intensivos en agua para encontrar suministros alternativos (Brears, 2018).

La calidad y la cantidad de agua están estrechamente relacionadas con la producción y el consumo de alimentos. El agua es vital para la fotosíntesis y los productos de origen animal que se necesitan directamente para la bebida de los animales e indirectamente para producir alimentos para los animales. El agua también es importante para el procesamiento, envasado y transporte de alimentos (Lapidou et al., 2017).

En el mundo, la agricultura requiere el 69% de las extracciones de agua dulce, incluidas las aguas subterráneas y superficiales, mientras que el 19% es utilizado por el sector industrial y

el 12% para uso municipal. Las estadísticas no son las mismas en todo el mundo. En Europa, los sectores agrícola, industrial y municipal representan el 21%, el 57% y el 22%, respectivamente. El sistema alimentario se puede dividir en tres grupos que son la producción primaria de alimentos (cultivos, animales y pescado), la producción secundaria de alimentos (procesamiento industrial) y el consumo de alimentos (Lapidou et al., 2017).

6.3.2.2 Alimentos-Agua

El aumento de la producción agrícola afectará la calidad de los recursos hídricos debido a la contaminación de fuentes difusas. Los problemas clave incluyen la escorrentía de sedimentos que causa problemas de sedimentación; la escorrentía de nutrientes con nitrógeno y fósforo como contaminantes clave que se encuentran en la escorrentía agrícola que se han aplicado a las tierras agrícolas de varias maneras, incluso como fertilizante, abono animal y aguas residuales municipales; escorrentía microbiana del ganado o uso de excrementos como fertilizante; y escorrentía química de pesticidas, herbicidas y otros agroquímicos que contaminan las aguas superficiales y subterráneas (UN-Water, 2015) (Schuster-Wallace y Sandford, 2015).

El riego puede provocar salinidad, ya que todo tipo de agua contiene algunas sales disueltas (Artoli et al., 2017), la salinidad causa el aumento de las aguas subterráneas salinas y la acumulación de sal en la superficie del suelo en las áreas irrigadas (Podmore, 2009) (NSW, 2017). Para reducir la salinidad en el área, los agricultores se han vuelto más dependientes de fertilizantes, pesticidas y equipos de riego para aumentar el rendimiento de sus cultivos, sin embargo, esto ha llevado a un mayor deterioro de la calidad y fertilidad del suelo. Además, ha aumentado los costos laborales, así como los gastos de fertilizantes y pesticidas (Khanom, 2016).

El uso extravagante de nutrientes para la producción de alimentos dará lugar a la proliferación de algas que crean zonas de bajo oxígeno disuelto. La eutrofización afectará los gastos de tratamiento del agua y puede hacer que la fuente de agua no sea consumible para los humanos (Lapidou et al., 2017). La pesca y la acuicultura requieren agua para los estanques y para mantener el agua fresca. Los alimentos para peces y los productos de desecho de la pesca aumentan los nutrientes del agua, lo que conduce a un crecimiento excesivo de algas y esta

materia aumenta la demanda de oxígeno (Laspidou et al., 2017). En la **Tabla 2** se presentan los riesgos e impactos entre el agua y los alimentos.

Tabla 2. Riesgos e impactos dentro del nexo agua-alimentos / alimentos-agua (IRENA, 2015)

	Riesgos	Impactos
Riesgos relacionados con el agua para la seguridad alimentaria	Mayor variabilidad en la disponibilidad de agua debido a tendencias climáticas y no climáticas	Cambios en la oferta de productos alimenticios que conducen a una mayor volatilidad de los precios, agravada por la concentración regional de las actividades de producción de alimentos
	Impacto de la calidad del agua en la producción y el consumo de alimentos	La utilización de agua de mala calidad a lo largo de las diferentes etapas de la cadena de suministro de alimentos puede tener impactos negativos, por ejemplo, la degradación del suelo, la acumulación de contaminantes dentro de la cadena alimentaria.
Riesgos relacionados con los alimentos para la seguridad hídrica	Impactos de las actividades agrícolas en los recursos hídricos	El uso de insumos externos para la agricultura y la producción de alimentos puede conducir a la contaminación del agua que afecta a todos los usuarios, humanos y naturales.
	Inversión extranjera directa agrícola mal regulada	El aumento del arrendamiento de tierras agrícolas, cuando está mal regulado, puede llevar a un mayor uso de los recursos hídricos locales con posibles impactos socioeconómicos locales.
	Sobreutilización de los recursos hídricos debido a ambiciones de seguridad alimentaria	La búsqueda de las ambiciones de seguridad alimentaria puede afectar los recursos hídricos, lo que lleva al agotamiento de las reservas de agua dulce.

6.3.3 Energía y Alimentos

6.3.3.1 Energía-Alimentos

El sector alimentario representa actualmente alrededor del 30% del consumo mundial de energía (FAO, 2014). El consumo de energía en la sección de agricultura es dividido en dos categorías en uso de energía directo e indirecto, siendo la energía directa el combustible o la electricidad que se utiliza para impulsar las actividades agrícolas y la energía indirecta se refiere a los fertilizantes, productos químicos y otros insumos agrícolas producidos fuera del sitio. Por lo general, la mayor parte de la energía utilizada se encuentra en operaciones directas (Hitaj y Suttles, 2016).

La cantidad total y la forma de energía consumida varían según el producto principal de una granja. Por ejemplo, la producción de algodón requiere mayores cantidades de electricidad para operar las bombas de riego, mientras que la producción de trigo de tierras secas no lo hace (Hitaj y Suttles, 2016). Se requiere energía para el funcionamiento de las bombas de

agua subterránea. Por ejemplo, en Arabia Saudita, la energía consumida en el bombeo de aguas subterráneas comprende menos del 10% del total de insumos energéticos para la producción de alimentos; sin embargo, una transición a agua desalinizada o agua salobre aumentará significativamente el porcentaje de energía consumida debido al tratamiento adicional requerido (Grindle et al., 2015). Los fertilizantes (nitrógeno, fosfato y potasio) y plaguicidas, fungicidas y herbicidas químicos, que se utilizan para aumentar la producción de alimentos en todas las regiones del mundo, requieren energía en su proceso de producción, distribución y transporte y debido a que la producción actual de fertilizantes nitrogenados se basa en la energía de combustibles fósiles, los aportes de fertilizantes nitrogenados contribuirán significativamente a las emisiones totales de gases de efecto invernadero de la producción agrícola (Tallaksen et al., 2015). Los fertilizantes constituyen el mayor de estos insumos energéticos para la agricultura, mientras que los plaguicidas son el insumo agrícola más intensivo en energía (por kg de producto químico) (FAO, 2000).

También se requiere energía para producir, transportar y distribuir alimentos. El aumento de las redes de transporte, las empresas transnacionales y las cadenas de suministro y los mercados minoristas en crecimiento significan una gama cada vez mayor de alimentos de todo el mundo que suele estar disponible en las tiendas durante todo el año (Hoolohan et al., 2016).

6.3.3.2 Alimentos-Energía

La demanda de bioenergía moderna está aumentando para su uso en transporte, calefacción y electricidad. Los biocombustibles pueden proporcionar acceso a la energía para las comunidades privadas de energía y sin conexión a la red. Cuando los biocombustibles reemplazan la tradicional combustión ineficiente de biomasa, la contaminación del aire interior y la mala salud asociada disminuyen (Ben-Iwo et al., 2016). Finalmente, los biocombustibles reducen las emisiones de gases de efecto invernadero al reemplazar los combustibles fósiles en el transporte y otros usos. Sin embargo, la disponibilidad de tierra es un factor limitante en la producción de biocombustibles, debido a esto en los últimos años, los agricultores se enfrentan al debate sobre qué tierras agrícolas deben utilizarse para cultivar cultivos alimentarios o cultivos para biocombustibles (Hoff, 2011). Como tal, los biocombustibles han sido criticados por causar inseguridad alimentaria (**Tabla 3**). El maíz,

por ejemplo, es una importante materia prima para biocombustibles en los Estados Unidos, además de ser un cultivo alimenticio básico en muchos países de América del Sur y África. En 2007, la Ley de Seguridad e Independencia Energética de EE. UU. Requirió la producción de 36 mil millones de galones de biocombustibles para 2022. Este aumento en la producción de biocombustibles llevó a que los precios mundiales de los alimentos aumentaran un 7% (Baier et al., 2009).

Tabla 3. Riesgos e impactos dentro del nexo energía-alimentos / alimentos-energía

	Riesgos	Impactos
Riesgos relacionados con la energía para la seguridad alimentaria	La dependencia de los combustibles fósiles aumenta la volatilidad de los precios de los alimentos	• Dependencia de combustibles fósiles de aguas arriba (por ejemplo, producción) y aguas abajo (por ejemplo, transporte) para la cadena de suministro de alimentos • La volatilidad de los precios y la escasez de suministro de insumos energéticos que generan riesgos económicos y físicos en la cadena de suministro de alimentos • Impactos sociales, ambientales y de salud de los métodos tradicionales de cocción con biomasa
	Posibles compensaciones entre la producción de bioenergía y los cultivos alimentarios	Asignación de productos agrícolas para la producción de bioenergía con posibles impactos en los precios de los alimentos
	Riesgo de la producción de energía sobre la disponibilidad de alimentos	Posibles impactos negativos de las tecnologías energéticas, por ejemplo, la energía hidroeléctrica en la producción de alimentos
Riesgos relacionados con los alimentos para la seguridad energética	El aumento general de la producción de alimentos y el cambio de dietas aumentan la demanda de energía a lo largo de la cadena de suministro de alimentos	La creciente demanda de energía en la agricultura puede ejercer presión sobre el sistema energético, especialmente en áreas con el potencial de expandir la agricultura de regadío con agua bombeada.
	La calidad y la asequibilidad del suministro de energía pueden depender de la disponibilidad de materia prima	En mezclas de energía con bioenergía, la calidad y asequibilidad de la materia prima basada en cultivos puede afectar el suministro de energía.

6.4 Presiones del nexo WEF

Los impactos de las presiones del nexo del WEF se resumen en la **Tabla 4**. Como tal, identificar las interacciones entre los sectores del nexo y mejorar su eficiencia se considera

una estrategia de beneficio mutuo para el bienestar humano y la sostenibilidad ambiental para las generaciones actuales y futuras (Ringler et al., 2013). Estas interacciones son:

- Interdependencias: los sistemas dependen unos de otros;
- Restricciones: compensaciones entre sistemas; por ejemplo, una mayor demanda de alimentos aumentará la cantidad de agua extraída, reduciendo la disponibilidad de agua para otros usuarios, por ejemplo, la generación de energía.
- Sinergias: beneficios compartidos para los sistemas; por ejemplo, aumentar la eficiencia del agua y la energía y reducir el desperdicio de alimentos puede reducir las presiones del nexo del WEF en general (FAO, 2014).

Tabla 4. Impacto de los riesgos relacionados con las presiones del nexo del WEF

	Impactos directos	Impactos indirectos
Impacto en los gobiernos	• Estancamiento del crecimiento económico • La inestabilidad política • Rendimientos agrícolas reducidos • Amenazas a la seguridad energética	• Aumento de los costos sociales por la pérdida de empleo e ingresos • Potencial conflicto por recursos naturales escasos
Impacto en la sociedad	• Aumento de los niveles de inseguridad alimentaria • Aumento de los niveles de degradación ambiental. • Escasez de alimentos y agua • Malestar social	• Presiones migratorias • Recursos hídricos irreparablemente dañados • Pérdida de medios de vida
Impacto en el negocio	• Restricciones de exportación • Aumento de los precios de los recursos • Volatilidad de los precios de las materias primas • Restricciones de agua y energía	• Oportunidades de inversión perdidas

6.5 Importancia de los Objetivos de Desarrollo Sostenible (ODS)

Los Objetivos de Desarrollo Sostenible (ODS) o en inglés “Sustainable Development Goals (SDG)” (**Figura 1**) representan el marco global más comprehensivo para abordar los desafíos interconectados que enfrenta la humanidad. Como se menciona en la introducción, estos 17 objetivos adoptados en 2015 buscan "erradicar la pobreza, hambre y discriminación, disminuir el consumo de recursos no renovables y proteger el planeta" (United Nations, 2023). Su relevancia radica en su enfoque holístico que integra las dimensiones económica, social y ambiental del desarrollo, reconociendo que estos aspectos están intrínsecamente

relacionados. La implementación efectiva de los ODS requiere comprender sus complejas interrelaciones, ya que el progreso en un objetivo puede influir positiva o negativamente en otros (Scherer et al., 2018). Particularmente, el sector alimentario emerge como un eje central, dado que los sistemas alimentarios impactan directamente en el consumo energético (ODS 7), uso del agua (ODS 6), cambio climático (ODS 13) y bienestar humano (ODS 3) (Garcia-Garcia et al., 2021).



Figura 1. Objetivos de desarrollo sostenible

6.6 El Nexo Agua-Energía-Alimentos en los ODS

El nexo agua-energía-alimentos (WEF por sus siglas en inglés) ejemplifica perfectamente la interdependencia de los ODS. Como señala la FAO (2018), la sostenibilidad de los sistemas alimentarios es un elemento central para el logro del desarrollo sostenible debido a sus múltiples interconexiones con otros objetivos. La producción agrícola requiere grandes cantidades de agua (vinculado al ODS 6) y energía (ODS 7), mientras que al mismo tiempo contribuye significativamente a las emisiones de gases de efecto invernadero (ODS 13) (Saxena et al., 2018). Por ejemplo, se estima que la agricultura representa el 70% del consumo global de agua dulce y cerca del 30% del consumo energético mundial (Galanakis, 2022). Esta relación simbiótica se vuelve más crítica ante los desafíos del cambio climático, donde alteraciones en los patrones de precipitación afectan tanto la disponibilidad hídrica como la productividad agrícola (Duchenne-Moutien & Neetoo, 2021; Muluneh, 2021).

Además, como destacan Kraj y Smol (2023), las prácticas agrícolas intensivas han contribuido significativamente a las emisiones de GEI mediante la deforestación y el uso excesivo de fertilizantes sintéticos, creando un círculo vicioso que amenaza la seguridad alimentaria (ODS 2) y la sostenibilidad ambiental (ODS 15).

La gestión integrada de este nexo es fundamental para lograr sinergias entre los ODS. Como demuestran los hallazgos de este estudio, existe una fuerte correlación positiva entre el ODS 6 (agua limpia) y el ODS 2 (hambre cero), así como entre el ODS 7 (energía asequible) y el ODS 9 (industria e innovación). Sin embargo, también se identifican interrelaciones significativas, particularmente entre el ODS 12 (producción responsable) y el ODS 9, lo que refleja los desafíos de conciliar desarrollo industrial con sostenibilidad ambiental. Estos hallazgos coinciden con lo planteado por la ONU (2023a) sobre cómo los países desarrollados tienden a tener mayores huellas materiales pero menores eficiencias en el manejo de recursos. La implementación de enfoques circulares en los sistemas alimentarios, como el aprovechamiento de subproductos agrícolas para obtener compuestos bioactivos (Matharu et al., 2016) o energía renovable (Arzami et al., 2022), representa una estrategia prometedora para optimizar este nexo. Como concluye Galanakis (2023), solo mediante soluciones sistémicas que consideren estas interconexiones podremos construir sistemas alimentarios resilientes capaces de enfrentar crisis simultáneas como pandemias, conflictos geopolíticos y cambio climático.

6.7 Importancia de la Planificación Energética en Sistemas con Alta Participación de Energías Renovables

La planificación energética se ha convertido en un pilar fundamental para la transición hacia sistemas eléctricos sostenibles, particularmente en contextos con alta participación de energías renovables variables como la eólica y solar. La naturaleza intermitente de estas fuentes energéticas plantea desafíos significativos para la estabilidad y eficiencia económica de las redes eléctricas (Li et al., 2024). Este tipo de planificación requiere un enfoque integral que combine modelos de inversión a largo plazo para la expansión de capacidad con análisis detallados de operación a corto plazo, considerando aspectos como las limitaciones de rampa,

capacidad de almacenamiento y flexibilidad del sistema (Lara et al., 2018; Islam y Roy, 2023).

La selección adecuada de períodos representativos emerge como una herramienta crucial en este proceso, permitiendo simplificar la complejidad temporal sin sacrificar la representatividad de los patrones de generación y demanda (Helistö et al., 2020). Diferentes metodologías, desde algoritmos de agrupamiento hasta enfoques combinatorios, ofrecen variados equilibrios entre precisión y viabilidad computacional (Tejada-Arango et al., 2018). La elección entre estos métodos debe considerar cuidadosamente las características específicas del sistema analizado, incluyendo su composición tecnológica, patrones de demanda y recursos renovables disponibles.

Una planificación energética efectiva debe además incorporar dimensiones espaciales, analizando las interconexiones entre regiones y las particularidades locales de generación y consumo (Kotzur et al., 2021). Este enfoque multidimensional resulta particularmente relevante en sistemas como el mexicano, donde la diversidad geográfica y climática impacta significativamente en los perfiles de generación renovable (SENER, 2018). La integración de estos elementos permite diseñar sistemas eléctricos más resilientes, capaces de manejar tanto la variabilidad natural de las renovables como eventos extremos, al tiempo que se optimizan los costos y se minimiza el impacto ambiental.

6.8 Aprendizaje automático

La inteligencia artificial (IA) consiste en que la máquina (computadora) actúa y toma decisiones basándose en un conjunto de datos de entrada y en las relaciones descubiertas entre los datos. Un subcampo de la IA es el aprendizaje automático (ML), ya que la IA utiliza algoritmos de ML, además de big data y ciencia de datos para determinar cómo tomar decisiones en función de los datos, patrones y relaciones cambiantes. Por lo que la IA puede usar una o varias técnicas de ML que aprenden y mejoran en varias tareas relacionadas o independientes.

Arthur Samuel en 1959 introdujo por primera vez el término "aprendizaje automático" como un campo de la informática que brinda a las computadoras la capacidad de aprender sin ser

programadas explícitamente para hacerlo. Actualmente las técnicas de ML han resurgido debido a la generación y disponibilidad de grandes conjuntos de datos; a los grandes avances en el poder de cómputo y en la capacidad de almacenamiento, así como el desarrollo de nuevos algoritmos. Los algoritmos de ML incluyen conceptos de probabilidad y estadística (Subasi, 2020).

El proceso de aprendizaje automático inicia al introducir los datos para llevar a cabo el entrenamiento del algoritmo (aprendizaje), con el fin de construir un modelo y mejorar su comportamiento a través de parámetros autoajustables. El ML nos permite analizar datos de diferentes fuentes. Los algoritmos de ML constan de un conjunto de datos, una función objetivo, un método de optimización y un modelo parametrizado. En donde la función objetivo define el criterio de optimización relacionando los datos con los parámetros del modelo. La optimización busca los parámetros del modelo que mejor representen los datos proporcionados (Kollmannsberger et al., 2021). Por lo que las técnicas de ML se basan en una combinación iterativa de estadísticas y minimización de errores, aplicadas y combinadas en diversos grados. El gran número de iteraciones impide los cálculos de manera manual por lo que con los avances en la capacidad de cómputo recientemente están ganando gran importancia.

El ML tiene una gran variedad de algoritmos y la elección de un algoritmo depende de la naturaleza de la tarea, que puede ser regresión, clasificación y agrupación. El modelado basado en técnicas de ML ofrece buena precisión por lo que se ha aplicado en varias áreas de estudio ya que extrae conocimiento a partir de datos. Los modelos de aprendizaje automático han mostrado practicidad y un buen desempeño en casos donde el modelo determinista es muy costoso computacionalmente o inexistente para resolver el problema (El Boucheffry & de Souza, 2020). Un gran atractivo de las técnicas de ML es su capacidad de funcionar bien en situaciones complejas del mundo real.

6.8.1 Proceso de Aprendizaje Automático

El proceso de aprendizaje automático se parte de una pregunta de investigación que se pueda resolver utilizando uno o varios algoritmos de ML. Se recopilan los datos y después se preprocesan. Posteriormente los datos se transforman en la ingeniería de características para hacerlos adecuados para las técnicas de ML. En donde se construye, entrena y evalúa el

modelo de ML. Y finalmente se interpretan los resultados para generar conocimiento, esto se puede observar en la **Figura 2**.




Figura 2. Proceso del aprendizaje automático

6.8.2 Escalado

Regularmente un conjunto de datos contiene características con diferentes escalas (unidades y rango), pero la mayoría de los algoritmos de aprendizaje automático requieren que los datos estén en la misma escala con el fin de modelar correcta y eficazmente. Ya que si dentro del conjunto de datos hay variables (características) con valores más grandes estas dominaran, sin embargo, es necesario garantizar que cada característica contribuya por igual. Debido a que un desequilibrio en las ponderaciones de las variables puede resultar en un modelo inestable y con un mayor error de generalización (Gupta y Sehgal, 2021). Por tal motivo la solución a este problema consiste en escalar las variables de entrada en una escala similar, sin alterar las diferencias en los rangos de valores y conservando la información de los datos.

El escalado es una etapa importante en el preprocesamiento de datos, los cuales posteriormente se introducirán en algoritmos de aprendizaje automático. Los dos métodos más utilizados son la normalización (mínima-máxima) y estandarización (puntuación z) que buscan ajustar y transformar los datos.

6.9 Tipos de aprendizaje automático

Actualmente existen diferentes tipos de técnicas de aprendizaje automático que se utilizan para diferentes fines. Por lo cual dividir las técnicas de aprendizaje automático por el estilo de aprendizaje ayuda en la selección del enfoque más adecuado para una resolver una tarea específica. Las cuatro categorías son: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semisupervisado y aprendizaje reforzado.

No hay una técnica de aprendizaje automático que funcione bien para todos los problemas debido a que cada técnica de ML tiene diferente enfoque con sus propias características y funcionalidades, pero todas siguen un proceso iterativo. Además, cada tarea o problema a resolver tiene sus propias peculiaridades, por lo cual se debe seleccionar la técnica de ML que se adapte a la tarea. La selección de la técnica de ML puede ser fácil o muy compleja, ya que hay varios factores a considerar, por ejemplo, la estructura y el tamaño del conjunto de datos, la capacidad y el tiempo computacional disponible, así como el tipo de tarea a resolver. A continuación, abordaremos las categorías de aprendizaje automático supervisado y aprendizaje automático no supervisado.

6.9.1 Aprendizaje automático supervisado

El aprendizaje supervisado requiere un conjunto de datos etiquetados, es decir que cada entrada (X) (vector de características o variables) esta etiquetada o asignada a una variable de respuesta (Y) (también se le conoce como variable de salida, dependiente o predictora). Por lo tanto, se tiene que conocer previamente los valores de la variable de respuesta y tener completos los pares entrada-salida. En los algoritmos de aprendizaje supervisado el objetivo es aprender la función optima que capture la relación entre la entrada (datos explicativos) y la variable de respuesta. El algoritmo de aprendizaje supervisado entrena un modelo utilizando múltiples ejemplos y recibiendo retroalimentación de que tan cerca esta la predicción con el valor objetivo con el fin de mejorar la precisión. El modelo entrenado se utiliza posteriormente para predecir la salida de nuevos datos de entrada, esto proceso se muestra con la **Figura 3**.




Figura 3. Proceso de Aprendizaje supervisado

Los algoritmos de clasificación y de regresión son dos tipos de aprendizaje supervisado utilizados para desarrollar modelos predictivos. Dependiendo de la naturaleza de la variable de respuesta, si es una variable discreta o categórica (por ejemplo 0,1,2,3... o verdadero/falso, etc.) es un problema de clasificación; mientras que si es una variable continua (por ejemplo 0.15, 12.4, valores de temperatura o presión, etc.) es un problema de regresión. Los algoritmos de aprendizaje supervisado son similares, pero difieren en la evaluación del error de la predicción. En el caso de la clasificación el error de estimación es el porcentaje de etiquetas identificadas incorrectamente, a través de contar el número de etiquetas correctas. En el caso de la regresión se considera el error cuadrático medio (el promedio de un conjunto de errores) de la estimación, comparando las predicciones con los verdaderos valores objetivo, también se pueden utilizar otras métricas.

El aprendizaje supervisado es un proceso iterativo en el que los parámetros se optimizan para minimizar la diferencia entre las predicciones de salida y el valor objetivo. La predicción de series de tiempo es un ejemplo especial de regresión, en donde se estima un valor futuro mediante el análisis de los valores pasados y un valor actual (Jo, 2021). Existen varios tipos de algoritmos de aprendizaje supervisado y cada uno de ellos tiene sus ventajas y desventajas.

6.9.2 Aprendizaje profundo

El aprendizaje profundo (deep learning) es un subcampo del aprendizaje automático (machine learning) que se basa en redes neuronales artificiales con múltiples capas, lo que permite la extracción y transformación de características de datos de manera jerárquica y automatizada. Su relación con el aprendizaje supervisado es fundamental, ya que muchas de las aplicaciones más exitosas del aprendizaje profundo, como el reconocimiento de imágenes, el procesamiento del lenguaje natural y la predicción de series temporales, utilizan este paradigma de entrenamiento. En el aprendizaje supervisado, el modelo se entrena con un conjunto de datos etiquetados, donde cada ejemplo de entrada está asociado a una salida correcta conocida. Durante el entrenamiento, el algoritmo ajusta los pesos de la red neuronal mediante técnicas como el descenso de gradiente y la retropropagación, minimizando una función de pérdida que mide la discrepancia entre las predicciones del modelo y las etiquetas reales. La capacidad de las redes profundas para aprender representaciones complejas a partir de grandes volúmenes de datos las hace especialmente adecuadas para tareas supervisadas donde los patrones subyacentes son difíciles de capturar con modelos tradicionales. Las LSTM (Long Short-Term Memory) en español Memoria a Corto Plazo y las GRU (Gated Recurrent Units) en español Unidad Recurrente con Puertas, son arquitecturas de redes neuronales recurrentes (RNN) diseñadas para capturar dependencias temporales en secuencias de datos, superando las limitaciones de las RNN tradicionales. Se utilizan técnicas de aprendizaje profundo (deep learning) para determinar la proyección de producción y demanda de las fuentes. Para el desarrollo de modelos de pronóstico basados en aprendizaje profundo, se emplea un conjunto de datos históricos o una serie temporal $[x_1, x_2, \dots, x_t]$, los cuales se utilizan para encontrar un modelo f que permita predecir valores futuros. Esto puede expresarse en la **Ecuación 1**.

$$[x_{t+1}, x_{t+2}, \dots, x_{t+h}] = f(x_t, x_{t-1}, \dots, x_{t-(k-1)}) \quad (1)$$

donde k es igual al número de valores pasados utilizados como ventana histórica y h es el número de valores futuros a predecir (horizonte de predicción).

6.9.2.1 Long Short-Term Memory (LSTM)

Las unidades LSTM se introdujeron por primera vez en 1990 y son capaces de recordar patrones de manera selectiva durante un largo período de tiempo, superando el rendimiento de las RNN tradicionales. En las LSTM, se introducen celdas de memoria de naturaleza recursiva, lo que permite almacenar información previa en ellas, así como estructuras llamadas puertas que funcionan como elementos multiplicativos adaptativos. La estructura general de la LSTM se muestra en la **Figura 4** y se describe de la **Ecuación 2 al 7**.

$$f_t = \sigma(W_{xf}X_t + W_{hf}h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_{xi}X_t + W_{hi}h_{t-1} + b_i) \quad (3)$$

$$o_t = \sigma(W_{xo}X_t + W_{ho}h_{t-1} + b_o) \quad (4)$$

$$\tilde{c}_t = \tanh(W_{xc}X_t + W_{hc}h_{t-1} + b_c) \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (6)$$

$$h_t = o_t \odot \tanh(c_t) \quad (7)$$

La LSTM puede interpretarse como el mantenimiento de una celda de memoria C_t , que se restablece, escribe y lee según la puerta de olvido f_t , la puerta de entrada i_t y la puerta de salida O_t , que varían con el tiempo. La puerta de entrada (i_t) controla la cantidad de información actual en la unidad LSTM, la puerta de olvido (f_t) selecciona información del tiempo anterior y retiene de manera adaptativa parte de la información en el tiempo actual, y la puerta de salida (O_t) controla la cantidad de información actual que se utiliza como salida. La función de activación sigmoide restringe las salidas de las puertas a valores entre 0 y 1; por lo tanto, las tres puertas pueden cerrar completamente el flujo de información (0) o permitir un flujo completo de información (1). Además, X_t es el vector de entrada a las unidades en el paso de tiempo t , W y b son las matrices de pesos y los vectores de sesgo. $\tilde{c}_t$ es un valor intermedio durante el cálculo y h_t es la salida en el tiempo actual (nuevo estado oculto).




Figura 4. Redes LSTM y GRU

6.9.2.2 Gated Recurrent Units (GRU)

La unidad GRU se propuso en 2014 como una alternativa a la LSTM, pero con una estructura más simple, ya que realiza menos operaciones vectoriales; esto hace que su proceso de entrenamiento sea más rápido. La GRU opera de manera similar a la LSTM, con estructuras de puertas que deciden qué información debe olvidarse o retenerse. La GRU utiliza dos puertas: la puerta de actualización (Z_t), que define cuánta información se olvidará y qué nueva información se agregará a una nueva entrada, y la puerta de reinicio (r_t), que define qué información a largo plazo o pasada se olvidará. La estructura de la GRU se presenta en la **Figura 4** y se describe matemáticamente a través de las **Ecuaciones 8** a la **11**.

$$z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (8)$$

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (9)$$

$$\tilde{h}_t = \tanh(W_{xh}x_t + W_{hh}(r_t \odot h_{t-1}) + b_h) \quad (10)$$

$$h_t = (1 - z_t)h_{t-1} + z_t \odot \tilde{h}_t \quad (11)$$

6.9.3 Aprendizaje automático no supervisado

En el aprendizaje no supervisado se utilizan datos de entrada que no están etiquetados (es decir no tienen una variable de respuesta), ya que en muchas ocasiones no es fácil etiquetar los datos, debido a que hay demasiados datos o no se sabe que datos pertenecen a que etiqueta. El objetivo del aprendizaje no supervisado es descubrir estructuras, relaciones y patrones subyacentes a partir de los datos de entrada no etiquetados, como se muestra en la **Figura 5**. Lo que realiza la importancia de las técnicas de aprendizaje no supervisado es que la mayoría de los datos generados alrededor del mundo no están etiquetados y al aplicar estas

técnicas se pueden crear nuevos conocimientos que ayuden a incrementar ganancias en muchas industrias.




Figura 5. Proceso de aprendizaje no supervisado

Los algoritmos de agrupamiento y de reducción de dimensionalidad son las aplicaciones principales del aprendizaje automático no supervisado. Los resultados de los algoritmos de aprendizaje no supervisado se visualizan utilizando herramientas de análisis visual (Edgar y Manz, 2017).

El agrupamiento es la técnica más común de aprendizaje automático no supervisado, en donde se agrupan muestras de datos a partir de similitudes entre las características y sin ningún conocimiento previo de las relaciones de los datos. Cada grupo formado tiene sus propias especificaciones. La agrupación se aplica a conjuntos de datos con pocas o muchas características (dimensiones) que no se visualizan tan fácilmente. Los resultados del agrupamiento dependen de la métrica de similitud o disimilitud utilizada. Para evaluar las técnicas de agrupamiento se utiliza la dispersión dentro del grupo. El agrupamiento es útil para clasificar (etiquetar) datos no etiquetados, porque etiquetar manualmente puede ser una tarea agobiante si son demasiados datos, ya que no siempre es fácil identificar las clases. Existen muchos algoritmos de agrupación, pero no hay uno solo que funcione adecuadamente para todos los tipos de datos. Debido a que los datos pueden tener ruido, bajas o altas dimensiones (características), densidad variable y características jerárquicas. Cada algoritmo de agrupamiento tiene sus pros y contras dependiendo del tipo de datos de entrada.

6.9.3.1 Clustering K-means

El algoritmo K-means es uno de los métodos de clustering más utilizados. Este algoritmo tiene como objetivo identificar un cierto número de centroides y asignar cada punto de datos al cluster más cercano. El algoritmo de clustering K-means se puede describir de la siguiente manera:

1. Dado un determinado número de clústeres k , se seleccionan aleatoriamente los centroides iniciales $m'_1, \dots, m'_{kd}$, donde $t=0$.
2. A cada punto x_i del conjunto de datos X en el espacio d-dimensional R_d , es decir, $X = \{x_i | x_i \in R_d, i = 1, 2, \dots, n\}$, se le calcula su distancia respecto a cada centroide m'_{kd} . Utilizando la distancia euclidiana como medida de similitud que se calcula con la **Ecuación 12**.

$$d(x_{id}, m_{kd}) = \sqrt{\sum_d (x_{id} - m_{kd})^2} \quad \forall i, \forall k \quad (12)$$

3. Posteriormente se asigna cada x_i al grupo C_k con la distancia más pequeña respecto a su centroide m_k .
4. Se actualiza el centroide de cada grupo con la media aritmética de los puntos x_i correspondientes al grupo, como se muestra en la **Ecuación 13**.

$$m_k^{t+1} = \frac{1}{|C_k^t|} \sum_{x_i \in C_k^t} x_i \quad \forall k \quad (13)$$

Se repiten los pasos del 2 al 4 hasta que se satisfaga una condición de paro, que en nuestro caso fue la suma de distancias euclidianas al cuadrado “SED” (**Ecuación 14**) que se adopta como la función objetivo a minimizar. Aunque otra opción puede ser alcanzar un número de iteraciones determinadas.

$$SED = \sum_i \sum_k d(x_i - m_k)^2 \quad (14)$$

7. Metodología general

La metodología general se estructura en **cuatro fases**, correspondientes a cada uno de los trabajos desarrollados en el marco del proyecto, todos ellos articulados bajo un enfoque

interdisciplinario que combina herramientas de aprendizaje automático, evaluación mediante índices compuestos y análisis de sostenibilidad para abordar los desafíos del nexo agua-energía-alimentos (WEF), la planificación estratégica de sistemas energéticos y el análisis del cumplimiento de los Objetivos de Desarrollo Sostenible (ODS). Este enfoque se apoya en la integración de datos históricos, indicadores ambientales y sociales, y técnicas propias de la ingeniería química para generar análisis espaciales, proyecciones temporales y estrategias de gestión sostenible.

Fase 1. Evaluación cuantitativa de la seguridad del nexo WEF y residuos mediante el índice compuesto WEF-Waste (Caso: España)

Esta fase se enfoca en construir y aplicar un índice compuesto que cuantifique la seguridad de los recursos agua, energía, alimentos y residuos sólidos urbanos a través de 13 indicadores. Se aplicó al caso de España en una escala espaciotemporal (2010–2020), permitiendo identificar desigualdades regionales y dinámicas interanuales mediante mapas de calor.

Fase 2. Proyección del nexo WEF mediante redes neuronales profundas (LSTM y GRU)

Se desarrolla un modelo predictivo usando series temporales para proyectar hasta 2050 la disponibilidad y accesibilidad de agua, energía y alimentos. Se emplean técnicas de deep learning (LSTM y GRU), optimizadas mediante el algoritmo Hyperband, para predecir seis indicadores agregados en un índice WEF. Esta fase se aplicó al caso de México.

Fase 3. Clasificación de regiones según vulnerabilidad en el cumplimiento de los Objetivos de Desarrollo sostenible (SDG) mediante clustering

Aquí se integran indicadores del nexo WEF con métricas vinculadas a los Objetivos de Desarrollo Sostenible (ODS). Mediante técnicas de agrupamiento no supervisado (como K-means), se agrupan unidades espaciales según niveles de seguridad, acceso y eficiencia en el uso de recursos, con el fin de identificar zonas críticas y prioritarias para intervención.

Fase 4. Comparación de Métodos para Seleccionar Semanas Representativas en Planificación Energética con Energías Renovables

La última fase compara diferentes métodos para seleccionar semanas representativas (k-means con métrica euclidiana, k-means con DTW y un enfoque combinatorio) con el fin de

simplificar modelos de planificación energética a largo plazo que integran energías renovables variables. Evalúa su precisión para capturar patrones de demanda y generación, así como su impacto en costos, emisiones y decisiones operativas, proponiendo un marco para optimizar esta selección considerando precisión y eficiencia computacional.

A continuación, se abordan las metodologías específicas de cada fase, así como sus resultados.

7.1 Fase 1: Evaluación cuantitativa de la seguridad del nexo WEF y residuos mediante el índice compuesto WEF-Waste (Caso: España)

7.1.1 Metodología

La metodología para evaluar la seguridad de los recursos en España se fundamenta en un marco analítico riguroso que integra trece indicadores clave agrupados en cuatro dimensiones: agua (disponibilidad, independencia, tratamiento y reutilización), energía (disponibilidad, renovables e independencia), alimentos (disponibilidad, independencia, superficie ecológica y desperdicio) y residuos (separación y reutilización). Cada indicador es cuidadosamente normalizado en una escala de 0 a 1 para permitir comparaciones consistentes, y posteriormente se agregan mediante una media ponderada que refleja su importancia relativa en el índice compuesto. El análisis espaciotemporal se visualiza mediante mapas de calor que revelan patrones geográficos y tendencias temporales entre 2010 y 2020, complementado con un análisis de sensibilidad que identifica los indicadores más críticos para la seguridad de recursos en cada comunidad autónoma.

La seguridad del nexo Agua-Energía-Alimentos es un concepto complejo, y abarcar todas sus dimensiones daría lugar a definiciones muy amplias. Por ello, este estudio propone evaluar la seguridad de estos recursos a través de la disponibilidad, un pilar fundamental que se obtiene mediante la producción en la unidad espacial. Otro pilar clave es la estabilidad, que limita las importaciones para fomentar la producción interna y evitar la dependencia externa. En el caso del agua, se considera el nivel de tratamiento y reutilización de aguas residuales. En el sector eléctrico, se involucra la cuantificación de la generación de energía renovable, ya que la diversificación en el suministro energético y la reducción de la dependencia de combustibles importados es un elemento importante para el desarrollo

sostenible. En el sector alimentario, también se consideran el porcentaje de tierra con cultivos orgánicos y el desperdicio de alimentos. Los dos indicadores de residuos sólidos urbanos miden el nivel de separación y reutilización. Los residuos sólidos urbanos se incluyen debido a los riesgos sanitarios, de salud y ambientales que representan. Una gestión sostenible de los residuos es crucial para mejorar el entorno ecológico y la calidad de vida.

El indicador de disponibilidad de agua W_1 se calcula a partir del agua producida, que es la suma del agua superficial, subterránea y otros recursos hídricos procedentes de la desalinización en cada comunidad autónoma, a la que se resta el consumo de agua de la comunidad autónoma, incluyendo el consumo doméstico, económico, agrícola y municipal, y se divide por el agua producida en la comunidad autónoma en el tiempo t como se muestra en la **Ecuación 15**.

$$W_{1,c,t} = \frac{w_{c,t}^{production} - w_{c,t}^{consumption}}{w_{c,t}^{production}} \quad \forall c \in C, t \in T \quad (15)$$

El indicador de independencia hídrica W_2 utiliza el consumo de agua de cada comunidad autónoma y resta el agua importada, es decir, el agua que la comunidad autónoma c adquiere de otras comunidades, y divide esto por el consumo de agua en el tiempo t como se muestra en la **Ecuación 16**.

$$W_{2,c,t} = \frac{w_{c,t}^{consumption} - w_{c,t}^{import}}{w_{c,t}^{consumption}} \quad \forall c \in C, t \in T \quad (16)$$

El indicador de agua tratada W_3 se evalúa con la cantidad de agua residual que se procesa en las plantas de tratamiento en cada comunidad autónoma dividida por el consumo de agua en la comunidad autónoma en el tiempo t como se muestra en la **Ecuación 17**.

$$W_{3,c,t} = \frac{w_{c,t}^{wtreated}}{w_{c,t}^{consumption}} \quad \forall c \in C, t \in T \quad (17)$$

El indicador W_4 de agua reutilizada se calcula con la cantidad de agua tratada por las plantas de tratamiento de aguas residuales que se reutiliza en cada comunidad dividida por el agua consumida en la comunidad en un tiempo dado t como se muestra en la **Ecuación 18**.

$$W_{4,c,t} = \frac{w_{c,t}^{wreused}}{w_{c,t}^{consumption}} \quad \forall c \in C, t \in T \quad (18)$$

El indicador de disponibilidad energética E_1 se calcula con la energía generada en la comunidad autónoma c en el tiempo t menos la energía consumida en la comunidad autónoma y esto se divide por la energía generada como se muestra en la **Ecuación 19**.

$$E_{1,c,t} = \frac{e_{c,t}^{generation} - e_{c,t}^{consumption}}{e_{c,t}^{generation}} \quad \forall c \in C, t \in T \quad (19)$$

El indicador de energía renovable E_2 se evalúa con la energía generada a partir de fuentes renovables dividida por la energía total generada en la comunidad c en el tiempo t como se muestra en la **Ecuación 20**.

$$E_{2,c,t} = \frac{e_{c,t}^{renewable}}{e_{c,t}^{generation}} \quad \forall c \in C, t \in T \quad (20)$$

El indicador de independencia energética E_3 se calcula con el consumo de energía menos la cantidad de energía importada dividida por la energía consumida para cada comunidad autónoma c y tiempo t como se muestra en la **Ecuación 21**.

$$E_{3,c,t} = \frac{e_{c,t}^{consumption} - e_{c,t}^{import}}{e_{c,t}^{consumption}} \quad \forall c \in C, t \in T \quad (21)$$

La **Ecuación 23** representa el indicador de disponibilidad de alimentos F_1 , que es el promedio del cálculo de disponibilidad de alimentos por grupo alimenticio (**Ecuación 22**) que se evalúa con la producción de alimentos por grupo alimenticio g menos el consumo de alimentos por grupo alimenticio g dividido por la producción de alimentos en cada comunidad autónoma c y tiempo t . Los grupos alimenticios son Legumbres, Tubérculos, Hortalizas, Frutas tanto cítricas como no cítricas, Carne, Leche, Huevos y aceite de oliva que están representados por el subíndice g que está dentro del conjunto G .

$$F_{1,c,g,t} = \frac{f_{c,g,t}^{production} - f_{c,g,t}^{consumption}}{f_{c,g,t}^{production}} \quad \forall c \in C, g \in G, t \in T \quad (22)$$

$$F_{1,c,t} = \frac{\sum_{g=1}^G F_{1,c,g,t}}{G} \quad \forall c \in C, t \in T \quad (23)$$

El indicador F_2 de independencia alimentaria se calcula con la producción de alimentos menos las importaciones de alimentos dividido por la producción de alimentos en cada Comunidad Autónoma c y tiempo t como se muestra en la **Ecuación 24**. Para producción e

importaciones se consideran los siguientes grupos alimenticios: legumbres, cereales, tubérculos, hortalizas, frutas cítricas y no cítricas, carne, leche, huevos y aceite de oliva.

$$F_{2,c,t} = \frac{f_{c,t}^{production} - f_{c,t}^{import}}{f_{c,t}^{production}} \quad \forall c \in C, t \in T \quad (24)$$

En la **Ecuación 25**, el indicador F_3 de Superficie Ecológica de Alimentos Orgánicos se evalúa con el área de agricultura ecológica de la comunidad autónoma c entre el área de agricultura ecológica en España en el tiempo t . El indicador F_3 se incluye porque la UE ha establecido un plan de acción ecológico global. A través de él, la Comisión Europea intentará alcanzar el objetivo del Pacto Verde Europeo bajo la estrategia "De la Granja a la Mesa", donde "al menos el 25% de las tierras agrícolas en la UE estarán dedicadas a la agricultura ecológica para 2030" (Comisión Europea, 2023). Donde la agricultura ecológica se define como "un sistema que combina la gestión sostenible de los recursos genéticos, del suelo y del agua, las mejores prácticas en términos de medio ambiente y clima, un alto nivel de biodiversidad, la conservación de los recursos naturales, la exclusión de insumos de síntesis química y la aplicación de altos estándares de bienestar animal, para responder a la demanda expresada por un número creciente de consumidores de productos obtenidos a partir de sustancias y procesos naturales" (MAPA, 2021).

$$F_{3,c,t} = \frac{f_{c,t}^{surface}}{f_t^{totalsurface}} \quad \forall c \in C, t \in T \quad (25)$$

El indicador de desperdicio de alimentos F_4 se calcula como la cantidad de alimentos desperdiciados dividida por la cantidad de alimentos producidos en cada comunidad autónoma c y tiempo t como se muestra en la **Ecuación 26**.

$$F_{4,c,t} = \frac{f_{c,t}^{waste}}{f_{c,t}^{production}} \quad \forall c \in C, t \in T \quad (26)$$

El indicador R_1 de separación de residuos se evalúa con la cantidad de residuos separados entre la cantidad total de residuos generados en cada comunidad autónoma y tiempo t , como se muestra en la **Ecuación 27**.

$$R_{1,c,t} = \frac{r_{c,t}^{separatedwaste}}{r_{c,t}^{totwaste}} \quad \forall c \in C, t \in T \quad (27)$$

El indicador R2 de reutilización de residuos se evalúa con la cantidad de residuos reutilizados y reciclados entre la cantidad total de residuos generados en cada comunidad autónoma y tiempo t (**Ecuación 28**).

$$R_{2,c,t} = \frac{r_{c,t}^{\text{reused waste}}}{r_{c,t}^{\text{totwaste}}} \quad \forall c \in C, t \in T \quad (28)$$

En la **Ecuación 29**, el índice WEF-Waste se calcula con el promedio aritmético de los 13 indicadores en cada comunidad autónoma c y tiempo t ($I_{n,c,t}$). Donde N es el conjunto de indicadores mencionados anteriormente y $\varphi_n = 1/13$ es el peso de cada indicador, que en este caso es un peso equi-proporcional para asignar la misma prioridad a cada indicador (**Ecuación 30**). Es importante señalar que los pesos de los indicadores pueden ser modificados por los tomadores de decisiones según los atributos, restricciones y requisitos de cada caso de estudio específico. Estas modificaciones deben ser acordadas por los tomadores de decisiones, ya sean analistas y/o planificadores gubernamentales, sociedad e industria. Esto debe tener en consideración la ubicación del área y/o caso de estudio, sus limitaciones y requisitos para una gestión eficiente de los recursos con beneficios ambientales y socioeconómicos.

$$\text{WEF-Waste index}_{c,t} = \sum_{n=1}^N \varphi_n \cdot I_{n,c,t} \quad (29)$$

$$\sum_{n=1}^N \varphi_n = 1 \quad (30)$$

Para el cálculo del porcentaje de variación, se utilizó la aproximación lineal representada en la **Ecuación 31**.

$$\% \Delta = \frac{V_1 - V_0}{V_0} \times 100 \quad (31)$$

donde V_1 representa el valor del indicador actual, y V_0 representa el valor del indicador pasado. Los datos que involucran producción y consumo de agua, agua importada de otras comunidades autónomas, agua tratada y agua reutilizada, así como la recolección de residuos separados y su reutilización y/o reciclaje se obtuvieron del Instituto Nacional de Estadística (INE, 2022). Los datos sobre generación y consumo de electricidad, generación a partir de fuentes renovables y electricidad importada se extrajeron de la Red Eléctrica de España (REE, 2022). Los datos sobre producción y consumo de alimentos e importaciones, así como

desperdicio de alimentos y superficie ecológica se obtuvieron del Ministerio de Agricultura, Pesca y Alimentación (MAPA, 2022).

7.1.2 Caso de estudio

España fue seleccionada como caso de estudio en esta investigación por constituir un laboratorio excepcional para analizar los desafíos del nexo agua-energía-alimentos-residuos (WEF-Waste) en contextos mediterráneos industrializados. Tres factores clave justifican esta elección: En primer lugar, su condición de país semiárido con estrés hídrico crónico, donde según el Banco Mundial en 2019 "la relación entre el agua dulce extraída y los recursos renovables disponibles alcanza el 40,18%, situando a España entre los países industrializados con mayor estrés hídrico del mundo". Este dato se complementa con los hallazgos del INE (2022) que indican que "el consumo de agua per cápita en España alcanza los 700 m³/habitante, el tercero más alto de Europa", concentrándose particularmente en agricultura donde, según datos del MAPA (2021), "el riego agrícola representa el 77% del total de extracciones hídricas". En segundo término, su modelo energético dual que combina, según el informe de REE (2022), "una capacidad renovable instalada del 56,7% que generó el 46,7% de la electricidad en 2021", destacando que "la energía eólica aportó el 23,3% de la generación total". Sin embargo, como señala Eurostat (2021), "España mantiene una dependencia del 43,3% de combustibles fósiles importados", evidenciando esta dualidad característica. Finalmente, su posición como potencia agroalimentaria europea donde, según el INE (2021), "España es el segundo país de la UE en superficie agrícola utilizada", destacando en la producción de "cítricos (56,7% del total UE), frutas (19,5%) y hortalizas frescas (25,3%)". No obstante, como advierte el MAPA (2022), "el desperdicio alimentario anual alcanza el 30% de la producción total", mostrando graves ineficiencias en la cadena de valor. Esta combinación única de vulnerabilidades y fortalezas, sumada a las marcadas disparidades regionales entre sus 17 comunidades autónomas, ofrece un marco ideal para evaluar estrategias de gestión integrada de recursos en escenarios de cambio climático.

7.1.3 Resultados

El análisis minucioso del índice WEF-Waste y sus trece indicadores constituyentes revela patrones complejos y multidimensionales en la gestión de recursos esenciales a lo largo del territorio español durante la última década. La **Figura 6**, que presenta la evolución espaciotemporal del índice compuesto, se observa una marcada heterogeneidad regional en el desempeño global del nexo agua-energía-alimentos-residuos. Castilla y León emergen consistentemente como la comunidad autónoma con los resultados más sobresalientes, alcanzando un valor máximo de 0.583 en 2020. Este desempeño excepcional deriva de una combinación virtuosa de factores interrelacionados: una gestión hídrica sostenible enmarcada en el contexto de la cuenca del Duero, caracterizada por sistemas de regulación eficientes y políticas de conservación de acuíferos; una matriz energética diversificada con dominio de fuentes renovables, particularmente eólica e hidroeléctrica; y una potente base agroalimentaria orientada a la autosuficiencia y con creciente enfoque en la producción ecológica.




Figura 6. Mapa de calor que representa el valor del índice WEF-Waste para cada comunidad autónoma de España.

Extremadura (0.571) y la Comunidad Foral de Navarra (0.562) completan el grupo de regiones líderes, beneficiándose de su baja densidad poblacional y abundantes recursos naturales per cápita, así como de modelos de gestión territorial integrada. Estas comunidades demuestran cómo una planificación consciente de las interacciones entre los distintos sectores del nexo puede generar resiliencia sistémica incluso en contextos climáticos desafiantes. En el extremo opuesto del espectro, como se aprecia claramente en la **Figura 6**, Cantabria (0.322), el archipiélago canario (0.341) y la Comunidad de Madrid (0.348) presentan los mayores desafíos estructurales, evidenciando las limitaciones intrínsecas de los modelos de desarrollo intensivo en recursos, ya sea de carácter urbano-metropolitano o turístico-insular.

La evolución temporal del índice WEF-Waste entre 2010 y 2020, representada gráficamente en la **Figura 6**, sigue una trayectoria en forma de U profundamente marcada por los vaivenes de la coyuntura económica nacional. El período 2011-2013 representa el punto más bajo de esta curva, con más del 60% de las comunidades autónomas mostrando un deterioro significativo en sus puntuaciones. Esta regresión coincide temporalmente con los años más severos de la crisis económica española, sugiriendo una relación causal directa entre las restricciones presupuestarias y la capacidad de inversión en infraestructuras críticas para la gestión sostenible de recursos. La posterior recuperación (2016-2020) fue notablemente desigual: mientras comunidades mediterráneas como Andalucía y Murcia experimentaron mejoras sustanciales gracias a programas estratégicos de modernización de regadíos y despliegue acelerado de energías renovables, regiones como Madrid y Canarias permanecieron estancadas en los niveles inferiores del ranking, demostrando la inercia estructural de sus modelos insostenibles de gestión de recursos.

Sector Hídrico: Diagnóstico de una Crisis Estructural con Oportunidades de Mejora

Los indicadores hídricos (W_1 - W_4) presentan algunas de las disparidades más marcadas y preocupantes de todo el estudio. La **Figura 7a**, que muestra la disponibilidad hídrica (W_1), revela de manera contundente que nueve comunidades autónomas, incluyendo todos los grandes núcleos urbanos (Madrid, Barcelona) y las regiones insulares (Canarias, Baleares), mantuvieron valores de cero durante todo el período de estudio, indicando un déficit crónico donde el consumo supera sistemáticamente la disponibilidad renovable. Este patrón de

sobreexplotación se acentúa aún más en la **Figura 7b** (independencia hídrica W_2), donde Aragón emerge como caso paradigmático de dependencia interregional, con valores nulos persistentes entre 2014-2020 debido a su necesidad de importar regularmente más de 200,000 mil m³ anuales de otras cuencas hidrográficas.

Navarra destaca como excepción positiva en la **Figura 7a**, alcanzando un valor máximo de 0.329 en 2014 gracias a su modelo integrado de gestión de la cuenca del Ebro. Este éxito relativo se sustenta en cuatro pilares interrelacionados: 1) programas agresivos de modernización de regadíos que han reducido las pérdidas técnicas a menos del 15%; 2) sistemas innovadores de recarga gestionada de acuíferos que mitigan los efectos de las sequías recurrentes; 3) políticas de reutilización planificada de aguas residuales tratadas; y 4) mecanismos de gobernanza participativa que involucran a todos los usuarios del agua. Este caso demuestra que, incluso en contextos climáticos mediterráneos, es posible alcanzar equilibrios razonables entre demanda y disponibilidad mediante una combinación de innovación tecnológica y gestión adaptativa.




Figura 7. Puntuaciones de cada comunidad autónoma para los indicadores de a) Disponibilidad hídrica W_1 y b) Independencia hídrica W_2 .

Las **Figuras 8a** y **8b** ofrecen perspectivas complementarias sobre el desempeño en tratamiento y reutilización de aguas residuales. La **Figura 8a** (W_3) muestra que Canarias presenta el peor desempeño en tratamiento, con solo 318,386 m³/día procesados adecuadamente en 2020 frente a un suministro de agua potable de 211,724 mil m³. Esta

brecha evidencia graves deficiencias en la cobertura de saneamiento básico en el archipiélago. En marcado contraste, la **Figura 8b** (W₄) revela que la Región de Murcia lidera la reutilización con un asombroso 91.4% de sus aguas residuales tratadas siendo reaprovechadas, principalmente en agricultura intensiva. Este contraste entre regiones insulares y mediterráneas subraya cómo la percepción de escasez condiciona profundamente las políticas hídricas: las comunidades históricamente conscientes de su vulnerabilidad hídrica (Murcia, Valencia, Baleares) han desarrollado sistemas avanzados de economía circular hídrica, mientras aquellas con percepciones tradicionales de abundancia (Galicia, Asturias) apenas reutilizan el 5% de sus aguas tratadas, desperdiciando así oportunidades significativas de crear sistemas más resilientes.





Figura 8. Puntuaciones de cada comunidad autónoma de 2009 a 2020 para los indicadores de a) Agua tratada W_3 y b) Agua reutilizada W_4 .

Transición Energética: Entre Logros Notables y Asignaturas Pendientes Urgentes

El sector energético muestra la transformación más dinámica y esperanzadora del período analizado. La **Figura 9a** (disponibilidad energética E_1) sitúa a Extremadura como líder indiscutible, generando en 2021 cuatro veces su demanda interna (valor máximo de 0.79) gracias a una combinación estratégica de energía nuclear de base (central de Almaraz) y un despliegue masivo de energía fotovoltaica (3,000 MW instalados). Este superávit energético convierte a la región en un pilar fundamental del sistema eléctrico nacional. En el extremo opuesto, nueve comunidades, incluyendo todos los grandes núcleos metropolitanos, aparecen en rojo intenso en la **Figura 9a** ($E_1=0$), reflejando una dependencia total del sistema eléctrico interconectado para satisfacer sus necesidades básicas.

La **Figura 9b** (energía renovable E_2) profundiza este análisis con hallazgos reveladores: Castilla y León alcanza el 89% de generación renovable mediante una red estratégicamente planificada de parques eólicos ubicados en zonas de alto potencial, combinados con una importante contribución hidroeléctrica. Este modelo contrasta dramáticamente con la situación de Baleares (6.77% renovable) y Canarias (10%), cuyos sistemas eléctricos aislados y limitaciones de espacio físico quedan rezagadas en la transición energética. Estas regiones insulares enfrentan desafíos particulares que requieren soluciones específicas, como el desarrollo de energía undimotriz o sistemas avanzados de hibridación renovable.




Figura 9. Puntuaciones de las comunidades autónomas de 2010 a 2021 para los indicadores de a) Disponibilidad energética E_1 y b) Energías renovables E_2 .

La **Figura 10a** (independencia energética E_3) documenta con especial claridad la crisis energética de 2017-2018, cuando una sequía severa redujo la generación hidroeléctrica

nacional a apenas el 7% del total, forzando importaciones récord desde Francia (15,500 GWh en 2018) a precios exorbitantes. Sin embargo, el rápido despliegue renovable posterior (2020-2021) visible en las **Figuras 9b y 10a** permitió recuperar niveles razonables de autonomía estratégica, demostrando la resiliencia de sistemas energéticos diversificados y bien planificados. Este episodio ilustra de manera elocuente cómo las distintas figuras interactúan para contar una historia compleja: la vulnerabilidad ante choques climáticos (**Figura 10a**), la apuesta tecnológica como solución (**Figura 9b**) y la recuperación sistémica (**Figura 6**) conforman un ciclo de aprendizaje crítico para la política energética nacional.

Sector Alimentario y Gestión de Residuos: Contrastes Persistentes y Oportunidades Desaprovechadas

La **Figura 10b** (disponibilidad alimentaria F_1) expone una de las paradojas más llamativas del sistema español: siendo una potencia agrícola exportadora, varias de sus regiones son importadoras netas de alimentos. Extremadura (0.645) y Andalucía (0.638) muestran superávit alimentario constante gracias a sus extensos sistemas agropecuarios, mientras Madrid (0.12) depende de importaciones para cubrir el 82% de sus necesidades básicas. En el indicador de independencia alimentaria F_2 se corrobora este patrón (**Figura 11a**), con Cantabria, Madrid y País Vasco mostrando valores cero por importar sistemáticamente más de lo que producen. Esta dependencia externa genera vulnerabilidades estratégicas, particularmente evidentes durante la crisis de suministros de 2020. En el indicador de superficie ecológica F_3 (**Figura 11b**) destaca el liderazgo indiscutible de Andalucía (1.37 millones de hectáreas certificadas), aunque el valor añadido de esta producción sigue siendo modesto: solo el 30% se exporta como producto elaborado, perdiéndose así oportunidades significativas de creación de empleo y renta. Este dato sugiere la necesidad de políticas activas para desarrollar cadenas de transformación locales que capturen mayor valor dentro de los territorios productores.




Figura 10. Puntuaciones de las comunidades autónomas de 2010 a 2021 para los indicadores de a) Independencia energética E_3 y b) Disponibilidad alimentaria F_1 .




Figura 11. Puntuaciones de las comunidades autónomas para los indicadores a) F_2 y b) F_3 .

En el mapa de calor (**Figura 12**) del indicador F_4 "Desperdicio de alimentos", con una escala de 0.174 a 0.996, la mayoría de las comunidades tienen una puntuación alta, lo que indica que la cantidad de desperdicio de alimentos es pequeña en comparación con la producción de alimentos en cada comunidad. Sin embargo, la comunidad con las peores puntuaciones entre 2010 y 2020 y un promedio más bajo de 0.29 es Cantabria, debido a que su producción

de alimentos es muy baja, mientras que el desperdicio es casi igual a lo producido. Por ejemplo, en 2010, su producción fue de 19,699 toneladas y el desperdicio de 14,739 toneladas. Aunque su situación mejora, alcanzando su mejor puntuación en 2019 con una producción de 25,683 toneladas y un desperdicio de 13,733 toneladas.

La Comunidad de Madrid tiene el segundo peor promedio con 0.66, ya que su producción de alimentos es muy baja (509,624 toneladas en 2010) y el desperdicio alto (163,724 toneladas en 2010). No obstante, su situación mejora para 2020, con un aumento en la producción a 543,332 toneladas y una reducción del desperdicio a 159,734 toneladas.




Figura 12. Puntuaciones de las comunidades autónomas de 2010 a 2020 para el indicador F_4 .

El indicador de separación de residuos R_1 y reutilización R_2 revelan el sector más atrasado en la transición hacia la economía circular (**Figura 13**). Navarra ($R_1=0.4$) lidera claramente gracias a sus sistemas integrales de depósito y retorno, combinados con intensas campañas de educación ambiental. En el extremo opuesto, Murcia (0.11) y Andalucía (0.12) muestran graves deficiencias en la separación en origen, limitadas por modelos obsoletos de gestión. En reutilización propiamente dicha, el promedio nacional (38%) se encuentra lejos del objetivo europeo (50%), con La Rioja (0.54) como única comunidad cercana al

cumplimiento. Estos resultados grafican el largo camino por recorrer para alcanzar una economía circular real y efectiva.




Figura 13. Puntuaciones de las comunidades autónomas de 2010 a 2020 para los indicadores a) R_1 y b) R_2

Como conclusiones integradas y lecciones para la Política Pública, el análisis conjunto de todas las figuras permite identificar tres patrones clave que deberían orientar la política de

gestión integrada de recursos: 1. La divergencia norte-sur en seguridad hídrica, ya que las regiones mediterráneas muestran mayor estrés hídrico pero también desarrollan soluciones más innovadoras en reutilización, mientras las regiones atlánticas tradicionalmente "ricas en agua" descuidan oportunidades de economía circular. 2. La Brecha urbano-rural en autosuficiencia ya que las áreas metropolitanas dependen críticamente de recursos externos, mientras las regiones rurales mantienen capacidades productivas, pero pierden valor añadido potencial. 3. Las oportunidades sistemáticamente desperdiciadas en economía circular, debido a que existen soluciones técnicas probadas (como los sistemas murcianos de reutilización hídrica o los navarros de gestión de residuos) que no se escalan al resto del territorio nacional. Estos hallazgos, respaldados por el análisis integrado de figuras complementarias, proporcionan una base empírica sólida para diseñar políticas diferenciadas por región, priorizando intervenciones en tres áreas críticas: la modernización integral de regadíos, combinando eficiencia hídrica con generación renovable distribuida y protección de acuíferos. La aceleración masiva de energías renovables con soluciones adaptadas a cada contexto regional, desde eólica terrestre en Castilla hasta fotovoltaica flotante en embalses. Y la implementación generalizada de sistemas de depósito de residuos, aprendiendo de los casos de éxito navarro y riojano para alcanzar los objetivos europeos. En este trabajo la riqueza visual y analítica de este conjunto de figuras interrelacionadas ofrece no solo un diagnóstico preciso de los desafíos actuales, sino también una hoja de ruta clara para transitar hacia una gestión realmente integrada y sostenible del nexo agua-energía-alimentos-residuos en España. El estudio demuestra que las soluciones existen, pero requieren voluntad política, inversión sostenida y, sobre todo, una visión sistémica que supere los enfoques sectoriales tradicionales.

7.2 Fase 2: Proyección del nexo WEF mediante redes neuronales profundas (LSTM y GRU)

7.2.1 Metodología

La metodología propuesta en este trabajo (**Figura 14**) considera la evaluación de la seguridad del nexo WEF en el futuro mediante la implementación del índice del nexo WEF y el desarrollo de modelos de aprendizaje profundo para las fuentes de producción y consumo

asociadas al nexo WEF. Es importante destacar que se desarrolla un modelo de aprendizaje profundo para cada fuente de producción y consumo. Luego, para cada modelo de aprendizaje profundo, primero se realiza la recopilación y preprocesamiento de datos históricos. Posteriormente, los datos se estandarizan y dividen en un conjunto de entrenamiento y un conjunto de validación, que se utilizan para entrenar los modelos de aprendizaje profundo y evaluar los modelos entrenados. Además, se lleva a cabo la optimización de los hiperparámetros asociados a cada modelo de aprendizaje profundo para obtener modelos competitivos (seleccionando los hiperparámetros, los límites superior e inferior y los parámetros asociados al algoritmo). Una vez optimizados los hiperparámetros, se selecciona el mejor modelo para cada una de las fuentes. Con los mejores modelos, se realizan proyecciones hacia el futuro y, finalmente, los valores obtenidos para cada fuente se utilizan para determinar el índice del nexo WEF mediante el cálculo de los seis indicadores de disponibilidad y accesibilidad.




Figura 14. Metodología específica de la fase 2

Es importante destacar que se dispone de conjuntos de datos para cada fuente de producción y demanda asociada al nexo agua-energía-alimentos; se evalúan y desarrollan redes LSTM y GRU para las fuentes consideradas en este trabajo. Además, durante la optimización de los

hiperparámetros, el proceso de entrenamiento y evaluación del modelo se lleva a cabo de manera consecutiva para encontrar el error mínimo asociado al conjunto de validación.

Métricas de evaluación

Las métricas utilizadas para evaluar y comparar la precisión de los modelos de aprendizaje profundo propuestos (LSTM y GRU) en este proyecto son el error absoluto medio (MAE), el error cuadrático medio (MSE) y el coeficiente de determinación (R^2) (**Ecuación 32-34**).

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (32)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |(Y_i - \hat{Y}_i)| \quad (33)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^N (\bar{Y}_i - Y_i)^2} \quad (34)$$

Donde N , Y_i , $\hat{Y}_i$ y $\bar{Y}_i$ son el número total de muestras, los valores reales, los valores predichos y la media de los valores reales, respectivamente.

Optimización de hiperparámetros

La precisión de los modelos de aprendizaje profundo está directamente relacionada con la selección de hiperparámetros, por lo que encontrar los valores adecuados de los hiperparámetros es un factor determinante en la etapa de entrenamiento de los modelos. Actualmente, existen diferentes métodos de optimización/ajuste de hiperparámetros para obtener modelos competitivos, como prueba y error (manual), búsqueda aleatoria, algoritmos genéticos, búsqueda en cuadrícula y métodos bayesianos (Wu et al., 2019; Alibrahim y Ludwig, 2021; López-Flores et al., 2022). Sin embargo, en este proyecto, se ha desarrollado una optimización de hiperparámetros utilizando un algoritmo adaptativo basado en muestreo aleatorio; se ha utilizado la biblioteca Keras-tuner bajo el lenguaje Python (O'Malley, 2019), que contiene varios algoritmos de optimización de hiperparámetros. Específicamente, se ha

utilizado el novedoso algoritmo Hyperband (Li et al., 2018), que es adaptativo en el cálculo al asignar más recursos a configuraciones de hiperparámetros prometedoras y descartar rápidamente las malas, lo que permite identificar rápidamente buenos hiperparámetros (las configuraciones de hiperparámetros se muestrean aleatoriamente). Además, este algoritmo examina un mayor número de configuraciones de hiperparámetros que los algoritmos que entrenan uniformemente todas las configuraciones hasta su finalización. Hyperband es de 5 a 30 veces más rápido que los algoritmos populares de optimización bayesiana en una variedad de problemas de aprendizaje profundo y basados en kernels (Li et al., 2018).

Metodología para el cálculo de indicadores y el índice del nexo WEF

Cada indicador se calculó para períodos de tiempo t , así como el índice del nexo WEF. Para el cálculo del indicador de disponibilidad de agua WW_1 (**Ecuación 35**), se utilizó el promedio de agua renovable, que es la cantidad máxima de agua que es factible explotar anualmente en un país sin alterar el ecosistema y que se renueva por las precipitaciones. A esta cantidad se le resta el consumo de agua y se divide entre el agua renovable.

$$WW_{1,t} = \frac{WG_t - WC_t}{WG_t} \quad (35)$$

El indicador de accesibilidad al agua WW_2 (**Ecuación 36**) se calcula restando la población sin acceso a agua entubada de la población total. Esto se divide entre la población total.

$$WW_{2,t} = \frac{Pop_t - Pop_{WW_t}}{Pop_t} \quad (36)$$

El indicador de disponibilidad de energía EE_1 (**Ecuación 37**) se obtiene restando el consumo de la generación de electricidad y dividiendo esto entre la generación de electricidad.

$$EE_{1,t} = \frac{EP_t - EC_t}{EP_t} \quad (37)$$

El indicador de accesibilidad a la energía EE_2 (**Ecuación 38**) se calcula restando la población sin acceso al servicio de electricidad de la población total y dividiéndolo entre la población total.

$$EE_{2,t} = \frac{Pop_t - Pop_{WE_t}}{Pop_t} \quad (38)$$

El indicador de disponibilidad de alimentos FF₁ (**Ecuación 39**) utiliza la producción de alimentos y resta el consumo de alimentos. Esto se divide entre la producción de alimentos.

$$FF_{1,t} = \frac{FP_t - FC_t}{FP_t} \quad (39)$$

El indicador de accesibilidad a los alimentos FF₂ (**Ecuación 40**) se obtiene restando la población sin acceso a alimentos de la población total y dividiéndolo entre la población total.

$$FF_{2,t} = \frac{Pop_t - PopWF_t}{Pop_t} \quad (40)$$

En el índice del nexo WEF, los 6 indicadores se agregan para cada tiempo t ($I_{n,t}$), donde $\varphi_n=1/6$ representa un peso equi-proporcional para cada indicador porque se asigna la misma prioridad a todos los indicadores (**Ecuación 41-42**).

$$WEF \text{ nexus index}_t = \sum_{n=1}^N \varphi_n \cdot I_{n,t} \quad (41)$$

$$\sum_{n=1}^N \varphi_n = 1 \quad (42)$$

El porcentaje anual de variación (**Ecuación 43**) se calcula con V_n , que representa el valor del año n , y V_0 representa el valor del año base.

$$\% \Delta = \frac{V_n - V_0}{V_0} \times 100 \quad (43)$$

7.2.2 Caso de Estudio

México emerge como una opción viable para analizar los desafíos y oportunidades del nexo agua-energía-alimentos (WEF) debido a su singular combinación de factores geográficos, demográficos y socioeconómicos. Como país megadiverso con una extensión territorial de 1,964,375 km² y una población en crecimiento (126 millones en 2020, proyectados a 148 millones en 2050), enfrenta presiones críticas sobre sus recursos naturales. Su sistema hídrico, caracterizado por una distribución desigual (72% de lluvias concentradas en 4 meses) y la sobreexplotación de 157 de sus 653 acuíferos (SINA, 2022), ilustra los retos de seguridad hídrica en contextos de cambio climático. Simultáneamente, su matriz energética, donde el

68.8% depende de fuentes no renovables y el gas natural importado cubre el 65.8% de la generación eléctrica (SENER, 2022), revela vulnerabilidades geopolíticas y ambientales. Por otro lado, México se consolida como potencia agroalimentaria (séptimo exportador global con 290.7 millones de toneladas producidas en 2020; SADER, 2021), el 24% de su población enfrentará inseguridad alimentaria en 2050 (CONEVAL, 2020), evidenciando contradicciones sistémicas entre producción, acceso y equidad. Esta complejidad se ve agravada por su estructura económica, donde las actividades primarias (4% del PIB) sustentan recursos estratégicos, pero reciben menor inversión que los sectores terciarios (64% del PIB; INEGI, 2020b). La convergencia de estos factores, como la escasez hídrica, la dependencia energética, asimetrías alimentarias y el crecimiento urbano, posiciona a México como un caso emblemático para estudiar la gobernanza del nexo WEF en economías emergentes, ofreciendo lecciones críticas sobre integración de políticas, innovación tecnológica y justicia socioambiental en la era de los Objetivos de Desarrollo Sostenible.

7.2.3 Resultados

7.2.3.1 Aprendizaje profundo

Se utilizaron conjuntos de datos de consumo de agua (incluyendo agrícola, industrial, generación de energía excepto hidroeléctrica y suministro público) (CONAGUA, 2021), producción de alimentos (agrícola y ganadera) (SIAP, 2022), consumo de electricidad y producción de electricidad (SIE, 2022) con períodos de 1 año para el desarrollo de los modelos de aprendizaje profundo; se desarrollaron cuatro modelos considerando unidades LSTM y GRU. De esta manera, se desarrollaron ocho modelos (cuatro por unidad) optimizando las configuraciones de hiperparámetros. Los conjuntos de datos históricos se tomaron de 1997 a 2020 para consumo de agua, de 1985 a 2021 para producción de alimentos, de 1965 a 2019 para consumo de electricidad, y de 1965 a 2019 para producción de electricidad. Es importante mencionar que estos datos están disponibles en las bases de datos oficiales. Además, los conjuntos de datos se separaron en un conjunto de entrenamiento y un conjunto de validación, donde el conjunto de validación es aproximadamente el 20% del total de datos; esto equivale a datos de 2016 a 2020 para consumo de agua; de 2015 a 2021 para producción de alimentos; de 2010 a 2019 para los modelos de consumo y producción de

electricidad. El 80% restante de los datos de cada conjunto se utilizó para el entrenamiento del modelo.

La **Tabla 5** presenta los hiperparámetros, los valores mínimos y máximos, y el paso establecido para la optimización; estos se han definido después de algunos entrenamientos por prueba y error. Asimismo, la función de activación se seleccionó como un hiperparámetro a optimizar al tener ReLu, Elu, Mish, Tanh y Sigmoid como opciones para elegir; también existe la opción de no seleccionar ninguna función de activación. Se ha utilizado Adam (optimizador de estimación de momento adaptativo) como optimizador y la función de pérdida de validación (MSE) es el objetivo por minimizar para reducir los problemas asociados con el sobreajuste del modelo. Durante el proceso de optimización de hiperparámetros, se realizaron aproximadamente 3800 experimentos para cada uno de los ocho modelos en un tiempo de cálculo promedio de 8.8 horas.

Tabla 5. Espacio de búsqueda de hiperparámetros para el algoritmo de optimización

Hiperparámetros	Escala	Min	Max	Paso
Capas ocultas	Entero	1	5	1
Unidades por capa	Entero	20	500	20
Tasa de aprendizaje	Log	1e-4	1e-2	-

La **Tabla 6** muestra los hiperparámetros con los que se obtuvieron los mejores modelos después de la optimización. Nótese que la unidad LSTM es la mejor para consumo de agua, producción de alimentos y producción de electricidad, mientras que la unidad GRU es la mejor para consumo de electricidad. Por otro lado, las funciones de activación se seleccionan solo en el modelo para producción de alimentos, que es el más complejo y no lineal de todos los modelos. En contraste, el modelo para consumo de electricidad es el más pequeño ya que tiene solo tres capas ocultas con unidades GRU, por lo que se realizan menos operaciones y cálculos vectoriales.

Tabla 6. Resultados obtenidos después de la optimización de hiperparámetros.

Concepto	Selección optima
Consumo de agua	
Unidad	LSTM

Capas ocultas	5
Unidad por capa	220 – 460 – 260 – 160 – 40
Tasa de aprendizaje	0.00068
Función de activación	Sin función
Producción de alimentos	
Unidad	LSTM
Capas ocultas	5
Unidad por capa	60 – 460 – 40 – 280 – 20
Tasa de aprendizaje	0.001833
Función de activación	Sigmoid – Mish – Sigmoid – Elu – Mish
Consumo de electricidad	
Unidad	GRU
Capas ocultas	3
Unidad por capa	460 – 240 – 100
Tasa de aprendizaje	0.00199
Función de activación	Sin función
Producción de electricidad	
Unidad	LSTM
Capas ocultas	3
Unidad por capa	220 – 320 – 420
Tasa de aprendizaje	0.001726
Función de activación	Sin función

La **Tabla 7** muestra los resultados de las diferentes métricas de error para los mejores modelos obtenidos. Los modelos con los mejores valores para las diferentes métricas son aquellos para consumo y producción de electricidad. Mientras que el peor modelo es el de producción de alimentos debido a la mayor dispersión de los datos y la tendencia más compleja, de ahí que la estructura de este modelo sea más grande (ver **Tabla 2**). Es importante mencionar que la métrica de error más consistente en estos modelos es el coeficiente de rendimiento (R^2). La **Figura 15** ilustra la comparación para el conjunto de validación de cada modelo entre los valores reales y los valores predichos por los modelos; cuanto más cerca estén los puntos de la pendiente de 45°, mejores serán las predicciones. En casi todas las gráficas se puede ver que todos los puntos están cerca de la línea, siendo la gráfica de producción de alimentos donde los puntos están más alejados de la línea; esto reafirma lo discutido previamente. Utilizando estos modelos, se han realizado predicciones hasta 2050 para evaluar la seguridad del nexo agua-energía-alimentos.

Tabla 7. Métricas de error obtenidas para datos de entrenamiento y validación.

Métrica	Consumo de agua		Producción de alimentos		Consumo de electricidad		Producción de electricidad	
	Entrenamiento	Validación	Entrenamiento	Validación	Entrenamiento	Validación	Entrenamiento	Validación
MSE	8.35×10^{-5}	6.95×10^{-6}	1.63×10^{-3}	1.35×10^{-4}	1.73×10^{-3}	1.76×10^{-4}	1.08×10^{-3}	1.28×10^{-4}
MAE	0.0069	0.0014	0.0325	0.0078	0.0350	0.0110	0.0269	0.0095
R ²	0.9584	0.9554	0.9635	0.8833	0.9950	0.9764	0.9969	0.9748




Figura 15. Comparación de los valores reales frente a los valores predichos por los modelos para el conjunto de validación.

7.2.3.2 Indicadores

Para el cálculo de los indicadores, se utilizaron datos reales para consumo de agua de 1997 a 2020, para demanda y producción de electricidad de 1965 a 2019, y para producción de alimentos de 1985 a 2021. Los datos de proyección para 2050 se obtuvieron mediante técnicas de aprendizaje profundo. En el caso de los datos de agua renovable promedio, solo

existen datos para 2017 con 451,583 hm³, para 2018 y 2019 de 451,585 hm³, y en 2020 de 461,640 hm³, este último se estableció hasta 2050 (SINA, 2021). Para el caso de la población futura, se utilizó la proyección del Consejo Nacional de Población, que considera la evolución futura de tres fenómenos demográficos que impactan en la dinámica poblacional, que son mortalidad, fertilidad y migración (CONAPO, 2019). En el caso de la población sin acceso a agua entubada (SEMARNAT, 2020b) y la población sin acceso a electricidad (SEMARNAT, 2020a), se utilizaron datos reales de 1990 a 2020 y se utilizaron regresiones lineales para las proyecciones a 2050. Para consumo de alimentos, se utilizó el consumo anual per cápita para 2020 (que incluye el consumo de cereales, tubérculos, legumbres secas, frutas, verduras, carnes, huevos, leche y productos del mar) (SIAP, 2022), que se multiplica por la población para cada año. En el caso de la población sin acceso a alimentos (CONEVAL, 2020), se utilizaron datos reales de 2016 a 2020 y los datos proyectados hacia 2050 se obtuvieron de una regresión lineal. En la **Figura 16**, el indicador de disponibilidad de agua W_1 muestra una tendencia decreciente en la puntuación a lo largo de los años, exactamente 12.94%, de 0.85 en 1997 a 0.74 en 2050. Con base en el año 2010 con una puntuación de 0.82, hay una disminución de 2.45% en 2020, 5.07% en 2030, 7.83% en 2040 y 10.87% en 2050. Esto se debe a que la proyección de consumo de agua tiene una tendencia creciente. Tomando como referencia el consumo de agua de 2010 de 80,213 hm³, para 2020 el consumo fue de 89,548 hm³ o un aumento de 11.64%, la proyección de consumo para 2030 es de 99,568 hm³, lo que representa un aumento de 24.13%, para 2040 hay 110,070 hm³ que equivalen a 37.22% más y en 2050 se proyectan 121,679 hm³, lo que representa un aumento de 51.7%. Por otro lado, con el aumento de la población, hay una disminución en el agua renovable per cápita, en 2010 con 4058 m³/hab/año tomado como año base para el cálculo de la variación en años futuros. En 2020 con 3612 m³/hab/año equivalente a una disminución de 10.99%, mientras que la proyección en 2030 con 3343 m³/hab/año (-17.62%), en 2040 con 3185 m³/hab/año (-21.52%) y en 2050 3114 m³/hab/año (-23.25%).




Figura 16. Consumo de agua proyectado, agua renovable per cápita y el indicador WW_1 de disponibilidad de agua.

En el indicador de accesibilidad al agua W_2 , la proyección muestra una tendencia de mejora a lo largo de los años hasta alcanzar un valor de 1 (**Figura 17**), ya que con respecto a 2010 hubo un aumento en el valor del indicador de 5.69% para 2020, 8.04% en 2030, 9.55% en 2040 y 10.22% en 2050. Esto se debe a que el número de personas con acceso a agua entubada aumenta en 18.73% en 2020, 31.14% en 2030, 39.59% en 2040 y 43.62% en 2050, tomando como referencia 103,443,041 personas con acceso en 2010. Lo anterior permite un aumento en el porcentaje de personas con acceso a agua entubada desde 1990 con 78.39%, 2000 con 87.83%, 2010 con 90.94%, 2020 con 96.11%, 2030 con 98.25%, 2040 con 99.63% y 2050 con 100% con una población de 148,209,594 habitantes (CONAPO, 2019).




Figura 17. Proyección de población con y sin acceso al agua e indicador de accesibilidad al agua WW_2 .

En el indicador de disponibilidad de energía E_1 , cuando el valor es mayor o igual a cero, la producción de electricidad satisface la demanda, y cuando los valores son negativos, la producción es insuficiente para abastecer la demanda de electricidad. La **Figura 18** ilustra que, en los próximos años, la demanda de electricidad crecerá más que la producción, lo que resultará en no poder satisfacer completamente la demanda de electricidad. Se proyecta que la generación de electricidad en 2030 será de 464,468 GWh, lo que representa un aumento de 68.55%, en 2040 de 598,996 GWh, o un aumento de 117.37%, y en 2050 de 772,486 GWh, igual a un aumento de 180.33% con base en la generación de 2010. Mientras que las proyecciones de demanda de electricidad tienen un mayor aumento, por ejemplo, para el año 2030 hay una demanda de 500,460 GWh, lo que representa un aumento de 85.39%, en el año 2040 una demanda de 683,259 GWh igual a un aumento de 153.11% y en 2050 la demanda proyectada es de 932,764 GWh equivalente a un aumento de 254.54%, con base en la demanda de electricidad del año 2010. El combustóleo fue el principal combustible utilizado en la generación de electricidad desde 1970, alcanzando su pico de 981 petajoules en 2000 y a partir de ahí comenzó su declive. Desde 2004 hasta la actualidad el combustible más utilizado es el gas natural; su máximo pico fue de 1813 petajoules en 2018. El gas natural utilizado en la generación de electricidad representó el 54.5% de la demanda interna del país en 2018 y el 51.8% en 2020. Sin embargo, se importaron 2191 petajoules que representan el

65.8% del suministro del país (que incluye producción, importación, exportación y existencias de inventario) en 2018 y 1890 petajoules que equivalen al 63.4% del suministro en 2020. Texas (EE.UU.) es el lugar del que se importa el mayor porcentaje de gas natural. El alto consumo de gas natural en la generación se debe a que la tecnología con mayor capacidad instalada en el país es el ciclo combinado con 31,948 MW representando el 38.4% de la estructura de potencia instalada en 2020 y 33,640 MW equivalentes al 39% en 2021. La tecnología de ciclo combinado tuvo una generación de 185,637 GWh en 2020 representando el 58.5% de la generación del país y 186,715 GWh igual al 56.8% en 2021 (SENER, 2022). Sin embargo, en 2019 y 2020 la generación de electricidad fue menor que la demanda total (que incluye consumo final, consumo del sector y pérdidas de transmisión y distribución), con importaciones y exportaciones en 2020 fue suficiente para satisfacer la demanda total; sin embargo, en 2019 esto fue insuficiente. Lo anterior resalta la dependencia energética de México del gas natural hacia Estados Unidos y, además de esto, existe una falta de infraestructura de almacenamiento de gas natural, ya que actualmente solo se pueden almacenar 2.4 días de inventario estratégico.




Figura 18. Producción y consumo de electricidad proyectados e indicador de disponibilidad energética E_1 .

En la **Figura 19**, el indicador E_2 de accesibilidad a la electricidad muestra que la puntuación es igual a 1 en los próximos años ya que el número de habitantes con acceso a electricidad ha crecido desde 1990 con 73,235,944 habitantes representando el 87.01% de la población, en 2000 con 93,648,441 habitantes representando el 94.8%, en 2010 había 111,371,324 habitantes igual al 97.97% y en 2020 había 126,667,714 habitantes representando una cobertura del 99.12% de la población. Las proyecciones muestran que el número de personas con acceso aumentará en 26% para 2030, 33.46% para 2040 y 37.01% para 2050, en comparación con 2010. En el cual el 100% de la población tiene acceso a electricidad.




Figura 19. Proyección de población con y sin acceso a electricidad y el indicador E_2 de accesibilidad energética.

En la **Figura 20**, el indicador de disponibilidad de alimentos F_1 muestra una evolución positiva de la puntuación a lo largo de los años. El año base fue 2010 con una puntuación de 0.43 y para 2020 mejoró en 10.64% alcanzando una puntuación de 0.48, mientras que las proyecciones para 2030 muestran una mejora de 22.82%, en 2040 de 31.75% y en 2050 de 45.63% alcanzando una puntuación de 0.63. Esto se debe a que la producción de alimentos ha tenido una tendencia al alza desde 1985 (datos más antiguos conocidos) hasta 2050 (proyección) con un aumento de 391.81% entre esos años. Tomando 2010 como año base con una producción de 173,258,806 toneladas, se calcula el porcentaje de variación de años futuros, donde para 2020 hubo una producción de 214,583,769 toneladas, representando un aumento de 23.85%. La proyección para 2030 con producción de alimentos de 258,131,184

toneladas es igual a un aumento de 48.99%, para 2040 con 295,553,984 toneladas que representan 70.59% más y en 2050 con 351,802,080 toneladas de alimentos igual a un aumento de 103.05% comparado con 2010. Mientras que el consumo de alimentos también ha aumentado en 13.73% alcanzando 111,453,914 toneladas en 2020 y las proyecciones muestran que para 2030 aumentará en 22.87% alcanzando 120,417,849 toneladas, para 2040 28.99% con 126,409,722 toneladas, y en 2050 un consumo de alimentos proyectado de 129,260,849 toneladas representando un aumento de 31.9% sobre 2010.




Figura 20. Producción y consumo de alimentos proyectados e indicador de disponibilidad de alimentos F_1 .

Aunque la producción y consumo de alimentos muestran una tendencia al alza, la producción siempre es mayor que el consumo y esto no genera un riesgo para abastecer la demanda interna del país. En la **Figura 21**, el indicador F_2 de acceso a alimentos muestra una evolución positiva en la puntuación de 1950 a 2018 y un empeoramiento de 2018 a 2050. El valor mínimo del indicador F_2 fue 0.382 en 1950 cuando el 61.8% de la población no tenía acceso a alimentos. Con base en la puntuación de 0.775 en 2010, hay un aumento de 0.2% en 2020, y las proyecciones muestran una disminución de 2.58% en 2030, 5.78% en 2040, y 9.61% en 2050. Esto se debe al aumento en el número de personas sin acceso a alimentos en comparación con 2010, que en 2020 fue de 11.58% y en la proyección de 2030 32.17%, en 2040 52.77% y en 2050 73.37%, lo que representa 44,398,427 personas. Como consecuencia,

el porcentaje de personas sin acceso a alimentos también aumentará año con año, de 20.36% en 2020 a 24.52% en 2030, 26.99% en 2040, y 29.96% en 2050.




Figura 21. Proyección de la población con y sin acceso a alimentos y el indicador F₂ de accesibilidad a los alimentos.

El acceso limitado a alimentos está directamente relacionado con el poder adquisitivo de las personas, así como con las condiciones estructurales que permiten el acceso a alimentos, como la densidad de vías férreas y carreteras, los ingresos y gastos del hogar, los altos precios, el nivel de marginación de la localidad y la prevalencia de desnutrición. Un hogar puede obtener sus alimentos de dos formas principales: producción de alimentos y compra de alimentos. Ambos requieren recursos o ingresos adecuados. Medios menos importantes y comunes de obtención de alimentos son las donaciones o asignaciones de alimentos caritativas o gubernamentales, a través de comidas escolares gratuitas o mediante vales de alimentos o subsidios alimentarios. Huertos comunitarios, granjas suburbanas y bancos de alimentos locales ofrecen ideas para mejorar el acceso a alimentos saludables. La puntuación del índice WEF muestra una tendencia positiva al alza (**Figura 22**). Tomando 2000 como año base con una puntuación de 0.628, hay un aumento de 4.65% en 2010, lo que coloca la puntuación en 0.657, 6.53% en 2020 alcanzando una puntuación de 0.669, mientras que en la proyección de 2030 aumenta en 7.59% representando una puntuación de 0.676, para 2040 7.73% alcanzando 0.667 y para 2050 7.97%, lo que significa un valor de índice de 0.678.

Políticas que podrían aplicarse para mejorar el nexo agua-energía-alimentos: El suministro de agua potable en muchas ciudades y áreas metropolitanas requiere buscar nuevas fuentes de suministro como desalinización, reúso de aguas residuales, captación de agua de ríos, renovación de aguas subterráneas y trasvase entre cuencas con métodos de almacenamiento. Satisfacer las demandas futuras de agua requiere integrar acciones estructurales y no estructurales (gestión, políticas y educación) para lograr una planificación y gestión integrada de los recursos hídricos. Estas incluyen: Educar para el cambio en patrones de consumo y estilos de vida; Mejorar prácticas de riego y agrícolas. Mejorar la infraestructura para captación, potabilización, almacenamiento, distribución, alcantarillado y depuración. Algunas acciones que pueden implementarse incluyen mejorar la eficiencia energética y reducir la dependencia de importaciones de energía, reducir emisiones mediante la promoción de investigación en tecnologías de energía limpia y baja en carbono, y priorizar investigación e innovación para impulsar la transición energética hacia una red resiliente, segura, confiable, sostenible y asequible ante condiciones climáticas cada vez más impredecibles. Así como invertir en la red de transmisión y distribución.




Figura 22. Puntuación del índice de nexo WEF proyectada.

Para mejorar la seguridad alimentaria, es necesario asegurar que los agricultores reciban una remuneración adecuada por sus productos (para evitar que se vean afectados por caídas en los precios debido a excedentes de generación o importaciones, brindando certeza a los ingresos de este sector empobrecido), y que los sistemas de producción, procesamiento y distribución sean lo más extensos y eficientes posibles (considerando mejorar caminos a localidades de difícil acceso); que los salarios mínimos sean adecuados; que los precios de alimentos básicos sean asequibles. Programas que provean alimentos subsidiados suficiente y económicamente, particularmente a personas que viven en zonas de difícil acceso o alta y muy alta marginación. Hogares agrícolas rurales, con ayuda de las autoridades, pueden implementar medidas para optimizar la producción de sus tierras para máximo rendimiento. La agricultura urbana y periurbana también puede incentivarse y ofrece una estrategia fundamental para construir resiliencia en el suministro de alimentos de una ciudad.

Los resultados revelan una paradoja crítica: mientras los indicadores de accesibilidad a agua y energía muestran mejoras significativas (alcanzando cobertura universal en 2050), la disponibilidad de estos recursos presenta tendencias preocupantes. El agua renovable per cápita disminuirá un 23.25% y el déficit energético se agravará, con una demanda que superará la producción en 2050. En el sector alimentario, aunque la producción superará consistentemente la demanda, el acceso a alimentos empeorará, afectando al 29.96% de la población.

El índice WEF compuesto (0.678 en 2050) enmascara estas disparidades, evidenciando la necesidad de políticas diferenciadas. Urgen medidas como: modernización de infraestructura hídrica, diversificación energética y programas focalizados de seguridad alimentaria que combatan las desigualdades estructurales. El estudio demuestra que las soluciones técnicas son insuficientes sin abordar factores socioeconómicos, destacando la importancia de enfoques integrados para alcanzar los ODS.

7.3 Fase 3: Clasificación de regiones según vulnerabilidad en el cumplimiento de los Objetivos de Desarrollo sostenible (SDG) mediante clustering

7.3.1 Metodología

La **Figura 23** muestra la metodología implementada, en la que se utilizaron dos conjuntos de datos. El primer conjunto utilizó las puntuaciones de cumplimiento para cada uno de los 17 ODS, y el segundo conjunto añadió el índice global de pérdida de alimentos a la base de datos anterior. Se realizó un análisis de correlación y luego los datos se normalizaron. Posteriormente, se determinó el número óptimo de clusters k utilizando los métodos Elbow y Silhouette. Finalmente, se aplicó el clustering y se caracterizaron los grupos creados para cada base de datos.



Figura 23. Metodología específica de la fase 3.

7.3.1.1 Estudio de caso

Cerca de celebrar la Cumbre de los ODS 2023 y superando la mitad del período hacia el cumplimiento de la Agenda 2030, los esfuerzos se intensifican para alcanzar el mayor desafío global. La Agenda 2030 para el Desarrollo Sostenible es una oportunidad para transformar el mundo y mejorar la vida de todos mediante el cumplimiento de 17 objetivos de desarrollo

sostenible (ODS) a través de 169 metas (ONU, 2015). Cada objetivo es un conjunto de metas interdisciplinarias donde se reconoce un compromiso común y universal a favor de las personas, el planeta y la prosperidad. El éxito o fracaso del plan dependerá completamente de los esfuerzos equilibrados en las esferas económica, social y ambiental. Sin embargo, lograr esta ambiciosa visión del desarrollo humano presenta nuevos y complejos desafíos para la población. Para erradicar la pobreza, mejorar la salud humana, reducir el hambre, proteger el planeta, controlar el consumo de recursos y enfrentar la incertidumbre asociada con el manejo de una gran cantidad de datos, es necesario un enfoque de gestión integrado que promueva el fortalecimiento de sinergias e inversiones que equilibren los beneficios en diferentes sectores. En este sentido, el análisis de datos puede proporcionar información sobre el logro de la Agenda, comprender las interconexiones e identificar áreas de deficiencia, lo que conduce a una toma de decisiones basada en evidencia.

Teniendo en cuenta también el retroceso en el progreso logrado como resultado de la pandemia de COVID-19, los desastres naturales, los conflictos sociales y las crisis económicas, se decidió analizar 143 países seleccionados por su disponibilidad y transparencia de datos en dos escenarios mediante técnicas de aprendizaje automático para identificar aspectos de la situación actual de los ODS.

Escenario 1: Un análisis completo de los 17 ODS

Se analizan los índices de los 17 ODS evaluados y reportados en el Informe de Desarrollo Sostenible 2023 (Sachs et al., 2023). Los países seleccionados actúan como una asociación colaborativa y han implementado comportamientos en un plan de acción hacia un mundo sostenible y resiliente. Es importante señalar que todos los países aceptaron la Agenda teniendo en cuenta la realidad de cada uno, su nivel de desarrollo y respetando prioridades y políticas. Esto puede tener tanto ventajas como desventajas. De hecho, los países con menor desarrollo y mayor pobreza no tendrán la capacidad de invertir recursos en actividades de investigación y tecnología, y finalmente, no exigirán mejoras ambientales en la medida en que no cubran otras necesidades básicas. Sin embargo, gracias a la cooperación global, las economías menos desarrolladas podrán aprender y adoptar patrones de países más desarrollados, lo que resultará en beneficios en los pilares de la sostenibilidad (económico, social y ambiental).

Escenario 2: Análisis de los 17 ODS y la meta 12.3

Basado en el cumplimiento general de los 17 ODS para lograr un futuro sostenible mediante el uso eficiente de los recursos, se analizan los 17 ODS, incluyendo la meta 12.3 "Pérdida y desperdicio de alimentos" como eje central. El ODS 12, "Producción y consumo responsables", se identifica como esencial y principalmente la meta 12.3 sobre desperdicio de alimentos debido al acelerado aumento de la población que se espera en el futuro cercano. Se trata de hacer más con menos, intensificando todas las etapas de la cadena de suministro, respondiendo a las necesidades básicas y promoviendo la reducción de residuos y el impacto ambiental en las ciudades. Actualmente, se generan 0.28 kg de desperdicio de alimentos por persona, lo que representa el 17% de los alimentos producidos a nivel mundial (OMS, 2022). Sin embargo, es más sorprendente observar los altos niveles de inseguridad alimentaria que aumentan año tras año, con el 22.7% de la población sufriendo de desnutrición (FAO, 2023b). Por lo tanto, existe una urgente necesidad de promover técnicas para optimizar la producción y gestión de alimentos mediante políticas prácticas, tecnológicas y educativas.

7.3.1.2 Recolección de datos

El análisis utilizó datos sobre la puntuación de cumplimiento de los 17 ODS para 143 países obtenidos del Informe de Desarrollo Sostenible 2023 (Sachs et al., 2023), donde cada objetivo tiene sus respectivos indicadores. Los 17 ODS se evalúan a través de 122 indicadores. La mayoría de los datos se extraen de bancos de datos de organizaciones internacionales (FAO, OIT, OCDE, UNICEF, OMS, Banco Mundial y otras fuentes) que siguen procesos extensos y rigurosos de validación de datos. Los datos globales de pérdida de alimentos se obtuvieron de la Organización de las Naciones Unidas para la Alimentación y la Agricultura (FAO, 2023a). Los países que no se incluyen se deben a la falta de datos que presentan.

7.3.1.3 Matriz de correlación

La matriz de correlación indica el nivel de asociación lineal entre las variables. En este caso, se refiere a la asociación entre los 17 ODS. Con un rango de valores de -1 a 1, los valores cercanos a -1 indican una correlación negativa (es decir, una variable aumenta mientras la otra disminuye), los valores cercanos a cero indican poca correlación, mientras que los

valores cercanos a 1 indican una correlación positiva (es decir, las dos variables aumentan o disminuyen juntas).

7.3.1.4 Preparación de datos

Cuando las variables están en diferentes escalas, el modelo puede introducir sesgos hacia variables con un mayor rango de variación. Por lo tanto, es importante normalizar los datos para que los valores de cada variable estén en escalas similares. Se utilizó la técnica MinMax, donde todas las variables se escalan linealmente al intervalo $[0,1]$ mediante la **Ecuación 44**, donde $x_{\max}$ y $x_{\min}$ son los valores máximo y mínimo para cada variable.

$$x_{norm} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (44)$$

7.3.1.5 Validación de grupos

No existe un criterio objetivo para la selección de número de clusters sin embargo hay varios métodos que sugieren el “número óptimo de grupos” que se refiere a una serie de grupos en los que los miembros de cada grupo tienen la mayor cantidad de similitudes entre sí y la mayor diferencia con los miembros de otros grupos (Wu, 2012). Para encontrar el número óptimo de clusters k utilizamos el método de codo y silueta.

7.3.1.5.1 Método de codo

El método de codo da más importancia en las distancias intra-cluster y cuanto menor se esta distancia mejor, ya que significa que los clusters formados son más compactos (Ketchen and Shook, 1996). El método del codo utiliza la suma de distancias al cuadrado de cada punto del clúster a su centroide a la cual le denomina “distorsión”. Utiliza los valores de distorsión obtenidos tras aplicar el K-means a diferente número de clúster (desde 1, 2, 3, ..., j) y se representan en una gráfica lineal la distorsión vs el número de clústeres. En dicha grafica se debe apreciar un cambio brusco en la pendiente (el codo) en el número óptimo de cluster. En este punto la disminución de la varianza intra-clúster se desacelera, lo que indica que aumentar el número de clústeres no mejorará la compactación de estos.

7.3.1.5.2 Método de silueta

El método de silueta mide la calidad del agrupamiento (Rousseeuw, 1987) ya que implica dos factores de agrupamiento: separación (es decir, distancia promedio al otro grupo más

cercano) y compacidad (es decir, distancia promedio dentro del grupo) (Handl y Knowles, 2005). El coeficiente de silueta para x_i esta dado por $s(x_i)$ como se muestra en la **Ecuación 45**.

$$s(x_i) = \frac{b(x_i) - a(x_i)}{\max\{a(x_i), b(x_i)\}} \quad (45)$$

Donde $a(x_i)$ es la distancia promedio de x_i a todos los demás puntos en el mismo clúster o dicho de otra forma la distancia media intra-cluster. Mientras que $b(x_i)$ es la distancia promedio de x_i a todos los demás puntos en el clúster más cercano. El valor de $s(x_i)$ se encuentra en un rango de $[-1,1]$.

Cuando son valores negativos indica un mal agrupamiento ya que los puntos están cerca de los clústeres vecinos por lo tanto están asignados al clúster erróneo. Cuando es 0 indica que el punto está muy cerca o en la frontera de decisión entre dos clústeres. Cuando es 1 indica un buen agrupamiento ya que los puntos están cerca de su propio clúster y lejos de los clústeres vecinos. Por lo tanto, el coeficiente de silueta para todo el agrupamiento se obtiene con la **Ecuación 46**.

$$SC = \frac{1}{n} \sum_{i=1}^n s(x_i) \quad (46)$$

El método de la silueta calcula la media de los coeficientes de silueta de todos los puntos para diferentes valores de k . El número óptimo de clústers k es aquel que maximiza la media de los coeficientes de silueta para un rango de valores de k . Se alcanza una configuración de agrupamiento adecuada cuando la mayoría de los puntos obtienen valores altos de silueta. De lo contrario, la disposición de agrupamiento puede tener demasiados o muy pocos agrupamientos.

7.3.2 Resultados

7.3.2.1 Correlación

En la **Figura 24** se muestra la matriz de correlación de los 17 objetivos de desarrollo sostenible y el indicador de desperdicio de comida en los hogares (Food Waste), donde el color rojo indica una correlación positiva mientras que el color azul indica una correlación

negativa. Entre mayor intensidad de color mayor es la correlación. Visualmente se observa que el indicador de desperdicio de comida en los hogares y los objetivos de desarrollo sostenible 10 de reducción de las desigualdades, 14 de vida submarina y 15 de vida de ecosistemas terrestres tienen líneas muy tenues lo que indica que no tiene mucha relación con otros objetivos.




Figura 24. Matriz de correlación de los 17 SDG y el indicador de desperdicio de comida en los hogares (Food-Waste)

Para realizar un análisis se ordenaron los pares de objetivos de desarrollo sostenible de mayor a menor correlación positiva y negativa, en la **Tabla 8** solo se muestran los 10 primeros pares. En donde se muestra que existe un objetivo con más cantidad de correlaciones positivas con otros objetivos, el cual es el SDG 3, es decir que cuando exista un puntaje alto en el objetivo 3 de salud y bienestar también se va a tener un puntaje alto en el objetivo 9 Industria, innovación e infraestructura, en el objetivo 1 fin de la pobreza, en el objetivo 7 energía asequible y no contaminante, en el objetivo 4 educación de calidad, en el objetivo 11 ciudades y comunidades sostenibles, en el objetivo 6 agua limpia y saneamiento y en el objetivo 16

paz, justicia e instituciones sólidas; o de manera inversa cuando SDG 3 tenga bajo puntaje los demás objetivos también.

El objetivo con más correlaciones negativas con otros objetivos es el SDG 12, es decir que cuando se tiene un alto puntaje en el objetivo 12 de producción y consumo responsable se tienen bajos puntajes en el objetivo 9 de industria, innovación e infraestructura, en el objetivo 16 de paz, justicia e instituciones sólidas, en el objetivo 3 de salud y bienestar, en el objetivo 6 de agua limpia y saneamiento, en el objetivo 11 de ciudades y comunidades sostenibles, en el objetivo 7 de energía asequible y no contaminante y en el objetivo 4 de educación de calidad.

También se observó que el par con la mayor correlación positiva fue entre el objetivo 9 de industria, innovación e infraestructura y el objetivo 3 de salud y bienestar, lo que indica que los países con mejor puntaje del SDG 9 tienen también alto puntaje del SDG3. Mientras que el par con mayor correlación negativa es entre SDG 9 y SDG 12, lo que indica que los países con alto puntaje en el objetivo 9 industria, innovación e infraestructura tienen bajos puntajes en el objetivo 12 de producción y consumo responsable.

Tabla 8. Pares de objetivos de desarrollo sostenible e indicador con mayor correlación positiva y negativa.

SDG	SDG	r	SDG	SDG	r
SDG 9	SDG 3	0.883	SDG 9	SDG 12	-0.841
SDG 12	SDG 13	0.878	SDG 16	SDG 12	-0.817
SDG 1	SDG 3	0.864	SDG 12	SDG 3	-0.782
SDG 7	SDG 3	0.849	SDG 13	SDG 9	-0.764
SDG 3	SDG 4	0.838	SDG 12	SDG 6	-0.701
SDG 3	SDG 11	0.829	SDG 11	SDG 12	-0.682
SDG 3	SDG 6	0.818	SDG 13	SDG 16	-0.681
SDG 3	SDG 16	0.813	SDG 13	SDG 3	-0.666
SDG 9	SDG 16	0.812	SDG 12	SDG 7	-0.653
SDG 11	SDG 7	0.810	SDG 4	SDG 12	-0.645

7.3.2.2 Validación

Para conocer y validar el número óptimo de clúster k se usó el método de codo y el método de silueta. Debido a que tenemos dos conjuntos de datos se deben obtener el número óptimo de cluster k para cada uno.

7.3.2.2.1 Método de codo

En la **Figura 25** se observan las gráficas del método de codo donde en el eje x se tiene el número de grupos k y en el eje y la distorsión o SED, mientras que la línea verde discontinua mide el tiempo de cómputo que se utilizó para entrenar al modelo de agrupamiento. Con los resultados del método de codo se determina que 3 es el número de grupos óptimo para la base de datos de los 17 objetivos de desarrollo sostenible. Mientras que para la base de datos de los 17 SDG y el indicador de desperdicio de alimentos se tiene también 3 como número óptimo de grupo.




Figura 25. Gráfico de codo para los 17 SDG (izquierda) y 17 SDG + indicador de desperdicio de comida (derecha)

7.3.2.2.2 Metodo de silueta

Figura 26 muestra los resultados del método de silueta mediante un gráfico de barras donde el eje x representa el número de clusters k y el eje y el coeficiente promedio de silueta. Se observa que para la base de datos con los 17 objetivos el mayor coeficiente promedio de silueta es de aproximadamente 0.34 en $k=2$ el cual es el número óptimo de clusters, sin embargo consideramos que eran muy pocos grupos para segmentar y decidimos tomar el siguiente valor de $k=3$ que tiene un coeficiente aproximado de 0.26.

Para la base de datos de los 17 objetivos y el indicador de desperdicio de alimentos se tiene el valor de 0.34 en el coeficiente promedio de silueta cuando $k=2$, sin embargo queríamos tener mayor segmentación para nuestros fines y el valor de $k=4$ era el siguiente con mejor coeficiente.




Figura 26. Graficas de coeficiente promedio de silueta para los 17 SDG (izquierda) y 17 SDG + indicador de desperdicio de comida (derecha)

El Visualizador de silueta muestra el coeficiente de silueta para cada muestra por grupo, evaluando visualmente la densidad y la separación entre grupos. En cada grafica se representan los grupos con un color diferente y la línea punteada es el coeficiente promedio de silueta. En la **Figura 27** se observan las agrupaciones con la base de datos de los 17 objetivos en donde las mejores opciones de clúster son $k=2$ y $k=3$ ya que presentan una buena distribución y densidad de los grupos, además cada grupo está por encima del coeficiente promedio de silueta. En el cluster $k=4$ se presenta un grupo con valores por debajo del coeficiente promedio de silueta y junto con el clúster $k=5$ se presentan varios valores por debajo de cero lo que significa que es posible que esos datos se hayan asignado al grupo incorrecto.




Figura 27. Visualizador de silueta de agrupamiento de k-means para 17 SDG en k grupos, k=2, 3, 4 y 5

La **Figura 28** se muestran los diagramas de silueta para los 17 SDG y el indicador de desperdicio de alimentos en k=2,3,4 y 5. Donde los grupos con mayor coeficiente promedio de silueta son k=2 y k=3 sin embargo este último presenta varios valores por debajo de cero que indican que esos datos pueden estar en el grupo equivocado. En una situación peor se encuentra k=5 ya que tiene valores negativos y además un grupo no alcanza el coeficiente promedio de silueta. Por tal motivo decidimos agrupar la base de datos con el siguiente clúster con mayor coeficiente de silueta k=4 ya que no tiene tantos valores negativos y todos sus grupos alcanzan el valor de su coeficiente promedio de silueta.




Figura 28. Visualizador de silueta de agrupamiento de k-means de 17 SDG e indicador de desperdicio de comida en k grupos, $k=2, 3, 4$ y 5

7.3.2.3 Análisis de grupos

7.3.2.3.1 Base de datos de los 17 SDGs

La **Tabla 9** muestra que los grupos 0, 1 y 2 fueron caracterizados de acuerdo con la cantidad de puntajes promedio altos, medios y bajos de los países que lo conforman. Esto con el fin de nombrarlos correctamente en función del cumplimiento de los objetivos de desarrollo sostenible. Por ejemplo, el grupo 2 tiene la mayor cantidad de objetivos de desarrollo sostenible con puntajes altos por lo cual se le denominó grupo con sostenibilidad alta, mientras el grupo 1 tiene la mayor cantidad de puntajes medios al cual se le denominó grupo con sostenibilidad media y finalmente el grupo 0 tiene la mayor cantidad de puntajes bajos y se le denominó grupo con sostenibilidad baja.

Tabla 9. Caracterización de grupos

Datos de 17 SDGs		
	Grupo	Cantidad de objetivos

Denominación del grupo		Con puntajes promedio altos	Con puntajes promedio medios	Con puntajes promedio bajos
Sustentabilidad alta	2	15	0	2
Sustentabilidad media	1	0	16	1
Sustentabilidad baja	0	2	1	14

En la **Tabla 10** se muestra que los países dentro del grupo con sostenibilidad alta tienen altos puntajes en el objetivo 1 fin de la pobreza, en el objetivo 2 hambre cero, en el objetivo 3 salud y bienestar, en el objetivo 4 educación de calidad, en el objetivo 5 igualdad de género, en el objetivo 6 agua limpia y saneamiento, en el objetivo 7 energía asequible y no contaminante, en el objetivo 8 trabajo decente y crecimiento económico, en el objetivo 9 industria, innovación e infraestructura, en el objetivo 10 reducción de las desigualdades, en el objetivo 11 ciudades y comunidades sostenibles, en el objetivo 14 vida submarina, en el objetivo 15 vida de ecosistemas terrestres, en el objetivo 16 paz, justicia e instituciones sólidas y en el objetivo 17 alianzas para lograr los objetivos. Mientras que tienen bajos puntajes en el objetivo 12 producción y consumo responsable y en el objetivo 13 acción por el clima.

Los países dentro del grupo con sostenibilidad media tienen casi en todos los objetivos puntajes medios con excepción del objetivo 15 vida de ecosistemas terrestres en el cual tienen puntajes bajos. Los países del grupo de sostenibilidad baja tienen puntajes bajos en la mayoría de los objetivos con excepción del objetivo 12 producción y consumo responsable y el objetivo 13 acción por el clima donde tienen los puntajes más altos. Además, en el objetivo 15 vida de ecosistemas terrestres tienen puntajes medios.

Tabla 10. Puntajes promedio de los 17 SDGs de cada grupo

Objetivos de desarrollo sostenible	Grupo con sostenibilidad		
	Alta	Media	Baja
SDG 1	99.40	87.73	34.56
SDG 2	66.14	61.49	51.56
SDG 3	91.85	73.27	41.76
SDG 4	96.41	84.66	45.70
SDG 5	79.13	63.66	50.42
SDG 6	82.36	69.49	50.60
SDG 7	78.21	68.99	33.31
SDG 8	82.74	72.09	62.63
SDG 9	86.98	51.30	21.67

SDG 10	87.93	54.94	49.55
SDG 11	88.37	75.99	50.99
SDG 12	57.85	84.62	95.14
SDG 13	62.38	89.73	98.04
SDG 14	54.75	50.90	43.75
SDG 15	77.36	63.47	66.47
SDG 16	80.78	60.12	45.92
SDG 17	67.40	64.11	50.25

7.3.2.3.2 Base de datos de los 17 SDGs y el indicador de desperdicio de alimentos

En la **Tabla 11** se observa que los países pertenecientes al grupo con sostenibilidad alta tienen altos puntajes en 15 objetivos y bajos puntajes en 2 objetivos los cuales son SDG 12 producción y consumo responsable y SDG 13 acción por el clima, además de tener muy bajas cantidades de desperdicio de comida en el hogar.

Los países del grupo de sostenibilidad media alta se caracterizan por tener puntajes por arriba de la media, pero más bajos que los países del grupo de sostenibilidad alta; tener bajos puntajes en el SDG 15 de vida de ecosistemas terrestres y la mayor cantidad de desperdicio de comida en el hogar.

En el grupo de sostenibilidad media baja los países se caracterizan por tener puntajes por debajo de la media en casi todos los objetivos, así como bajos puntajes en el objetivo 10 reducción de las desigualdades y el objetivo 14 vida submarina.

Los países del grupo con sostenibilidad baja tienen los puntajes más bajos en la mayoría de los objetivos con excepción de los objetivos 12 producción y consumo responsable y en el objetivo 13 acción por el clima. Además de tener un desperdicio de alimentos por arriba de la media.

Tabla 11. Puntajes promedio de los 17 SDGs e indicador de desperdicio de alimentos de cada grupo

Objetivos de desarrollo sostenible	Grupo con sostenibilidad			
	Alta	Media alta	Media baja	baja
Food waste	2,072,104	5,815,644	2,368,035	4,341,381
SDG 1	99.40	92.18	47.73	33.97
SDG 2	66.14	62.43	58.40	46.51

SDG 3	91.85	76.19	51.05	39.27
SDG 4	96.41	86.58	63.24	39.44
SDG 5	79.13	63.69	63.20	42.21
SDG 6	82.36	70.07	59.21	48.17
SDG 7	78.21	71.27	47.56	28.51
SDG 8	82.74	72.55	67.56	60.39
SDG 9	86.98	54.44	31.44	17.40
SDG 10	87.93	58.32	40.71	54.60
SDG 11	88.37	78.35	61.24	45.82
SDG 12	57.85	83.62	92.88	95.11
SDG 13	62.38	88.81	96.56	97.96
SDG 14	54.75	51.72	41.05	48.04
SDG 15	77.36	62.54	67.51	65.92
SDG 16	80.78	62.31	49.84	43.32
SDG 17	67.40	66.03	54.28	47.93

7.3.2.4 Clasificación de países

Se muestran los resultados de la clasificación con $k=3$ usando la base de datos de los 17 SDGs, donde los grupos se nombran de acuerdo con su nivel de sostenibilidad alta, media y baja en base a sus puntajes de cumplimiento de los objetivos de desarrollo sostenible. En la **Figura 29** el grupo con sostenibilidad alta tiene 37 países que se visualizan de color verde, el grupo de sostenibilidad media tiene 63 países con color amarillo y el grupo de sostenibilidad baja tiene 43 países en color rojo.




Figura 29. Clasificación de países de acuerdo con su nivel de sostenibilidad (Base de datos de 17 SDGs).

En la **Figura 30** se visualiza la clasificación de los países con la base de datos de los 17 SDGs y el indicador de desperdicio de alimentos, con $k=4$ se muestra que el grupo con sostenibilidad alta tiene 37 países que se observan con un color verde, el grupo con sostenibilidad media alta tiene 52 países con una coloración amarilla, el grupo con sostenibilidad media baja tiene 28 países con un color naranja y el grupo con sostenibilidad baja tiene 26 países con un color rojo.




Figura 30. Clasificación de países de acuerdo con su nivel de sostenibilidad (Base de datos de 17 SDGs e indicador de desperdicio de alimentos).

Este estudio analiza el progreso de los países en los Objetivos de desarrollo sostenible mediante técnicas de clustering, revelando patrones clave. Los países desarrollados muestran avances en la mayoría de los objetivos, pero rezagos en producción responsable (ODS 12) y acción climática (ODS 13). Las naciones en desarrollo enfrentan mayores desafíos, aunque destacan en algunas metas ambientales. El análisis del desperdicio de alimentos evidenció que los países más sostenibles gestionan mejor sus recursos alimentarios. Las recientes crisis globales han ampliado estas brechas, destacando la necesidad de políticas adaptativas y cooperación internacional. Este marco metodológico ayuda a identificar prioridades para avanzar hacia la Agenda 2030.

7.4 Fase 4. Comparación de Métodos para Seleccionar Semanas Representativas en Planificación Energética con Energías Renovables

7.4.1 Metodología

La metodología para optimizar sistemas energéticos con alta participación de energías renovables que combina técnicas de selección temporal con modelado matemático avanzado (**Figura 31**). Primeramente, se realiza la recopilación de los datos para el cálculo del NLDC en cada nodo del sistema eléctrico estudiado. Este conjunto de datos se utiliza para obtener las semanas representativas a partir de diferentes algoritmos, los cuales son: el agrupamiento K-means con métrica euclidiana, el agrupamiento K-means para series temporales con métrica de deformación dinámica del tiempo DTW y el método combinatorio de Sisternes y Webster (2013). Con el fin de comparar las semanas representativas resultantes en cada método se aplican en un modelo matemático de operación y planificación de una región del sistema eléctrico a lo largo de 10 años.



Figura 31. Metodología de la fase 4

7.4.2 Calculo del NLDC de cada nodo

Un año se conforma por 52 semanas, de las cuales se requiere seleccionar 4 semanas representativas (cada semana tiene 168h) (**Figura 32**) que se utilizaran en el modelo de operación y planificación energética de la siguiente sección.




Figura 32. Perfil de carga neta aproximado de 4 semanas representativas del conjunto total de 52 semanas.

Las tres metodologías se basan en la selección de 4 semanas representativas de una serie de carga neta con horizonte de un año. Se utiliza la carga neta porque representa la variabilidad combinada de la demanda y las tecnologías de generación de energía variable que deben equilibrarse con la generación despachable. La curva de duración de carga neta (*NLDC*) se calcula con la diferencia entre la demanda y la salida de los recursos energéticos variables, como son la energía eólica y la energía solar fotovoltaica. En donde la producción variable por hora se calcula como el producto del factor de capacidad horario CF de cada tecnología de generación variable y la capacidad instalada de esa tecnología ($\bar{W}$ y $\bar{S}$) (**Ecuación 47**).

$$\begin{aligned}
 NLDC_{r,t} &= D_{r,t} - CF_{r,t}^{wind} \bar{W} - CF_{r,t}^{solar} \bar{S} \\
 \text{s.t.: } NLDC_{r,t-1} - NLDC_{r,t} &\geq 0, \quad \forall r \in R, t \in T
 \end{aligned}
 \tag{47}$$

La curva de duración de carga neta aproximada ($NLDC$) se obtiene de escalar las horas contenidas en las cuatro semanas representativas a un año (52 semanas) y posteriormente ordenar de manera decreciente la serie. Para elegir entre todas las posibles aproximaciones de semanas, utilizamos la minimización del error de mínimos cuadrados entre la $NLDC$ y su aproximación $NLDC$. La aproximación óptima viene dada por la solución del siguiente problema de optimización (**Ecuación 48**).

$$\min \|NLDC - NLDC\|^2 \quad (48)$$

Se utiliza el error cuadrático medio (RMSE) como métrica de evaluación del desempeño de la aproximación de la curva de duración de carga neta, como se observa en la **Ecuación 49**.

$$RMSE = \sqrt{\frac{\sum_{t=1}^{8,736} (NLDC_t - NLDC_t)^2}{8,736}} \quad (49)$$

El algoritmo de selección de semanas de Sisternes y Webster (2013) consiste en una búsqueda exhaustiva a lo largo de todas las posibles combinaciones de semanas para determinar qué combinación arroja el mínimo error. Este proceso de enumeración se implementa mediante un número de bucles anidados igual al número de semanas a seleccionar, que en este caso es 4. El peso por el que se tiene que escalar cada hora dentro del grupo de semanas representativas para generar una serie de un año es igual a $52/4=13$. El conjunto de datos fue de 52 semanas por 168 h de cada semana, sin embargo, este conjunto es la sumatoria de las NLDC de cada nodo.

7.4.3 Clustering

En la etapa de preprocesamiento de datos, estos se normalizan utilizando la técnica de StandardScaler de la paquetería sklearn.preprocessing (Scikit learn, 2023). En donde se elimina la media y se escala a la varianza unitaria.

Algoritmo de agrupamiento K-means para series temporales con métrica DTW

La agrupación de series temporales es una técnica que sirve para explorar el patrón implícito que tienen en común un conjunto de series temporales que en este caso son las *NLDC* de cada nodo. DTW busca la alineación temporal que minimiza la distancia euclidiana entre series alineadas. La distancia acumulada en cualquier ubicación está dada por la **Ecuación 50**.

$$D(x_p, y_q) = d(x_p, y_q) + \min \{ D(x_{p-1}, y_q), D(x_p, y_{q-1}), D(x_{p-1}, y_{q-1}) \} \quad (50)$$

Donde en $d(x_p, y_q) = (x_p - y_q)^2$ se usa regularmente la distancia euclidiana, aunque también se puede usar otra distancia.

El problema de optimización se muestra con la **Ecuación 51**, que es la distancia de deformación dinámica del tiempo entre dos series de tiempo *X* y *Y* con la misma longitud, que encuentra la ruta de deformación óptima.

$$dtw(p, q) = \min \sum \| D(x_p, y_q) \| \quad (51)$$

7.4.4 Modelo Matemático

El problema requiere la gestión de un conjunto diverso de tecnologías, tanto convencionales como renovables, en la generación de electricidad a nivel regional. Estas fuentes deben ser capaces de generar la cantidad necesaria de energía para satisfacer la demanda en momentos específicos, mientras gestionan eficientemente los flujos de energía para cubrir directamente las necesidades eléctricas de una región determinada o almacenarla para usos futuros. En primer lugar, las fuentes de energía renovable deben poder dirigir los flujos de energía producidos hacia el almacenamiento o hacia la satisfacción inmediata de la demanda. Por otro lado, las tecnologías convencionales se dividen en aquellas que utilizan gas natural y aquellas que emplean otros tipos de combustibles. En contraste, las tecnologías renovables se clasifican en variables y no variables según la disponibilidad del recurso natural en cada una de ellas. El problema de optimización disyuntiva busca identificar la combinación óptima de tecnologías de generación de energía que deben estar activas simultáneamente, así como las unidades de almacenamiento necesarias para garantizar el funcionamiento eficiente del proceso. Además, se consideran las capacidades de estas unidades y los costos asociados a

su uso. Este problema de optimización se enfoca en la planificación a lo largo de un horizonte temporal que abarca varios años en el futuro, considerando condiciones operativas horarias.

Formulación Matemática

Se presenta el modelo matemático propuesto para lograr una producción óptima de energía eléctrica en un sistema a gran escala a lo largo de un horizonte temporal. La representación esquemática de la estructura propuesta se muestra en la **Figura 33**. En este contexto, un conjunto de tecnologías ($j = 1, 2, \dots, J$) opera para satisfacer la demanda de energía en una región geográfica específica ($r = 1, 2, \dots, R$) durante un período horario ($t = 1, 2, \dots, T$) y un período anual ($s = 1, 2, \dots, S$). La energía generada por tecnologías renovables, tanto variables ($jrt = 1, 2, \dots, J$) como no variables ($jrh = 1, 2, \dots, J$), se almacena en dispositivos de almacenamiento de energía ($i = 1, 2, \dots, I$) para cubrir la demanda cuando sea necesario. Por otro lado, las tecnologías convencionales ($jt = 1, 2, \dots, J$) se categorizan en dos grupos: las que utilizan gas natural como combustible ($jg = 1, 2, \dots, J$) y las que emplean fuelóleo ($jc = 1, 2, \dots, J$). La formulación matemática incluye ecuaciones para modelar la generación de cada tipo de tecnología, incorporando tanto el dimensionamiento como los costos asociados a la producción y el equipo utilizado. A continuación, se presenta el modelo de optimización para la planificación energética.

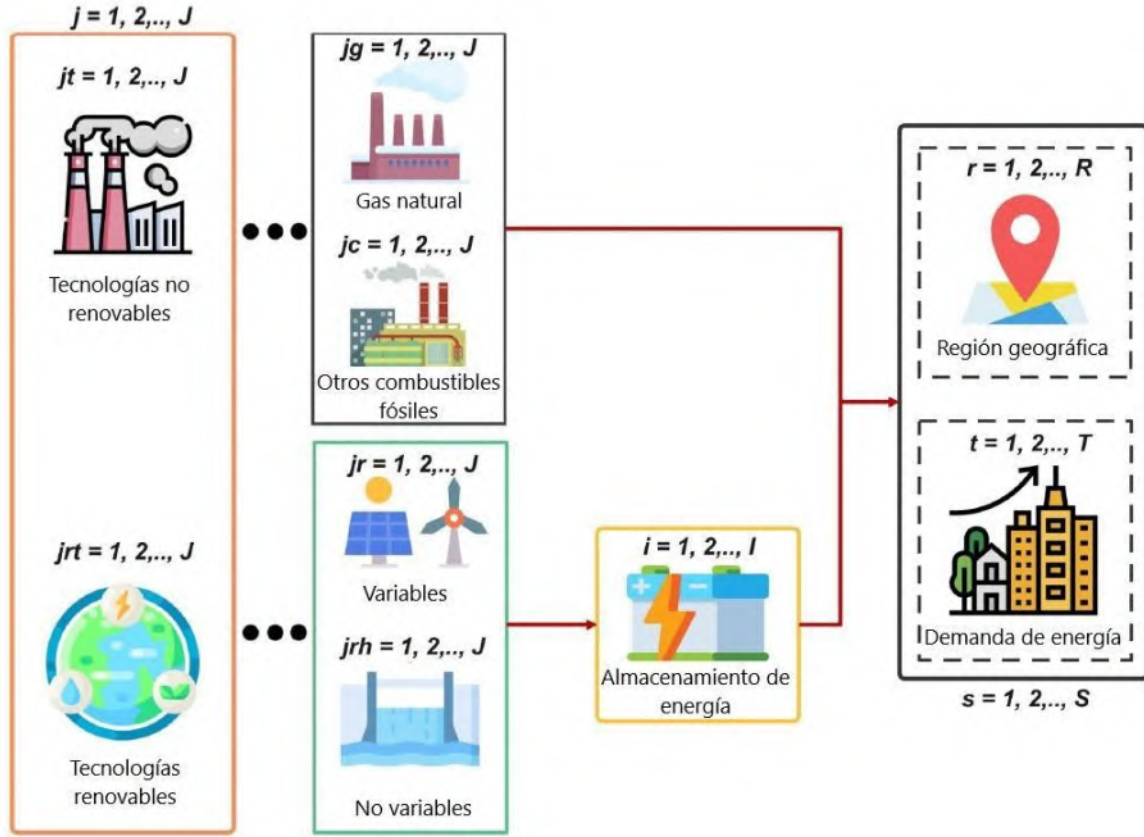


Figura 33. Representación esquemática de la metodología general implementada.

Demanda de energía eléctrica en cada región de transmisión

La demanda de electricidad ($EDEM$) en cada región (r), período horario (t) y período anual (s) puede cubrirse mediante generación local ($eprodem$) de las tecnologías disponibles (j), energía producida y transmitida desde otra región (r'), y energía liberada desde sistemas de almacenamiento. En el caso de energía externa a la región r , se debe considerar la eficiencia de transmisión (η^{trans}) para contabilizar las pérdidas asociadas al transporte de electricidad. Además, se introduce un término para la demanda no satisfecha ($umdem$) para garantizar equilibrio y evitar escenarios inviables. Sin embargo, se espera que la demanda siempre sea satisfecha, por lo que la demanda no satisfecha se penaliza en la función objetivo.

$$EDEM_{r,t,s} = umdem_{r,t,s} + \sum_j eprodem_{r,j,t,s} + \sum_{r' \neq r} \sum_j etrans_{r',r,j,t,s} (\eta^{trans}) + \sum_i edes_{r,i,t,s} \quad \forall r \in R, \forall t \in T, \forall s \in S \quad (52)$$

Producción de electricidad a partir de tecnologías convencionales

La electricidad producida ($ep_{r,jt,t}$) por cada tecnología convencional (jt) en la región r se calcula sumando la energía utilizada para cubrir la demanda local y la energía transmitida desde la región r hacia la región r' , que puede estar ubicada en otra zona con infraestructura de transmisión disponible.

$$ep_{r,jt,t,s} = eprod_{r,jt,t,s} + \sum_{r' \neq r} etrans_{r,r',jt,t,s} \quad \forall r \in R, \forall jt \in J, \forall t \in T, \forall s \in S \quad (53)$$

Cantidad de combustible consumido por tecnologías convencionales

La cantidad de combustible requerida por tecnologías térmicas que usan gas natural (jg) se determina sumando el volumen de gas natural ($mgas$) multiplicado por su valor calorífico ($LHVG$), y la relación entre la eficiencia térmica de los combustibles y la electricidad ($\eta_{jg}^{convgas}$).

$$ep_{r,jg,t,s} = \frac{mgas_{r,jg,t,s} (LHVG)}{(\eta_{jg}^{convgas})} \quad \forall r \in R, \forall jg \in J, \forall t \in T, \forall s \in S \quad (54)$$

Para algunas tecnologías térmicas (jt) que operan con diferentes tipos de combustibles, como en el caso de este tipo específico de tecnología (jc), la cantidad de combustible se calcula como:

$$ep_{r,jc,t,s} = \frac{mcom_{r,jc,t,s} (LHVC)}{(\eta_{jc}^{convotr})} \quad \forall r \in R, \forall jc \in J, \forall t \in T, \forall s \in S \quad (55)$$

Donde $mcom_{r,jc,t,s}$ es la masa de otros combustibles.

Producción de electricidad renovable

La electricidad producida por tecnologías renovables en cada región (ep) se estima sumando la energía utilizada para cargar los sistemas de almacenamiento ($ecar$), la energía renovable transmitida a otras regiones ($etrans$) y la energía no utilizada (cu), conocida como "curtailment". Por otro lado, las tecnologías renovables (jrt) se dividen en tecnologías

variables (jr), cuya producción está limitada por la disponibilidad del recurso y la variabilidad climática (solar o eólica), y tecnologías no variables (jr_h), que no están sujetas a restricciones de recurso (como la hidroeléctrica), y se modelan de la siguiente manera:

$$ep_{r,jr,t,s} = eprodem_{r,jr,t,s} + \sum_i ecar_{r,jr,i,t,s} + \sum_{r \neq r'} etrans_{r,r',jr,t,s} + cu_{r,jr,t,s} \quad \forall r \in R, \forall jr \in J, \forall t \in T, \forall s \in S \quad (56)$$

$$ep_{r,jr_h,t,s} = eprodem_{r,jr_h,t,s} + \sum_i ecar_{r,jr_h,i,t,s} + \sum_{r \neq r'} etrans_{r,r',jr_h,t,s} + cu_{r,jr_h,t,s} \quad \forall r \in R, \forall jr_h \in J, \forall t \in T, \forall s \in S \quad (57)$$

Energía renovable total no utilizada

La energía renovable que no puede ser aprovechada por el sistema debido a restricciones técnicas de la infraestructura se refleja en la función objetivo con una penalización.

$$cuT_s = \sum_r \sum_{jr_t} \sum_t cu_{r,jr,t} \quad \forall s \in S \quad (58)$$

Restricciones operativas para tecnologías convencionales

Es crucial limitar la operación de las diversas tecnologías convencionales para lograr la producción de energía deseada, como se ilustra en las Ecuaciones 59-62.

Aumento en la generación de electricidad

El crecimiento en la generación de electricidad incluye la capacidad de producción ($CAPROD$) de las diversas tecnologías térmicas (jt), junto con la proporción de capacidad instalada que puede incrementarse por hora ($RUMAX$).

$$ep_{r,jt,t,s} - ep_{r,jt,t-1,s} \leq RUMAX_{jt} (CAPROD_{r,jt,t,s}), \quad \forall r \in R, \forall jt \in J, \forall t > 1 \in T, \forall s \in S \quad (59)$$

Reducción en la generación de electricidad

La reducción en la generación de electricidad considera la capacidad de producción ($CAPROD$) de las diferentes tecnologías térmicas (jt), así como la proporción de capacidad instalada que puede reducirse por hora ($RDMAX$).

$$ep_{r,jt,t-1,s} - ep_{r,jt,t,s} \leq RDMAX_{jt} (CAPROD_{r,jt,t,s}), \quad \forall r \in R, \forall jt \in J, \forall t > 1 \in T, \forall s \in S \quad (60)$$

Generación máxima y mínima de tecnologías convencionales

Las siguientes restricciones controlan la operación de las plantas para evitar paradas y están relacionadas con la capacidad de producción ($CAPROD$). Los límites de generación máxima y mínima se establecen como:

$$ep_{r,jt,t,s} \leq MAXPROD_{r,jt,t} \quad \forall r \in R, \forall jt \in J, \forall t \in T, \forall s \in S \quad (61)$$

$$ep_{r,jt,t,s} \geq MINPROD_{r,jt,t} \quad \forall r \in R, \forall jt \in J, \forall t \in T, \forall s \in S \quad (62)$$

Restricciones operativas de tecnologías renovables

La producción de energía a partir de tecnologías renovables variables (jr) está restringida por la disponibilidad del recurso (solar o eólico). Dado que no es factible aprovechar el 100% de la capacidad instalada, se utiliza el factor de capacidad (CF) para determinar la fracción de la capacidad instalada que puede ser utilizada por las diferentes tecnologías en cada región y período. Asimismo, también se considera la nueva capacidad a instalar para cada tecnología (ic^{renew}).

$$ep_{r,jr,t,s} = CAPROD_{r,jr,t} \times CF_{r,jr,t} + ic_{r,jr}^{renew} \times CF_{r,jr,t}, \quad \forall r \in R, \forall jr \in J, \forall t \in T, \forall s \in S \quad (63)$$

Instalación de tecnologías renovables

Cuando es ventajoso instalar cualquier tecnología renovable (jr) en una región específica (r), la variable binaria y^{RENEW} se establece en 1; de lo contrario, se asigna un valor de cero. Además, estas variables binarias permiten restringir la capacidad seleccionada de tecnologías renovables ic^{renew} dentro del rango de capacidades mínimas y máximas disponibles en el mercado ($CMINRENEW$ y $CMAXRENEW$).

$$y_{r,jr}^{RENEW} (CMINRENEW_{r,jr}) \leq ic_{r,jr}^{renew}, \quad \forall r \in R, \forall jr \in J \quad (64)$$

$$y_{r,jr}^{RENEW} (CMAXRENEW_{r,jr}) \geq ic_{r,jr}^{renew}, \quad \forall r \in R, \forall i \in I \quad (65)$$

Instalación de sistemas de almacenamiento de energía

La decisión de instalar ESS (Sistemas de Almacenamiento de Energía) se representa mediante variables binarias. Cuando es beneficioso instalar un sistema de almacenamiento

en una región específica (r), la variable binaria y^{ESS} se establece en 1. De lo contrario, si no es favorable tener una unidad de almacenamiento, la variable binaria (y^{ESS}) se establece en cero. Además, estas variables binarias permiten ajustar la capacidad seleccionada del sistema de almacenamiento ic^{renew} dentro del rango de capacidades mínimas y máximas disponibles en el mercado ($CMINESS$ y $CMACESS$).

$$y_{r,i}^{ESS} (CMINESS_{r,i}) \leq ices_{r,i}, \quad \forall r \in R, \forall i \in I \quad (66)$$

$$y_{r,i}^{ESS} (CMACESS_{r,i}) \geq ices_{r,i}, \quad \forall r \in R, \forall i \in I \quad (67)$$

Balance de energía en sistemas de almacenamiento

Para conocer la cantidad de energía contenida en los sistemas de almacenamiento de energía ($ealm$) de cada región (r) en un período horario (t) y en un período anual (s), se debe realizar un balance de energía que considere la energía que se carga y descarga en cada período, así como sus respectivas eficiencias de carga y descarga (η_i^{car} y η_i^{des}).

$$ealm_{r,i,t,s} = ealm_{r,i,t-1,s} + \left(\sum_{jrt} ecar_{r,jrt,i,t,s} \right) \left(\eta_i^{car} \right) - \frac{edes_{r,i,t,s}}{\eta_i^{des}}, \quad \forall r \in R, \forall i \in I, \forall t > 1 \in T, \forall s \in S \quad (68)$$

$$ealm_{r,i,t,s} = EALM_{r,i}^0 + \left(\sum_{jrt} ecar_{r,jrt,i,t,s} \right) \left(\eta_i^{car} \right) - \frac{edes_{r,i,t,s}}{\eta_i^{des}}, \quad \forall r \in R, \forall i \in I, \forall t = 1 \in T, \forall s \in S \quad (69)$$

Restricciones operativas de sistemas de almacenamiento de energía

La **Ecuación 70** restringe la cantidad de energía almacenada para evitar exceder la capacidad instalada del ESS. También establece que la energía inyectada en el sistema de almacenamiento ($ecar$) no debe exceder la capacidad que cada tecnología puede transferir en un período desde las tecnologías convencionales disponibles (jrt).

$$ealm_{r,i,t,s} \leq ices_{r,i,s} \quad \forall r \in R, \forall i \in I, \forall t \in T, \forall s \in S \quad (70)$$

$$\sum_{jrt} ecar_{r,jrt,i,t,s} \left(\eta_i^{car} \right) \leq ices_{r,i,s} \quad \forall r \in R, \forall i \in I, \forall t \in T, \forall s \in S \quad (71)$$

De manera similar, la energía descargada se limita ($edes$) por el sistema de almacenamiento i en un período t para que los ESS no descarguen más electricidad de la que pueden.

$$\frac{edes_{r,i,t,s}}{\eta_i^{des}} \leq ices_{r,i,s}, \quad \forall r \in R, \forall i \in I, \forall t \in T, \forall s \in S \quad (72)$$

Además, se especifican las siguientes ecuaciones para considerar la existencia de unidades de almacenamiento de energía, las cuales también limitan la carga y descarga del almacenamiento en el mismo período, obligando al modelo a cargar y descargar el almacenamiento en un período diferente determinado mediante la variable binaria ω^{ESS} , que está relacionada con el porcentaje de capacidad que la batería puede descargar $CAPDESC$ y la capacidad máxima de almacenamiento ($CMAXESS$).

$$\sum_{jrt} ecar_{r,jrt,i,t,s} \leq \omega_{r,i,t,s}^{ESS} (CAPDESC_{r,i}) (CMAXESS_{r,i}), \quad \forall r \in R, \forall i \in I, \forall t \in T, \forall s \in S \quad (73)$$

$$edes_{r,i,t,s} \leq (1 - \omega_{r,i,t,s}^{ESS}) (CAPDESC_{r,i}) (CMAXESS_{r,i}), \quad \forall r \in R, \forall i \in I, \forall t \in T, \forall s \in S \quad (74)$$

Restricciones operativas en la transmisión de energía

Cuando se trata de la energía transmitida ($etrans$) entre dos regiones, es necesario incluir todos los flujos a través de una línea de transmisión. Este valor no debe exceder la capacidad del enlace de transmisión CT de la línea. La energía se transmite desde la región r hacia otra región r' .

$$CT \geq \sum_{r' \neq r} \sum_j etrans_{r',r,j,t,s} \quad \forall t \in T, \forall s \in S \quad (75)$$

Emisiones totales

Las emisiones totales están relacionadas con la cantidad de combustible utilizado en cada región (r) para cada tipo de planta de energía convencional (jrt). Se considera un factor de emisión ($EMIS$) que determina la cantidad de emisiones de CO_{2eq} generadas por la cantidad de combustible utilizado.

$$Emisiones_s = \sum_t \left[\sum_{jc} \sum_r mcom_{r,jc,t,s} (EMIS_{jc}) \right] + \sum_t \left[\sum_{jg} \sum_r mgas_{r,jg,t,s} (EMIS_{jg}) \right] \quad (76)$$

Demanda total no suministrada

Se consideró la demanda no suministrada ($umdem$), lo que permite evitar soluciones inviábiles en el proceso de optimización.

$$umdemT_s = \sum_r \sum_t umdem_{r,t,s} \quad \forall s \in S \quad (77)$$

Costos de producción de energía convencional

Los costos asociados a la producción de energía eléctrica en generadores convencionales se determinan por la relación entre la cantidad de energía producida (ep) en un tiempo t y un costo variable de producción en cada una de las tecnologías convencionales jt .

$$opex_{t,s}^{conv} = \sum_r \sum_{jt} ep_{r,jt,t,s} (CPROD_{jt}), \quad \forall t \in T, \forall s \in S \quad (78)$$

Costos de producción de energía renovable

Los costos asociados a la producción de electricidad renovable se determinan por la relación entre la cantidad de energía generada ep en un período de tiempo t y el costo variable de producción $CPROD$ de cada tecnología renovable (jrt).

$$opex_{t,s}^{renw} = \sum_r \sum_{jrt} ep_{r,jrt,t,s} (CPROD_{jrt}), \quad \forall t \in T, \forall s \in S \quad (79)$$

Costos de transmisión

Los costos de transmisión están relacionados con el costo de transportar energía ($etrans$) de una región a otra, asumiendo un costo unitario de transmisión $CTRANS$ desde la región r hacia la región r' .

$$cost_{t,s}^{trans} = \sum_{r' \neq r} \sum_j etrans_{r,r',j,t,s} (CTRANS_{r,r'}), \quad \forall t \in T, \forall s \in S \quad (80)$$

Costo de instalación de Sistemas de Almacenamiento de Energía (ESS)

Los costos relacionados con las instalaciones de almacenamiento se calculan considerando los costos de capital según la capacidad instalada del sistema de almacenamiento ($icess$).

Este costo de capital se considera solo cuando se decide instalar estos sistemas, como se ilustra a continuación:

$$Capex^{ess} = \sum_r \sum_i \sum_s \left[FC_i^{ESS} icess_{r,i,s} \right] \quad (81)$$

Costo de instalación de tecnologías renovables variables

La instalación de tecnologías renovables (jr) considera un cargo unitario (FC^{renew}) relacionado con la capacidad de la unidad ic^{renew} .

$$Capex^{renew} = \sum_r \sum_{jr} \sum_s \left[FC_{jr}^{renew} ic_{r,jr,s}^{renew} \right] \quad (82)$$

Costo total de capital

El costo total de capital incluye los costos de adquisición de las unidades de almacenamiento de energía y las tecnologías renovables:

$$CostcapT = Capex^{ess} + Capex^{renew} \quad (83)$$

Costo operativo del almacenamiento de energía

El costo operativo del ESS está influenciado por la cantidad de energía almacenada en los sistemas de almacenamiento ($ealm$) de cada región (r), así como por un costo unitario operativo variable ($UC^{ess-CV-O\&M}$) de la unidad de almacenamiento (i). También se considera un costo operativo fijo para cada una de las unidades de almacenamiento ($UC^{ess-CF-O\&M}$).

$$Opex_{t,s}^{ess} = \sum_r \sum_i ealm_{r,i,t,s} \left(UC_i^{ess-CV-O\&M} \right) + UC_i^{ess-CF-O\&M} y_{r,i,s}^{ESS}, \quad \forall t \in T \quad (84)$$

El costo operativo total es igual a los costos operativos de las plantas de almacenamiento de energía.

$$CostopT = \sum_t \sum_s Opex_{t,s}^{ess} \quad (85)$$

Costo total

Se incluyen los costos de producción de energía convencional y renovable, así como los costos de transmisión de energía a las diferentes regiones. También se considera el costo de capital de adquisición de unidades de almacenamiento de energía, junto con los costos operativos asociados a estas unidades. Por otro lado, se incluye el costo relacionado con las emisiones generadas, que está sujeto a un impuesto ambiental ($UC^{CARBONTAX}$) sobre las emisiones de CO_{2eq} . También se considera el costo asociado a la energía no suministrada y no utilizada, con un costo unitario (U^{UMDEMT} y U^{CUT}). Además, se considera un factor de anualización de la inversión (K^{inv}).

$$TOC = \left[\sum_t \sum_s opex_{t,s}^{conv} + \sum_t \sum_s opex_{t,s}^{renw} + \sum_t \sum_s cost_{t,s}^{trans} + CostcapT(K^{inv}) + CostopT + \sum_s cuT_s(U^{CUT}) + \sum_s umdemT_s(U^{UMDEMT}) + \sum_s Emisiones_s(U^{CARBONTAX}) \right] \quad (86)$$

Función Objetivo

La función objetivo busca minimizar el costo total, que se determina de la siguiente manera:

$$O.F. = \min \{TOC\} \quad (87)$$

La formulación matemática corresponde a un problema de Programación Lineal Entera Mixta (MILP), que busca minimizar el costo total (TOC) asociado a la producción de electricidad. Es crucial enfatizar que el modelo matemático desarrollado puede utilizarse en cualquier región del mundo, siempre que se consideren las restricciones y configuraciones particulares de la red eléctrica, así como las opciones disponibles para la producción de energía renovable.

7.4.5 Caso de estudio

Se selecciona como caso de estudio el sistema eléctrico peninsular de México para aplicar el marco propuesto debido a que existen datos disponibles, además de tener una ventana de oportunidad para el uso de energías renovables debido a los problemas de suministro de gas natural. El sistema considera la producción eléctrica y cuenta con cinco regiones de transmisión las cuales son Lerma (RC), Chetumal (RD), Mérida (RE), Cancún (RF) y Cozumel (RG) las cuales están conectadas con el sistema eléctrico oriental a través de 2 regiones, las cuales son Grijalva (RA) y Tabasco (RB). Cada región cuenta con una línea de transmisión de energía eléctrica con cierta capacidad que se muestran en la **Figura 34**. La producción de energía eléctrica en el sistema eléctrico peninsular y oriental es a partir de diferentes tipos de tecnologías de generación, sin embargo, solo se consideran las ocho que tienen mayor aporte de electricidad en la producción total. Las tecnologías de generación de energía eléctrica se clasifican en dos grandes grupos, las tecnologías convencionales que utilizan combustibles fósiles para su funcionamiento (en este caso gas natural y combustóleo) y las tecnologías renovables que utilizan recursos naturales como el agua, el viento y la luz solar.

El marco de modelado, que se basa en la programación lineal entera mixta (MILP), adopta el punto de vista de planificación con decisiones operativas cuyo objetivo es identificar la generación a partir de tecnologías convencionales (por ejemplo, turbogás, ciclo combinado, cogeneración eficiente, combustión interna y termoeléctrica convencional), de tecnologías renovables variables (eólica y solar fotovoltaica) y de tecnología renovable no variable como la hidroeléctrica, esto para cada una de las siete regiones, además de la capacidad y ubicación de las futuras tecnologías de almacenamiento de energía para satisfacer la demanda de electricidad en cada periodo. Al mismo tiempo minimiza los costos totales que incluyen costos de producción y transmisión de energía entre las regiones, la inversión de capital en la adquisición de unidades de almacenamiento de energía, así como sus costos operativos y los costos ambientales correspondientes (por ejemplo, impuesto al carbono).

Los parámetros que se utilizan en el modelo de optimización se muestran en la **Tabla 12**, los cuales han sido tomados de informes técnicos actualizados (SENER, 2018) (INECC, 2020). Se considera un 95% de eficiencia en la transferencia de energía eléctrica de una región a otra. Los bajos poderes caloríficos para gas natural de 50,03 GJ/ton y para combustóleo de

40,10 GJ/ton. El almacenamiento de energía es un componente clave en la descarbonización de los sistemas eléctricos al apoyar la integración de tecnologías de generación de energía renovables variables ya que suavizan la variabilidad de la producción eólica y solar, al evitar la escasez y aprovechar eventos de electricidad excedente para ser utilizada en horas que requieren menor costo o de necesidad crítica. Por lo que en este modelo se utilizan las baterías de iones de litio (Li-ion) y las baterías redox de vanadio (VRB) (INECC, 2020). El impuesto ambiental se consideró de 3 \$/tonCO₂ eq (Renner, 2018) y un costo unitario de energía no suministrada de 2600 \$/MWh (SENER, 2018).

Tabla 12. Parámetros de capacidad instalada de las tecnologías de generación y costos de almacenamiento

Capacidad instalada (MW)							
Tecnología de generación	Grijalva (RA)	Tabasco (RB)	Lerma (RC)	Chetumal (RD)	Mérida (RE)	Cancún (RF)	Cozumel (RG)
Renovables variables							
Eólica	17.37	0.00	40.36	8.07	145.31	18.19	5.05
Solar	0.00	0.00	0.00	0.00	0.00	0.00	0.00
Renovables no variables							
Hidroeléctrica	4828.00	0.00	0.00	0.00	0.00	0.00	0.00
Convencionales							
Turbogas	121.00	217.00	47.00	71.20	60.00	190.00	53.00
Ciclo combinado	0.00	0.00	252.40	0.00	1229.00	0.00	0.00
Cogeneración eficiente	0.00	367.00	112.50	0.00	243.00	0.00	0.00
Combustión interna	1.00	47.00	0.00	0.00	13.13	0.00	0.00
Termoeléctrica convencional	0.00	0.00	0.00	0.00	1.06	3.20	0.00
Energía almacenada							
Tipo de batería	Eficiencia de carga	Eficiencia de descarga	Costos fijos (\$)	Costos variables (\$/MWh)	Capacidad máxima (MW)	Capacidad mínima (MW)	Energía en el tiempo cero (MWh)
Li-ion	0.98	0.98	540.00	2220.00	100.00	6.00	0.00
VRB (batería redox de vanadio)	0.85	0.85	944.00	1000.00	100.00	6.65	0.00

Se seleccionan cuatro semanas representativas a través de tres métodos diferentes con el fin de caracterizar la NLDC que combina la demanda de energía y la producción de recursos

energéticos variables durante un horizonte temporal y poder evitar la complejidad temporal, así como el uso de recursos computacionales excesivos. Las cuatro semanas representativas se seleccionan de un total de 52 semanas (8760 h) equivalentes a un año, por lo que a cada semana le corresponden 168 h. En este marco propuesto se comparan las semanas representativas resultantes en cada método en la precisión para representar la NLDC de cada región y en el dominio de la función objetivo del problema de optimización.




Figura 34. Regiones de transmisión del modelo estudiado en México.

7.4.6 Resultados

7.4.6.1 Selección de semanas

Para identificar las 4 semanas representativas obtenidas con cada método, se han etiquetado como: (A) obtenidas con el algoritmo de agrupamiento *k-means* con métrica euclidiana, (B) con el algoritmo *k-means* para series temporales con métrica DTW, y (C) con el método combinatorio. La **Tabla 13** muestra que el conjunto de semanas C tiene el menor error cuadrático medio (RMSE), seguido por el conjunto B y finalmente el conjunto A. Se observa que en los conjuntos A y B, cada semana tiene un peso diferente para escalar a un año. Por ejemplo, la semana 31 del conjunto A debe multiplicarse 23 veces, la semana 48 se repite 10 veces, y así sucesivamente para completar las 52 semanas del año. El parámetro n_{init} indica

el número de veces que se ejecuta el algoritmo *k-means* con semillas de centroides diferentes. El tiempo de cálculo para el conjunto A fue de aproximadamente 30 segundos, para el conjunto B de 35 minutos y para el conjunto C de 2 minutos. El algoritmo *k-means* con métrica DTW no tuvo restricciones en la cantidad de deformación permitida, lo que aumentó su tiempo de cálculo en comparación con los otros métodos. Como se puede apreciar, el uso de la distancia euclidiana en *k-means* reduce significativamente el tiempo computacional en comparación con la distancia DTW.

La curva de duración de carga neta (NLDC) se obtiene a partir de la diferencia entre la demanda y la producción de energías variables, ordenada de manera decreciente, como se muestra en las **Figuras 35 a 39**, donde también se incluyen las curvas aproximadas de carga neta para cada método.

Tabla 13. Resultados de los tres métodos en la selección de semanas representativas

n_init	Semanas representativas	Pesos de cada semana para escalado	RMSE	ID del conjunto de semanas
500	[31,48,13,4]	23,10,6,13	5.49	A
100	[35,47,44,36]	7,10,13,22	3.21	B
	[11,34,36,46]	52/4=13	2.80	C




Figura 35. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 41.




Figura 36. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 42.




Figura 37. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 43.




Figura 38. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 44.





Figura 39. La curva de duración de carga neta y sus aproximaciones por los métodos A, B y C en el nodo 45.

7.4.6.2 Modelo de GAMS

Se implementa el modelo matemático presentado anteriormente en software General Algebraic Modeling System (GAMS versión 43.4.1) como un modelo de programación entero mixto lineal (MILP). El modelo contiene 2,950,403 variables continuas, 94,220 variables binarias y 2,425,543 restricciones. Se utilizó una computadora con un procesador Intel Core i7-12700H de 2.30 GHz y 16.0 GB de RAM que tuvo un tiempo de CPU

aproximado de 1 min con 30 s en la resolución del programa utilizando el solucionador CPLEX. En la **Tabla 14** se muestran los resultados ambientales, económicos y energéticos de los distintos conjuntos de semanas representativas.

En el aspecto ambiental se muestra que el conjunto de semanas A tiene la menor cantidad de emisiones con 1.6516×10^6 tonCO_{2eq} sin embargo tiene el mayor factor de emisiones de 0.4952 tonCO_{2eq}/ MWh. Por el contrario, el conjunto de semanas C tiene mayor cantidad de emisiones y menor factor de emisiones. En la **Figura 40** se muestran las emisiones en cada año.






Figura 40. Evolución de las emisiones durante cada año de planificación en el conjunto de semanas A, B y C.

En el aspecto económico, el conjunto de semanas A tiene el menor costo total con \$ 4.4167 x 10¹⁰ y los menores costos de producción de energía térmica con \$ 1.0548 x 10⁷ y de costos de transmisión con \$ 4.6482 x 10⁶. Seguido del conjunto de semanas B con un costo total de \$ 4.4217 x 10¹⁰ y teniendo un costo de producción de energía térmica de \$ 1.0869 x 10⁷ y el mayor costo de transmisión de \$ 4.7335 x 10⁶ en comparación con los otros conjuntos de semanas. Mientras que el conjunto de semanas representativas C tiene el mayor costo total con \$ 4.4274 x 10¹⁰ y el mayor costo de producción de energía térmica con \$ 1.1241 x 10⁷ y un costo de transmisión de \$ 4.7048 x 10⁶.

En comparación con los otros conjuntos de semanas representativas, el conjunto de semanas A produce la menor cantidad de energía durante los 10 años de planificación con 1.7567 x 10⁷ MWh de los cuales el 81.0% a partir de tecnologías renovables (hidroeléctrica, eólica y solar fotovoltaica) y 19.0% con tecnologías convencionales. El conjunto de semanas B produce 1.7799 x 10⁷ MWh en donde el 80.6% es a partir de tecnologías renovables y el 19.4% de tecnologías convencionales. El conjunto de semanas C produce la mayor cantidad de energía con 1.7807 x 10⁷ en donde el 79.9% es a partir de renovables y el 20.1% de tecnologías convencionales.

En las tecnologías convencionales se usan combustibles fósiles, la menor cantidad usada fue en el conjunto de semanas A con 6.1218 x 10⁵ ton de los cuales el 98.1% es gas natural y el 1.9% es combustóleo. Seguido por el conjunto B con 6.3080 x 10⁵ ton con 98.1% de gas natural y el resto de combustóleo. La mayor cantidad usada de combustibles fósiles fue en el conjunto C con 6.5170 x 10⁵ sin embargo usando ligeramente un mayor porcentaje de gas

natural con 98.2% y un 1.8 de combustóleo. En las **Figuras 41 y 42** se muestra la evolución del uso de gas natural y combustóleo en cada nodo a través de los 10 años.




Figura 41. Evolución del uso de gas natural en cada nodo en el conjunto de semanas A, B y C.




Figura 42. Evolución del uso de combustóleo en cada nodo en el conjunto de semanas A, B y C.

El conjunto de semanas C tiene 0.2% y 0.1% más costos totales respecto al conjunto de semanas A y B, 6.2% y 3.3% más costos de producción de energía térmica respecto al

conjunto A y B; y 6% y 3% más generación de emisiones respecto al conjunto A y B, pero también debemos considerar que tiene 1.3% y 0.05% de mayor producción de energía respecto al conjunto A y B. Esto puede ser ocasionado a que representa con mayor precisión la variabilidad de generación y producción de energía eólica y solar, ya que tiene el menor error en la representación de NLDC. Estos resultados muestran que los conjuntos de semanas con mayor error en la representación de la NLDC subestiman el costo del sistema, esto puede estar ocasionado a una variación irregular debido a que tienen alta participación de energías renovables variables y/o un menor rango de variabilidad, por lo que al integrar esta dinámica en el modelo no se reflejen adecuadamente las operaciones operativas como las rampas de subida y bajada y/o la carga y descarga de las baterías para almacenamiento. Lo que puede resultar en escenarios menos costosos de lo que realmente son.

Tabla 14. Resultados obtenidos para los conjuntos de semanas A, B y C, minimizando costos.

Concepto	A	B	C
Emisiones (tonCO _{2eq})	1.6516 x 10 ⁶	1.7017 x 10 ⁶	1.7579 x 10 ⁶
Factor de emisiones (tonCO _{2eq} /MWh)	0.4952	0.4926	0.4905
Costo total (\$)	4.4167 x 10 ¹⁰	4.4217 x 10 ¹⁰	4.4274 x 10 ¹⁰
Producción de energía (MWh)	1.7567 x 10 ⁷	1.7799 x 10 ⁷	1.7807 x 10 ⁷
Producción de tecnologías convencionales	3.3354 x 10 ⁶	3.4541 x 10 ⁶	3.5836 x 10 ⁶
Producción de tecnologías renovables variables	1.8361 x 10 ⁶	1.8361 x 10 ⁶	1.8361 x 10 ⁶
Producción de tecnologías renovables no variables	1.2396 x 10 ⁷	1.2508 x 10 ⁷	1.2388 x 10 ⁷
Curtailment (MWh)	1.5437 x 10 ⁵	1.4645 x 10 ⁵	1.4224 x 10 ⁵
Energía no suministrada	163.27	163.27	163.27
Gas natural usado (ton)	6.0037 x 10 ⁵	6.1908 x 10 ⁵	6.3997 x 10 ⁵
Combustibles usados (ton)	1.1808 x 10 ⁴	1.1724 x 10 ⁴	1.1731 x 10 ⁴

En la **Tabla 15** se muestra la producción total de energía por cada tecnología en cada nodo durante los 10 años de planificación del conjunto de semanas representativas A. El nodo 39 produce la mayor cantidad de energía eléctrica con un 71.4%, de los cuales el 98.9% es de generación hidroeléctrica. Seguido del nodo 42 que produce el 18.9% de la energía eléctrica total de los 10 años, a partir del 55.5% de ciclo combinado y el 34.7% de eólica. Mientras que el nodo 41 produce el 3.8% de la cual el 47.4% es eólica y el resto de las energías

convencionales como Ciclo combinado, Cogeneración y Turbogas (con un 34.7%, 13.1% y 4.7% respectivamente). Sigue el nodo 38 con el 3.3% generado totalmente con tecnologías convencionales, en donde el 65.9% fue de Cogeneración, el 27.9% de Turbogas y el 6.2% de Combustión interna. El nodo 43, 44 y 45 generaron el 1.6%, el 0.6% y el 0.4% a partir de la tecnología eólica (en un 52.1%, 56.7% y 52.3%) y de Turbogas con un 47.2%, 43.3% y 47.7% respectivamente.

Tabla 15. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas A

Conjunto de Semanas A							
Tecnologías de generación	Energía producida en 10 años						
	Nodo 38	Nodo 39	Nodo 41	Nodo 42	Nodo 43	Nodo 44	Nodo 45
Turbogas	159,277.27	86,286.99	31,982.64	40,973.70	130,548.73	48,751.12	36,506.47
Ciclo combinado	0.00	0.00	234,301.95	1,842,557.45	0.00	0.00	0.00
Cogeneración eficiente	376,883.68	0.00	88,520.51	210,431.21	0.00	0.00	0.00
Combustión interna	35,635.85	749.48	0.00	9,070.93	0.00	0.00	0.00
Termoeléctrica convencional	0.00	0.00	0.00	714.33	2,157.87	0.00	0.00
Eólica	0.00	54,701.58	319,768.66	1,151,167.18	144,109.08	63,953.73	39,971.08
Solar	0.00	0.00	0.00	62,453.95	0.00	0.00	0.00
Hidroeléctrica	0.00	12,395,662.08	0.00	0.00	0.00	0.00	0.00
Energía total (MWh)	571,796.80	12,537,400.12	674,573.75	3,317,368.74	276,815.68	112,704.85	76,477.55

En la **Tabla 16** se muestra que el nodo 39 produce el 71.1% de la energía total durante los 10 años, se generan 12,649,704.9 MWh en donde el 98.9% proviene de hidroeléctrica, lo cual es la cantidad más grande de generación de electricidad. El segundo nodo que más genera es el 42 que produce el 19.3% de la energía, a partir de un 57.1% de ciclo combinado y del 33.5% de eólica. Bajando el porcentaje de producción eléctrica con el nodo 41 a 3.8% de la cual el 47.3% es eólica y el resto con tecnologías convencionales como Ciclo combinado, Cogeneración y Turbogas (con un 35.3%, 12.7% y 4.7% respectivamente). Seguido del nodo 38 con el 3.2% generado totalmente con tecnologías convencionales, en donde el 66.0% fue de Cogeneración, el 27.8% de Turbogas y el 6.2% de Combustión interna. El nodo 43 con una generación del 1.6% con una participación mayoritaria de tecnología renovable del 52.1% (eólica) y 47.9 de tecnologías convencionales (Turbogas y Termoelectica). Los nodos

44 y 45 generan un 0.6% y el 0.4% a partir de las tecnologías eólica (en un 56.8% y 52.4% respectivamente) y el resto de Turbogas.

Tabla 16. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas B

Tecnologías de generación	Conjunto de Semanas B						
	Energía producida en 10 años						
	Nodo 38	Nodo 39	Nodo 41	Nodo 42	Nodo 43	Nodo 44	Nodo 45
Turbogas	157,914.2	85,882.9	31,936.6	40,917.7	130,281.6	48,694.9	36,269.3
Ciclo combinado	0.0	0.0	238,497.1	1,965,501.2	0.0	0.0	0.0
Cogeneración eficiente	374,327.8	0.0	86,196.2	209,736.6	0.0	0.0	0.0
Combustión interna	35,338.3	745.4	0.0	9,032.5	0.0	0.0	0.0
Termoeléctrica convencional	0.0	0.0	0.0	712.3	2,150.4	0.0	0.0
Eólica	0.0	54,701.6	319,768.7	1,151,167.2	144,109.1	63,953.7	39,971.1
Solar	0.0	0.0	0.0	62,454.0	0.0	0.0	0.0
Hidroeléctrica	0.0	12,508,375.0	0.0	0.0	0.0	0.0	0.0
Energía total (MWh)	567,580.3	12,649,704.9	676,398.5	3,439,521.3	276,541.1	112,648.6	76,240.4

En la **Tabla 17** se observa que el nodo 39 produce el 70.4% de la energía total durante el horizonte de 10 años de planificación, se producen 12,528,854.20 MWh de los cuales el 98.9% es generada por hidroeléctrica. Le sigue el nodo 42 con 3,531,655.37 MWh equivalente al 19.8%, de los cuales el 58.1% proviene de ciclo combinado y del 32.6% de eólica. En el resto de los nodos cae significativamente el porcentaje de generación de electricidad. Por ejemplo, la generación en el nodo 41 representa el 3.9% de la electricidad, que se compone con 46.1% de eólica, 36.2% de ciclo combinado, 13% de cogeneración y 4.6% de Turbogas. Le sigue el nodo 38 con el 3.3% generado totalmente con tecnologías convencionales, en donde el 6.0% fue de Combustión interna, el 26.8% de Turbogas y el 67.1% de Cogeneración. El nodo 43 con una generación del 1.6% con el 51.9% de eólica, el 47.4% de Turbogas y el 0.8% de Termoeléctrica. Finalmente, los nodos de menor generación son el 44 y 45, que generan 0.6% y 0.4% respectivamente, en donde un 56.6% y 52.3% fue de tecnología eólica y el resto de Turbogas.

Tabla 17. Energía producida durante 10 años en cada nodo de transmisión en el conjunto de semanas C

Conjunto de Semanas C							
Tecnologías de generación	Energía producida en 10 años						
	Nodo 38	Nodo 39	Nodo 41	Nodo 42	Nodo 43	Nodo 44	Nodo 45
Turbogas	157,205.29	85,696.51	32,064.96	41,143.03	131,595.13	49,034.44	36,495.59
Ciclo combinado	0.00	0.00	251,537.80	2,052,454.35	0.00	0.00	0.00
Cogeneración eficiente	393,311.33	0.00	90,537.88	214,558.29	0.00	0.00	0.00
Combustión interna	35,231.62	741.87	0.00	9,164.98	0.00	0.00	0.00
Termoeléctrica convencional	0.00	0.00	0.00	713.59	2,154.56	0.00	0.00
Eólica	0.00	54,701.58	319,768.66	1,151,167.18	144,109.08	63,953.73	39,971.08
Solar	0.00	0.00	0.00	62,453.95	0.00	0.00	0.00
Hidroeléctrica	0.00	12,387,714.25	0.00	0.00	0.00	0.00	0.00
Energía total (MWh)	585,748.24	12,528,854.20	693,909.30	3,531,655.37	277,858.77	112,988.17	76,466.67

En la **Figura 43** se muestra la energía producida por los nodos para su demanda interna y la energía que se transmite a otros nodos, además se alcanza a visualizar el curtailment de los nodos en cada conjunto de semanas representativas. En el conjunto A se muestra que en el año 1 la energía producida de los nodos para su demanda interna es de 45.3%, la energía transmitida hacia otros nodos es del 53.3% y el curtailment es de 1.4%. Mientras que para el año 10 se aprecia una disminución en el porcentaje de curtailment a el 0.6%, aumentando la producción para demanda interna a 56.2% y la energía transmitida a 60.8%. En el conjunto de semanas B pasa de tener en el año 1 un 45.1% de producción para la demanda interna de los nodos, 53.7% de energía transmitida y 1.2% de curtailment, mientras que para el año 10 se tiene un 56.1% de producción para demanda interna, el 61.0% de energía transmitida y solo el 0.6% de curtailment. En el conjunto de semanas C también se tiene una mejora en el curtailment ya que en el año 1 es de 1.1% y en el año 10 es de 0.6%, aumentando la producción para demanda interna de 45.4% a 56.5% y la energía transmitida de 53.5% a 60.6%. La estructura de generación de la producción total y la producción para demanda interna de electricidad a lo largo de los 10 años se muestra en la **Figura 44**.




Figura 43. Energía producida, transmitida y restringida durante el horizonte de 10 años para cada conjunto de semanas representativas.





Figura 44. Estructura de generación total y generación para abastecer demanda interna

Los nodos 39, 41 y 42 son los únicos nodos que transmiten energía hacia otros nodos en los tres conjuntos de semanas representativas. En el conjunto A, el nodo 39 transmite 7,944,528.00 MWh que representa el 85.5% del total de energía transmitida en los 10 años,

el nodo 42 transmite 1,262,335.98 MWh que representa el 13.6% y el nodo 41 transmite solo el 1%. En el conjunto B, el nodo 39 transmite 8,056,836.04 MWh que representa el 85.1% de energía transmitida, el nodo 42 transmite 1,327,829.82 MWh que representa el 14.0% y el nodo 41 transmite el 0.9%. En el conjunto C, el nodo 39 transmite 7,935,991.58 MWh equivalente al 84.3% del total de energía transmitida, el nodo 42 transmite 1,393,788.30 MWh equivalente al 14.8% y el nodo 41 solo el 0.8%. En la **Figura 45** muestra la evolución de la energía transmitida en cada nodo de cada conjunto de semanas.







Figura 45. Electricidad transmitida de cada nodo

Los nodos 41, 42, 44 y 45 son los únicos que tienen curtailment para los tres conjuntos de semanas representativas. En el conjunto A, el nodo 42 no aprovecha 141,518.26 MWh que representa el 91.7%, en el nodo 45 es 11,948.83 MWh que representa el 7.7%, en el nodo 41 y el 44 se tiene un 0.2% y el 0.4% respectivamente. En el conjunto B, el nodo 42 no aprovecha 134,396.21 MWh equivalente al 91.8%, en el nodo 45 es 10,535.65 MWh equivalente al 7.2%, mientras que en el nodo 41 y el 44 desaprovechan el 0.2% y el 0.9% respectivamente. En el conjunto C, el nodo 42 no aprovecha 129,812.45 MWh que representa el 91.3%, en el nodo 45 es 10,689.16 MWh que representa el 7.5%, en el nodo 41 es de 0.7% y el nodo 44 de 0.6%. Cabe destacar que el conjunto A muestra la mayor cantidad de energía desaprovechada con 1.5437×10^5 MWh, seguido del conjunto B con 1.4645×10^5 MWh y el conjunto C con 1.4224×10^5 MWh que desaprovecha menos energía. En la **Figura 46** se muestra la evolución de la energía desaprovechada en los nodos en cada conjunto de semanas.






Figura 46. Energía desperdiciada de cada nodo.

El nodo 39 fue el único en donde se instalaron unidades de almacenamiento de energía, en la **Tabla 18** se muestra la energía almacenada total durante los 10 años de planeación. El conjunto de semanas representativas A tiene la mayor cantidad de energía almacenada en los dispositivos ST-1 y ST-2, mientras que el conjunto C tiene la menor cantidad almacenada. La capacidad instalada de las unidades ST-1 es de 6 MWh para el año 9 y 10 y la capacidad instalada de las unidades ST-2 es de 6.65 MWh en el año 9 y 7.008 MWh en el año 10 en los tres conjuntos de semanas. Por lo que los costos de adquisición de las unidades de almacenamiento son $\$1.3142 \times 10^7$ y los costos operativos son $\$3.6112 \times 10^7$; estos son iguales en todos los conjuntos de semanas representativas A, B y C ya que tienen la misma capacidad instalada.

Tabla 18. Almacenamiento de electricidad total durante 10 años en el nodo 39.

Nodo 39			
Unidades de almacenamiento	Energía almacenada en 10 años (MWh)		
	Conjunto de semanas A	Conjunto de semanas B	Conjunto de semanas C
ST-1	3,715.67	3,596.70	3,507.90
ST-2	5,053.78	4,974.34	4,335.51
Total	8,769.45	8,571.04	7,843.41

Este estudio comparó tres métodos para seleccionar semanas representativas (*k-means* con métrica euclidiana, *k-means* con DTW y un enfoque combinatorio) en la planificación de sistemas eléctricos con alta participación de energías renovables. El método combinatorio mostró mayor precisión al capturar la variabilidad de la curva de duración de carga neta (NLDC), pero con un costo computacional elevado. Los enfoques basados en *k-means* ofrecieron resultados más rápidos, aunque menos precisos, subestimando costos y emisiones al no reflejar adecuadamente las dinámicas operativas. La elección del método depende del equilibrio entre precisión y recursos disponibles, destacando la importancia de preservar la cronología y variabilidad para garantizar flexibilidad en la planificación a largo plazo. Este marco de trabajo facilita la optimización de sistemas multi-regionales, reduciendo la complejidad temporal sin comprometer la evaluación de tecnologías renovables y convencionales.

8. Conclusión

Este proyecto presenta cuatro trabajos interdisciplinarios que, desde la ingeniería química, abordan desafíos críticos en la evaluación del nexo Agua-Energía-Alimentos (WEF), la planificación energética y la sostenibilidad global, incorporando técnicas avanzadas de aprendizaje automático. Cada uno de estos estudios contribuye de manera única al avance del conocimiento y la práctica en sus respectivos ámbitos, mientras que en conjunto ofrecen una visión integrada y holística para abordar los complejos problemas de sostenibilidad y gestión de recursos en el siglo XXI. A continuación, se mencionan las contribuciones de los cuatro trabajos incluidos en este proyecto.

8.1 Evaluación Cuantitativa del Nexo WEF en España

Este trabajo desarrolla un índice compuesto (WEF-Waste) que integra 13 indicadores para evaluar la seguridad del nexo WEF en España y sus comunidades autónomas. La metodología propuesta, respaldada por mapas de calor, permite visualizar tendencias temporales y espaciales, identificando regiones con mayor vulnerabilidad en la gestión de recursos. Su principal contribución radica en la cuantificación de sinergias y compensaciones entre agua, energía y alimentos, proporcionando una herramienta versátil para la toma de decisiones políticas y económicas. Además, destaca la importancia de incluir residuos sólidos urbanos en el análisis, ampliando el enfoque tradicional del nexo WEF.

8.2 Proyecciones del Nexo WEF en México mediante Aprendizaje Profundo

Utilizando redes neuronales LSTM y GRU, este estudio proyecta la demanda y producción de agua, energía y alimentos en México hasta 2050. La integración de estas proyecciones en un índice WEF permite evaluar futuros escenarios de seguridad de recursos. La aplicación de técnicas de aprendizaje profundo resalta la capacidad de predecir comportamientos complejos y no lineales, ofreciendo a los planificadores información valiosa para diseñar políticas sostenibles. Este trabajo subraya la importancia de la accesibilidad y disponibilidad de recursos en contextos de crecimiento poblacional y urbanización acelerada.

8.3 Análisis de los ODS y su Relación con el Desperdicio de Alimentos

Mediante técnicas de clustering (k-means), este estudio clasifica países según su desempeño en los Objetivos de Desarrollo Sostenible (ODS), con énfasis en el desperdicio de alimentos. La correlación entre los ODS revela interdependencias críticas, como la fuerte relación entre salud (ODS 3) e industria (ODS 9), y la tensión entre producción responsable (ODS 12) y desarrollo industrial. La inclusión del desperdicio de alimentos como variable clave destaca su impacto en la sostenibilidad global y la necesidad de políticas integradas para reducir pérdidas y mejorar la seguridad alimentaria.

8.4 Selección de Semanas Representativas para la Planificación Energética

Este trabajo compara métodos de clustering (k-means con métricas euclidiana y DTW) y un enfoque combinatorio para seleccionar semanas representativas en la planificación de sistemas eléctricos con alta participación de energías renovables. La metodología propuesta optimiza la representación temporal de la curva de duración de carga neta (NLDC),

reduciendo la complejidad computacional sin sacrificar precisión. Su aplicación en el sistema eléctrico peninsular de México demuestra cómo estas técnicas pueden mejorar la flexibilidad y eficiencia en la planificación energética a largo plazo.

En conjunto, estos cuatro trabajos ilustran cómo el aprendizaje automático, desde la ingeniería química, puede transformar la evaluación y gestión de sistemas complejos como el nexo WEF, la planificación energética y los ODS. Las contribuciones clave incluyen:

- **Integración de Datos y aprendizaje automático:** Los estudios utilizan técnicas avanzadas para analizar grandes volúmenes de datos, identificar patrones y proyectar escenarios futuros. Esto permite una toma de decisiones basada en evidencia y adaptada a contextos específicos.
- **Enfoque Multiescala:** Desde escalas regionales (comunidades autónomas en España) hasta nacionales (México) y globales (ODS), los trabajos demuestran la versatilidad de las metodologías propuestas para abordar problemas en diferentes niveles geográficos y temporales.
- **Sostenibilidad y Resiliencia:** Cada estudio enfatiza la importancia de la sostenibilidad, ya sea mediante la optimización de recursos, la reducción de emisiones, la minimización del desperdicio de alimentos o la integración de energías renovables. Estos enfoques están alineados con los ODS y los principios de la economía circular.
- **Interdisciplinariedad:** La combinación de ingeniería química, ciencia de datos y planificación estratégica refleja un enfoque interdisciplinario esencial para resolver los desafíos globales contemporáneos.

Por tal motivo la incorporación del aprendizaje automático en la ingeniería química no solo mejora la precisión y eficiencia de las evaluaciones, sino que también abre nuevas vías para la innovación en la gestión sostenible de recursos. Los cuatro trabajos presentados son un testimonio del potencial de estas herramientas para transformar la teoría en práctica, facilitando la transición hacia sistemas más resilientes y equitativos. Futuras investigaciones podrían expandir estos enfoques a otros contextos geográficos o integrar más variables

socioeconómicas y ambientales, fortaleciendo aún más el puente entre la ingeniería y la sostenibilidad global.

9. Nomenclatura

FASE 1

ACs	Comunidades Autónomas
$e_{c,t}^{generation}$	Generación de energía
$e_{c,t}^{consumption}$	Consumo de energía
$e_{c,t}^{renewable}$	Energía renovable
$e_{c,t}^{import}$	Importación de energía
$f_{c,f,t}^{production}$	Producción de cada grupo de alimentos por comunidad autónoma
$f_{c,f,t}^{consumption}$	Consumo de cada grupo de alimentos por comunidad autónoma
$f_{c,t}^{import}$	Importación de alimentos por comunidad autónoma
$f_{c,t}^{surface}$	Superficie de agricultura ecológica por comunidad autónoma
$f_t^{totalsurface}$	Superficie total de agricultura ecológica en España
$f_{c,t}^{waste}$	Desperdicio de alimentos en cada comunidad autónoma
$f_{c,t}^{production}$	Producción total de alimentos por comunidad autónoma
$r_{c,t}^{separatedwaste}$	Residuos recogidos selectivamente por comunidad autónoma
$r_{c,t}^{totwaste}$	Total de residuos generados en la comunidad autónoma
$r_{c,t}^{reused waste}$	Residuos reutilizados y reciclados por comunidad autónoma
$w_{c,t}^{production}$	Producción de agua por comunidad autónoma
$w_{c,t}^{consumption}$	Consumo de agua por comunidad autónoma
$w_{c,t}^{import}$	Importación de agua de otras comunidades
$w_{c,t}^{wtreated}$	Agua tratada
$w_{c,t}^{wreused}$	Agua reutilizada

Sets

- c Representa el conjunto de las 17 comunidades autónomas de España.
- t Representa el conjunto temporal en años, desde 2010 hasta 2021.

- f Grupo de alimentos (que incluye Legumbres, Cereales, Tubérculos, Hortalizas, Frutas cítricas y no cítricas, Carnes, Leche, Huevos y Aceite de oliva).

FASE 2

WG_t	Agua generada
WC_t	Consumo de agua
EP_t	Producción de electricidad
EC_t	Consumo de electricidad
FP_t	Producción de alimentos
FC_t	Consumo de alimentos
Pop_t	Población
$PopWW_t$	Población sin servicio de agua entubada
$PopWE_t$	Población sin servicio eléctrico
$PopWF_t$	Población sin acceso a alimentos
t	Período de tiempo (anual)

FASE 4

Índices

I	Almacenamiento de energía eléctrica
j	Tecnología de generación de energía
jt	Tecnología convencional de generación de energía
jpg	Tecnología convencional de generación de energía que usa gas natural como combustible
jpc	Tecnología convencional de generación de energía que usa fuelóleo como combustible
jrt	Tecnología de generación de energía renovable
jr	Tecnología de generación de energía renovable variable
jrh	Tecnología de generación de energía renovable no variable
r	Área geográfica
t	Período de tiempo horario
s	Período de tiempo anual

Variables binarias

$y_{r,i}^{ESS}$ = Variable binaria para modelar la existencia de almacenamiento de energía eléctrica

$\omega_{r,i,t,s}^{ESS}$ = Variable binaria para modelar la carga/descarga de almacenamiento de energía eléctrica en un período específico

$y_{r,jr}^{RENEW}$ = Variable binaria para modelar la existencia de tecnologías renovables variables

Variables

$Capex^{ess}$ = Costo de capital de almacenamientos de energía eléctrica, \$

$Capex^{renew}$ = Costo de capital de tecnologías renovables variables, \$

$CostcapT$ = Costo total de capital, \$

$cost_{t,s}^{trans}$ = Costo de transmisión de energía, \$

$CostopT$ = Costo operativo total, \$

$cu_{r,jr,t,s}$ = Energía no utilizada en tecnologías renovables variables, MWh

$cu_{r,jrh,t,s}$ = Energía no utilizada en tecnologías renovables no variables, MWh

$cu_{r,jrt,t,s}$ = Energía no utilizada en tecnologías renovables disponibles, MWh

cuT_s = Energía renovable total no aprovechada de tecnologías disponibles, MWh

$eprodem_{r,j,t,s}$ = Generación local de tecnologías disponibles, MWh

$etrans_{r',r,j,t,s}$ = Energía producida en tecnologías disponibles y transmitida de una región a otra, MWh

$edes_{r,i,t,s}$ = Energía descargada del sistema de almacenamiento de electricidad, MWh

$ep_{r,jt,t,s}$ = Electricidad generada por cada una de las tecnologías convencionales, MWh

$ep_{r,jr,t,s}$ = Electricidad generada por cada una de las tecnologías renovables variables, MWh

$eprodem_{r,jt,t,s}$ = Generación local de tecnologías convencionales, MWh

$ep_{r,jc,t,s}$ = Cantidad de combustible necesaria en tecnologías convencionales que usan fuelóleo, GJ

$ep_{r,jr,t,s}$ = Electricidad generada por cada una de las tecnologías renovables variables, MWh

$eprodem_{r,jr,t,s}$ = Generación local de tecnologías renovables variables, MWh

$ecar_{r,jr,i,t,s}$ = Energía cargada al sistema de almacenamiento de electricidad por tecnologías renovables variables, MWh

$etrans_{r,r',jr,t,s}$ = Energía producida en tecnologías renovables variables y transmitida de una región a otra, MWh

$etrans_{r,r',jt,t,s}$ = Energía producida en tecnologías convencionales y transmitida de una región a otra, MWh

$ep_{r,jg,t,s}$ = Cantidad de combustible necesaria en tecnologías convencionales que usan gas natural, GJ

$ep_{r,jrh,t,s}$ = Electricidad generada por cada una de las tecnologías renovables no variables, MWh

$eprodem_{r,jrh,t,s}$ = Generación local de tecnologías renovables no variables, MWh

$ecar_{r,jrh,i,t,s}$ = Energía cargada al sistema de almacenamiento de electricidad por tecnologías renovables no variables, MWh

$etrans_{r,r',jrh,t,s}$ = Energía producida en tecnologías renovables no variables y transmitida de una región a otra, MWh

$ealm_{r,i,t,s}$ = Cantidad de energía contenida en sistemas de almacenamiento, MWh

$ecar_{r,jrt,i,t,s}$ = Energía cargada al sistema de almacenamiento de electricidad por tecnologías renovables disponibles, MWh

$edes_{r,i,t,s}$ = Energía descargada del sistema de almacenamiento de electricidad, MWh

$eelec_{r,jrt,h,t,s}$ = Energía renovable de tecnologías disponibles utilizada por electrolizadores, MWh

$Emisiones_s$ = Emisiones totales generadas por tecnologías convencionales, tonCO_{2eq}

$ep_{r,jrt,t,s}$ = Electricidad generada por cada una de las tecnologías renovables, MWh

$icess_{r,i,s}$ = Capacidad del sistema de almacenamiento, MW

$ic_{r,jr,s}^{renew}$ = Capacidad de tecnologías renovables variables, MW

$mgas_{r,jg,t,s}$ = Masa de gas natural utilizada por tecnologías convencionales, ton de gas natural

$mcom_{r,jc,t,s}$ = Masa de fuelóleo utilizada por tecnologías convencionales, ton de fuelóleo

$opex_{t,s}^{conv}$ = Costo de producción de energía en tecnologías convencionales, \$

$opex_{t,s}^{renew}$ = Costo de producción de energía en tecnologías renovables, \$

$Opex_{t,s}^{ess}$ = Costo operativo de almacenamiento de energía, \$

TC = Costo total, \$

$umdem_{r,t,s}$ = Energía no suministrada a cada una de las regiones, MWh

$umdemT_s$ = Energía total no suministrada, MWh

Parámetros

$CAPROD_{r,jt,t,s}$ = Capacidad de producción de tecnologías convencionales, MW

$CAPROD_{r,jr,t}$ = Capacidad de producción de tecnologías renovables variables, MW

$CF_{r,jr,t,s}$ = Factor de capacidad de tecnologías renovables disponibles, MWh/MW

$CMINRENEW_{r,jr}$ = Capacidad mínima de producción para considerar la instalación de tecnologías renovables variables, MW

$CMAXRENEW_{r,jr}$ = Capacidad máxima de producción para considerar la instalación de tecnologías renovables variables, MW

$CMINESS_{r,i}$ = Capacidad mínima de almacenamiento para considerar la instalación de almacenamiento de energía eléctrica, MW

$CMAXESS_{r,i}$ = Capacidad máxima de almacenamiento para considerar la instalación de almacenamiento de energía eléctrica, MW

$CAPDESC_{r,i}$ = Porcentaje de capacidad que puede ser descargada por el almacenamiento de energía

CT = Capacidad del enlace de transmisión de una región a otra, MWh

$CPROD_{jt}$ = Costo variable de producción en tecnologías convencionales, \$/MWh

$CPROD_{jrt}$ = Costo variable de producción en tecnologías renovables, \$/MWh

$CTRANS_{r,r'}$ = Costo unitario de transmisión de energía de una región a otra, \$/MWh

$EALM^0_{r,i}$ = Energía contenida en almacenamientos de energía en el tiempo cero, MWh

$EDEM$ = Demanda de electricidad, MWh

$EMIS_{jc}$ = Factor de emisión de equivalentes de CO₂ generados a la atmósfera por la cantidad de fuelóleo usado, tonCO_{2eq}/ton de fuelóleo

$EMIS_{jg}$ = Factor de emisión de equivalentes de CO₂ generados a la atmósfera por la cantidad de gas natural usado, tonCO_{2eq} /ton de gas natural

FC^{ess}_i = Costo unitario de instalación de almacenamiento de energía eléctrica, \$/MW

FC^{renow}_{jr} = Costo unitario de instalación de tecnologías renovables variables, \$/MW

K^{inv} = Factor utilizado para anualizar la inversión en equipos

$LHVC$ = Valor calorífico inferior del fuelóleo, GJ/ton de fuelóleo

$LHVG$ = Valor calorífico inferior del gas natural, GJ/ton de gas natural

$MAXPROD_{r,jt,t}$ = Capacidad máxima de producción de tecnologías convencionales, MW

$MINPROD_{r,jt,t}$ = Capacidad mínima de producción de tecnologías convencionales, MW

$RDMAX_{jt}$ = Fracción de capacidad instalada que puede reducirse en un período

$RUMAX_{jt}$ = Fracción de capacidad instalada que puede incrementarse en un período

$UC_i^{ess-CV-O\&M}$ = Costo variable de operación y mantenimiento en almacenamiento de energía, \$/MWh

$UC_i^{ess-CF-O\&M}$ = Costo fijo de operación y mantenimiento en almacenamiento de energía, \$

U^{UMDEMT} = Impuesto unitario sobre energía no suministrada, \$/MWh

U^{CUT} = Impuesto unitario sobre energía no utilizada, \$/MWh

$U^{CARBONTAX}$ = Impuesto ambiental sobre emisiones de equivalentes de CO₂, \$/ tonCO_{2eq}

η_i^{car} = Eficiencia de carga en sistemas de almacenamiento de energía eléctrica

η_i^{des} = Eficiencia de descarga en sistemas de almacenamiento de energía eléctrica

η^{trans} = Eficiencia de transmisión de electricidad

$\eta_{jc}^{convotr}$ = Eficiencia térmica de fuelóleo a electricidad

$\eta_{jg}^{convgas}$ = Eficiencia térmica de gas natural a electricidad

10. Referencias

- Akhter, M.N., Mekhilef, S., Mokhlis, H., Shah, N.M. (2019). Review on forecasting of photovoltaic power generation based on machine learning and metaheuristic techniques. *IET Renew. Power Gener.* 13 (7), 1009–1023. <https://doi.org/10.1049/IET-RPG.2018.5649>.
- Albrecht, T. R., Crootof, A., & Scott, C. A. (2018). The water-energy-food nexus: A systematic review of methods for nexus assessment. *Environmental Research Letters*, 13(4), 043002. <https://doi.org/10.1088/1748-9326/aaa9c6>
- Alexandratos, N., & Bruinsma, J. (2012). *World agriculture towards 2030/2050: The 2012 revision* (ESA Working Paper No. 12-03). FAO. <http://www.fao.org/3/a-ap106e.pdf>
- Alibrahim, H., & Ludwig, S. A. (2021). Hyperparameter optimization: Comparing genetic algorithm against grid search and Bayesian optimization. *2021 IEEE Congress on Evolutionary Computation (CEC)*, 1551–1559. <https://doi.org/10.1109/CEC45853.2021.9504761>
- Amer, K., Adeel, Z., Böer, B., & Saleh, W. (Eds.). (2017). *The water, energy, and food security nexus in the Arab Region*. Springer International Publishing.
- Arzami, A. N., Ho, T. M., & Mikkonen, K. S. (2022). Valorization of cereal by-product hemicelluloses: Fractionation and purity considerations. *Food Research International*, 151, 110818. <https://doi.org/10.1016/j.foodres.2021.110818>
- Artioli, F., Acuto, M., & McArthur, J. (2017). The water-energy-food nexus: An integration agenda and implications for urban governance. *Political Geography*, 61, 215–223.
- Baier, S. L., Clements, M., Griffiths, C. W., & Ihrig, J. E. (2009). Biofuels impact on crop and food prices: Using an interactive spreadsheet. *FRB International Finance Discussion Paper*, 967.
- Ben-Iwo, J., Manovic, V., & Longhurst, P. (2016). Biomass resources and biofuels potential for the production of transportation fuels in Nigeria. *Renewable and Sustainable Energy Reviews*, 63, 172–192. <https://doi.org/10.1016/j.rser.2016.05.050>

- Brears, R. (2016). *Urban Water Security*. John Wiley & Sons.
- Brears, R. (2018). *The green economy and the water-energy-food nexus*. Palgrave Macmillan.
- British Petroleum. (2016). *BP Energy Outlook 2016*.
<https://www.bp.com/content/dam/bp/business-sites/en/global/corporate/pdfs/energy-economics/energy-outlook/bp-energy-outlook-2016.pdf>
- Chang, Y., Li, G., Yao, Y., Zhang, L., & Yu, C. (2016). Quantifying the water-energy-food nexus: Current status and trends. *Energies*, 9(2), 65.
<https://doi.org/10.3390/en9020065>
- CONEVAL (2020). Poverty measurement. https://www.coneval.org.mx/Medicion/MP/Paginas/Pobreza_2020.aspx (Accessed 18 November 2022).
- CONAGUA (2021). Public Registry of Water Rights (REPDA) / Registered Volumes (national). <http://sina.conagua.gob.mx/sina/tema.php?tema=usosAgua&ver=reporte&o=0&n=nacional> (Accessed 4 November 2022).
- CONAPO (2019). Databases of Population Projections for Mexico and the Federal Entities, 2016–2050. <https://www.gob.mx/conapo/documentos/diccionario-de-las-bases-de-datos-de-proyecciones-de-la-poblacion-de-mexico-y-de-las-entidades-federativas-2016-2050> (Accessed 24 November 2022).
- Cuberos Balda, M., Furubayashi, T., & Nakata, T. (2017). A novel approach for analyzing the food-energy nexus through on-farm energy generation. *Clean Technologies and Environmental Policy*, 19(4), 1003–1019. <https://doi.org/10.1007/s10098-016-1295-8>
- Daher, B., Lee, S.-H., Kaushik, V., Blake, J., Askariyeh, M. H., Shafieezadeh, H., Zamaripa, S., & Mohtar, R. H. (2019). Towards bridging the water gap in Texas: A water-energy-food nexus approach. *Science of the Total Environment*, 647, 449–463.
<https://doi.org/10.1016/j.scitotenv.2018.07.398>
- De Sisternes, F.J., Webster, M.D. (2013). Optimal Selection of Sample Weeks for Approximating the Net Load in Generation Planning Problems. MIT lib. <https://dspace.mit.edu/handle/1721.1/102959>.

- Duchenne-Moutien, R. A., & Neetoo, H. (2021). Climate change and emerging food safety issues: A review. *Journal of Food Protection*, 84(11), 1884–1897. <https://doi.org/10.4315/JFP-21-141>
- Edgar, T. W., & Manz, D. O. (2017). *Research methods for cyber security*. Syngress.
- El Bouchefry, K., & de Souza, R. S. (2020). Learning in big data: Introduction to machine learning. In *Knowledge discovery in big data from astronomy and earth observation* (pp. 225–249). Elsevier.
- El-Halwagi, M. M. (2017). A return on investment metric for incorporating sustainability in process integration and improvement projects. *Clean Technologies and Environmental Policy*, 19(2), 611–617.
- Endo, A., Burnett, K., Orencio, P. M., Kumazawa, T., Wada, C. A., Ishii, A., Tsurita, I., & Taniguchi, M. (2015). Methods of the water-energy-food nexus. *Water*, 7(10), 5806–5830. <https://doi.org/10.3390/w7105806>
- Endo, A., & Oh, T. (Eds.). (2018). *The water-energy-food nexus: Human-environmental security in the Asia-Pacific ring of fire*. Springer.
- European Commission. (2023). *Organic action plan*. https://agriculture.ec.europa.eu/farming/organic-farming/organic-action-plan_en
- FAO. (1996). *The state of food and agriculture*. <http://www.fao.org/3/w1358e/w1358e.pdf>
- FAO. (2000). *The Energy and agriculture nexus*. <http://www.fao.org/docrep/003/x8054e/x8054e00.htm>
- FAO. (2012). *Food losses and food waste in the world - Extent, causes and prevention*. <https://www.fao.org/3/i2697s/i2697s.pdf>
- FAO. (2014). *Walking the nexus talk: Assessing the water-energy-food nexus in the context of the sustainable energy for all initiative*. <http://www.fao.org/3/a-i3959e.pdf>
- FAO. (2019). *AQUASTAT - FAO's Global Information System on Water and Agriculture*. <https://www.fao.org/aquastat/en/overview/methodology/water-use>

- FAO. (2023a). *Technical platform on the measurement and reduction of food loss and waste*. <https://www.fao.org/platform-food-loss-waste/food-loss/food-loss-measurement/en>
- FAO. (2023b). *Global Report on Food Crises: Number of people facing acute food insecurity rose to 258 million in 58 countries in 2022*. <https://www.fao.org/newsroom/detail/global-report-on-food-crises-GRFC-2023-GNAFC-fao-wfp-unicef-fpri/es>
- Galanakis, C. M. (2022). Sustainable applications for the valorization of cereal processing by-products. *Foods*, 11(2), 241. <https://doi.org/10.3390/foods11020241>
- Galanakis, C. M. (2023). The "Vertigo" of the food sector within the Triangle of climate change, the post-pandemic world, and the Russian-Ukrainian war. *Foods*, 12(4), 721. <https://doi.org/10.3390/foods12040721>
- Garcia-Garcia, G., Azanedo, L., & Rahimifard, S. (2021). Embedding sustainability analysis in new food product development. *Trends in Food Science & Technology*, 108, 236–244.
- Global Water Partnership. (2012). *Water in the green economy*. <https://www.gwp.org/globalassets/global/toolbox/publications/perspective-papers/03-water-in-the-green-economy-2012.pdf>
- Grindle, A. K., Siddiqi, A., & Anadon, L. D. (2015). Food security amidst water scarcity: Insights on sustainable food production from Saudi Arabia. *Sustainable Production and Consumption*, 2, 67–78.
- Gupta, P., & Sehgal, N. K. (2021). *Introduction to machine learning in the cloud with python: Concepts and practices*. Springer Nature.
- GWP, G. W. (2014). *Connecting water and energy*. Recuperado el 29 de Junio de 2021, de <https://www.gwp.org/en/>
- Handl, J., & Knowles, J. (2005). Improvements to the scalability of multiobjective clustering. *IEEE Congress on Evolutionary Computation*, 3, 2372–2379. <https://doi.org/10.1109/CEC.2005.1554990>

- Helistö, N., Kiviluoma, J., & Reittu, H. (2020). Selection of representative slices for generation expansion planning using regular decomposition. *Energy*, 211, 118585. <https://doi.org/10.1016/j.energy.2020.118585>
- Hitaj, C., & Suttles, S. (2016). *Trends in U.S. agriculture's consumption and production of energy: Renewable power, shale energy, and cellulosic biomass*. USA: United States Department of Agriculture Economic Information Bulletin.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hoff, H. (2011). *Understanding the Nexus*. Stockholm Environment Institute. <https://www.sei.org/publications/understanding-the-nexus/>
- Hoolohan, C., McLachlan, C., & Mander, S. (2016). Trends and drivers of end-use energy demand and the implications for managing energy in food supply chains: Synthesising insights from the social sciences. *Sustainable Production and Consumption*, 8, 1–17.
- IEA. (2012). *Water for energy. Is energy becoming a thirstier resource?* <https://www.iea.org/topics/world-energy-outlook>
- INE. (2021). *Spain in numbers*. https://www.ine.es/ss/Satellite?L=es_ES&c=INEPublicacion_C&cid=1259924856416&p=1254735110672&pagename=ProductosYServicios%2FPYSLayout¶m1=PYSDetalleGratuitas
- INE. (2022). *INEbase*. <https://www.ine.es/dyns/INEbase/listaoperaciones.htm>
- IRENA. (2015). *Renewable energy and the water, energy and food nexus 2015*. http://www.irena.org/documentdownloads/publications/irena_water_energy-food_nexus_2015.pdf
- Islam, S., & Roy, N. K. (2023). Renewables integration into power systems through intelligent techniques: Implementation procedures, key features, and performance evaluation. *Energy Reports*, 9, 6063–6087. <https://doi.org/10.1016/j.egyr.2023.05.063>

- Ji, L., Zhang, B., Huang, G., & Lu, Y. (2020). Multi-stage stochastic fuzzy random programming for food-water-energy nexus management under uncertainties. *Resources, Conservation and Recycling*, 155, 104665. <https://doi.org/10.1016/j.resconrec.2019.104665>
- Jo, T. (2021). Introduction. *Machine Learning Foundations*, 3–22. https://doi.org/10.1007/978-3-030-65900-4_1
- Ketchen, D. J., & Shook, C. L. (1996). The application of cluster analysis in strategic management research: An analysis and critique. *Strategic Management Journal*, 17(6), 441–458. <https://www.jstor.org/stable/2486927>
- Khanom, T. (2016). Effect of salinity on food security in the context of interior coast of Bangladesh. *Ocean & Coastal Management*, 130, 205–212.
- Kollmannsberger, S., D’Angella, D., Jokeit, M., & Herrmann, L. (2021). Fundamental concepts of machine learning. *Studies in Computational Intelligence*, 977, 5–18. https://doi.org/10.1007/978-3-030-76587-3_2
- Kotzur, L., Markewitz, P., Robinius, M., & Stolten, D. (2018). Impact of different time series aggregation methods on optimal energy system design. *Renewable Energy*, 117, 474–487. <https://doi.org/10.1016/j.renene.2017.10.017>
- Kotzur, L., Nolting, L., Hoffmann, M., Groß, T., Smolenko, A., Priesmann, J., Büsing, H., Beer, R., Kullmann, F., Singh, B., Praktiknjo, A., Stolten, D., Robinius, M. (2021). A modeler’s guide to handle complexity in energy systems optimization. *Adv. Appl. Energy* 4, 100063. <https://doi.org/10.1016/j.adapen.2021.100063>.
- Kraj, K., & Smol, M. (2023). How to achieve climate neutrality—the impact of fertilizer usage on climate change. In *Sustainable and Circular Management of Resources and Waste Towards a Green Deal* (pp. 349–356). Elsevier.
- Lara, C.L., Mallapragada, D.S., Papageorgiou, D.J., Venkatesh, A., Grossmann, I.E. (2018). Deterministic electric power infrastructure planning: mixed-integer programming model and nested decomposition algorithm. *Eur. J. Oper. Res.* 271 (3), 1037–1054. <https://doi.org/10.1016/J.EJOR.2018.05.039>.

- Laspidou, C., Witmer, M., Vamvakeridou-Lyroudia, L. S., Domingo, X., Brouwer, F. M., Howells, M., & Papadopoulou, M. P. (2017). The water-land-food-energy-climate Nexus for a resource efficient Europe. *15th International Conference on Environmental Science and Technology*.
- Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2018). Hyperband: A novel bandit-based approach to hyperparameter optimization. *arXiv preprint arXiv:1603.06560*. <https://arxiv.org/abs/1603.06560>
- Li, Z., Xia, Y., Bo, Y., & Wei, W. (2024). Optimal planning for electricity-hydrogen integrated energy system considering multiple timescale operations and representative time-period selection. *Applied Energy*, 362, 122965. <https://doi.org/10.1016/j.apenergy.2024.122965>
- López-Flores, F.J., Rubio-Castro, E., Ponce-Ortega, J.M. (2022). Incorporating machine learning for thermal engines modeling in industrial waste heat recovery. *Chem. Eng. Res. Des.* 181, 239–252. <https://doi.org/10.1016/j.cherd.2022.03.022>.
- Lotfi, A., Mohammadi-Ivatloo, B., & Asadi, S. (2020). Introduction to FEW nexus. In *Food-Energy-Water Nexus Resilience and Sustainable Development: Decision-Making Methods, Planning, and Trade-Off Analysis* (pp. 29–56). Springer. https://doi.org/10.1007/978-3-030-40052-1_2
- MAPA. (2021). *Ecological production*. <https://www.mapa.gob.es/es/alimentacion/temas/produccion-eco/>
- MAPA. (2022). *Directorate General of the Food Industry*. <https://www.mapa.gob.es/es/alimentacion/temas/default.aspx>
- Matharu, A. S., de Melo, E. M., & Houghton, J. A. (2016). Opportunity for high value-added chemicals from food supply chain wastes. *Bioresource Technology*, 215, 123–130. <https://doi.org/10.1016/j.biortech.2016.03.039>
- Maupin, M. A., Kenny, J. F., Hutson, S. S., Lovelace, J. K., Barber, N. L., & Linsey, K. S. (2014). *Estimated use of water in the United States in 2010* (Circular No. 1405). US Geological Survey. <https://doi.org/10.3133/cir1405>

- Mentch, L., & Hooker, G. (2016). Quantifying uncertainty in random forests via confidence intervals and hypothesis tests. *Journal of Machine Learning Research*, 17(26), 1–41. <http://jmlr.org/papers/v17/14-168.html>
- Molajou, A., Afshar, A., Khosravi, M., Soleimanian, E., Vahabzadeh, M., & Variani, H. A. (2021). A new paradigm of water, food, and energy nexus. *Environmental Science and Pollution Research*, 28, 1–11. <https://doi.org/10.1007/s11356-021-13034-1>
- Mohtar, R. H., & Daher, B. (2016). Water-Energy-Food Nexus Framework for facilitating multi-stakeholder dialogue. *Water International*, 41(5), 655–661. <https://doi.org/10.1080/02508060.2016.1149759>
- Muluneh, M. G. (2021). Impact of climate change on biodiversity and food security: A global perspective—a review article. *Agriculture & Food Security*, 10(1), 1–25. <https://doi.org/10.1186/s40066-021-00318-5>
- Namany, S., & Al-Ansari, T. (2021). Energy, Water, Food Nexus Decision-Making for Sustainable Food Security. In S. S. Muthu (Ed.), *The Water-Energy-Food Nexus* (pp. 1–25). Springer.
- Naranjo, L., & Willaarts, B. (2020). *Methodological guide: Design of actions with a water-energy-food nexus approach for Latin American and Caribbean countries*. ECLAC. <https://repositorio.cepal.org/handle/11362/46078>
- NSW. (2017). *NSW Government*. Obtenido de Department of Primary Industries: <https://www.dpi.nsw.gov.au/agriculture/soils/salinity/general-information/irrigation>
- OECD. (2016). *Policy guidance on resource efficiency*. <https://www.oecd.org/environment/waste/Resource-Efficiency-G7-2016-Policy-Highlights-web.pdf>
- O'Malley, T., Bursztein, E., Long, J., Chollet, F., Jin, H., & Invernizzi, L. (2019). *Keras Tuner*. GitHub. <https://github.com/keras-team/keras-tuner>
- OMS. (2022). *UN Report: Global hunger numbers rose to as many as 828 million in 2021*. 2022. Retrieved from <https://www.who.int/news/item/06-07-2022-un-report-global-hunger-numbers-rose-to-as-many-as-828-million-in-2021>. (Accessed 26 July 2023).

- ONU. (2015). *Sustainable development goals*.
<https://www.un.org/sustainabledevelopment/es/2015/09/la-asamblea-general-adopta-la-agenda-2030-para-el-desarrollo-sostenible/>
- Podmore, C. (2009). *Irrigation Salinity: Causes and Impacts* (Primefact 937). NSW Department of Primary Industries.
http://www.dpi.nsw.gov.au/data/assets/pdf_file/0018/310365/Irrigation-salinity-causes-and-impacts.pdf
- PNUMA. (2011). *Hacia una economía verde: Guía para el desarrollo sostenible y la erradicación de la pobreza*. <http://sostenibilidadyprogreso.org/files/entradas/hacia-una-economia-verde.pdf>
- Rajagukguk, R. A., Ramadhan, R. A., & Lee, H. J. (2020). A review on deep learning models for forecasting time series data of solar irradiance and photovoltaic power. *Energies*, 13(24), 6623. <https://doi.org/10.3390/en13246623>
- REE. (2022). *Electricity grid of Spain*. <https://www.ree.es/es/datos/balance/balance-electrico>
- Reinhard, S., Verhagen, J., Wolters, W., & Ruben, R. (2017). *Water-food-energy nexus: A quick scan*. Wageningen Economic Research.
- Renner, S. (2018). Poverty and distributional effects of a carbon tax in Mexico. *Energy Policy*, 112, 98–110. <https://doi.org/10.1016/j.enpol.2017.10.011>
- Ringler, C., Bhaduri, A., & Lawford, R. (2013). The nexus across water, energy, land and food (WELF): Potential for improved resource use efficiency? *Current Opinion in Environmental Sustainability*, 5(6), 617–624.
<https://doi.org/10.1016/j.cosust.2013.11.002>
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53–65.
[https://doi.org/10.1016/0377-0427\(87\)90125-7](https://doi.org/10.1016/0377-0427(87)90125-7)
- Sachs, J. D., Lafortune, G., Fuller, G., & Drumm, E. (2023). *Sustainable Development Report 2023: Implementing the SDG stimulus*. SDSN.
<https://policycommons.net/artifacts/4445283/2023-sustainable-development-report/>

- SADER. (2021). Agrifood Outlook 2021. <https://www.gob.mx/siap/acciones-y-programas/panorama-agroalimentario-258035> (accessed 2 November 2022).
- Salam, P. A., Shrestha, S., Pandey, V. P., & Anal, A. K. (Eds.). (2017). *Water-energy-food nexus: Principles and practices*. John Wiley & Sons.
- Saxena, R., Vanga, S. K., Wang, J., Orsat, V., & Raghavan, V. (2018). Millets for food security in the context of climate change: A review. *Sustainability*, 10(7), 2228. <https://doi.org/10.3390/su10072228>
- Scherer, L., Behrens, P., de Koning, A., Heijungs, R., Sprecher, B., & Tukker, A. (2018). Trade-offs between social and environmental sustainable development goals. *Environmental Science & Policy*, 90, 65–72. <https://doi.org/10.1016/j.envsci.2018.10.002>
- Schuster Wallace, C., & Sandford, R. (2015). *Water in the world we want: Catalysing national water-related sustainable development*. United Nations University.
- Scikit-learn. (2023). *sklearn.preprocessing.StandardScaler*. <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html>
- SEI. (2013). *Long-range Energy Alternatives Planning System (LEAP)*. <http://sei-us.org/software/leap>
- SEI. (2014). *Water Evaluation and Planning (WEAP) tool*. <http://www.weap21.org>
- SENER. (2018). *National Electric System Development Program 2018–2032 (PRODESEN)*. <https://www.gob.mx/cms/uploads/attachment/file/331770/PRODESEN-2018-2032-definitiva.pdf>
- SENER. (2022). National Electric System Development Program. <https://www.gob.mx/sener/articulos/programa-para-el-desarrollo-del-sistema-electrico-nacional-304042> (Accessed 28 October 2022).
- SEMARNAT. (2020b). Coverage of the population with piped water service. http://dgeiawf.semarnat.gob.mx:8080/ibi_apps/WFServlet?IBIF_ex=D1_SISCDS03_

- 01&IBIC_user=dgeia_mce&IBIC_pass=dgeia_mce&NOMBREENTIDAD=* &NOMBREANIO=* (Accessed 26 August 2022).
- SEMARNAT (2020a). Coverage of the population with electricity service. http://dgeiawf.semarnat.gob.mx:8080/ibi_apps/WFServlet?IBIF_ex=D1_SISCDS03_03&IBIC_user=dgeia_mce&IBIC_pass=dgeia_mce&NOMBREENTIDAD=* &NOMBREANIO=* (Accessed 26 August 2022).
- SIAP (2022). Agrifood Information System for Consultation (SIACON). <https://www.gob.mx/siap/documentos/siacon-ng-161430> (Accessed 25 November 2022).
- Siddiqi, A., & Anadon, L. D. (2011). The water-energy nexus in Middle East and North Africa. *Energy Policy*, 39(8), 4529–4540. <https://doi.org/10.1016/j.enpol.2011.04.023>
- SIE. (2022). Energy information system. <https://sie.energia.gob.mx/> (Accessed 25 November 2022).
- SINA. (2021). Renewable water. <http://sina.conagua.gob.mx/sina/tema.php?tema=aguaRenovable&ver=reporte&o=0&n=regional> (Accessed 6 November 2022).
- SINA. (2022). Aquifers (national). <http://sina.conagua.gob.mx/sina/tema.php?tema=acuiferos&ver=reporte&o=1&n=nacional> (Accessed 6 November 2022).
- Smajgl, A., & Ward, J. (Eds.). (2013). *The Water-Food-Energy Nexus in the Mekong Region*. Springer. <https://doi.org/10.1007/978-1-4614-6120-3>
- Subasi, A. (2020). Machine learning techniques. In *Practical Machine Learning for Data Analysis Using Python* (pp. 91–202). Elsevier. <https://doi.org/10.1016/B978-0-12-821379-7.00003-5>
- Tallaksen, J., Bauer, F., Hulteberg, C., Reese, M., & Ahlgren, S. (2015). Nitrogen fertilizers manufactured using wind power: Greenhouse gas and energy balance of community-scale ammonia production. *Journal of Cleaner Production*, 107, 626–635.
- Tejada-Arango, D. A., Domeshek, M., Wogrin, S., & Centeno, E. (2018). Enhanced representative days and system states modeling for energy storage investment

- analysis. *IEEE Transactions on Power Systems*, 33(6), 6534–6544.
<https://doi.org/10.1109/TPWRS.2018.2819578>
- Tiwari, M. K., & Adamowski, J. F. (2017). An ensemble wavelet bootstrap machine learning approach to water demand forecasting: A case study in the city of Calgary, Canada. *Urban Water Journal*, 14(2), 185–201.
- UNEP. (2011). *Towards a Green Economy: Pathways to Sustainable Development and Poverty Eradication*.
https://sustainabledevelopment.un.org/content/documents/126GER_synthesis_en.pdf
- UNESCO. (2015). *The United Nations World Water Development Report 2015: Water for a Sustainable World*. <http://www.unesco.org/new/es/natural-sciences/environment/water/wwap/wwdr/2015-water-for-a-sustainable-world/>
- United Nations. (2015). *World Population Prospects: The 2015 Revision*.
https://population.un.org/wpp/publications/files/key_findings_wpp_2015.pdf
- United Nations. (2018). *2018 Global Report on Food Crises*. World Food Programme.
<https://www.wfp.org/publications/global-report-food-crises-2018>
- United Nations. (2023). *Transforming our world: The 2030 Agenda for Sustainable Development*. <https://sdgs.un.org/2030agenda>
- UN-Water. (2015). *Wastewater Management: A UN-Water Analytical Brief*.
<https://www.unwater.org/>
- World Economic Forum. (2016). *The Global Risks Report 2016*.
<https://reports.weforum.org/global-risks-2016/>
- Wu, J. (2012). Cluster analysis and K-means clustering: An introduction. In *Advances in K-means Clustering* (pp. 1–16). Springer. https://doi.org/10.1007/978-3-642-29807-3_1
- Wu, J., Chen, X.-Y., Zhang, H., Xiong, L.-D., Lei, H., Deng, S.-H. (2019). Hyperparameter optimization for machine learning models based on Bayesian optimization. *J.*

Electron. Sci. Technol. 17, 26–40. <https://doi.org/10.11989/JEST.1674-862X.80904120>

Zhang, C., Chen, X., Li, Y., Ding, W., & Fu, G. (2018). Water-energy-food nexus: Concepts, questions and methodologies. *Journal of Cleaner Production*, 195, 625–639. <https://doi.org/10.1016/j.jclepro.2018.05.194>

Zwaan, B., Kober, T., & Halstead, M. (2014). Understanding the Energy-Water Nexus. *Political Science*, 46(3), 329–344.

Apéndice A. Caratulas de artículos científicos publicados en este proyecto Fase 1

Sustainable Production and Consumption 39 (2023) 109–122



Contents lists available at ScienceDirect

Sustainable Production and Consumption

journal homepage: www.elsevier.com/locate/spc



A spatial and temporal assessment of resource security in the water, energy, food and waste nexus in Spain

Alma Yunuen Raya-Tapia^a, Brenda Cansino-Loeza^a, Xate Geraldine Sánchez-Zarco^a,
César Ramírez-Márquez^{a,*}, Mariano Martín^b, José María Ponce-Ortega^a

^a Chemical Engineering Department, Universidad Michoacana de San Nicolás de Hidalgo, Francisco J. Múgica S/N, Ciudad Universitaria, Morelia, Michoacán 58060, Mexico

^b Department of Chemical Engineering, University of Salamanca, Psa. Caldas 1-5, 37008 Salamanca, Spain

ARTICLE INFO

Editor: Dr. Gonzalo Guillen Gosalbes

Keywords:

Water-energy-food-waste nexus
Security
Composite index
Sustainability
Climate change

ABSTRACT

The effects of climate change, such as droughts and decreased rainfall, as well as population growth and globalization are aggravating the availability of water, energy and food. As a result, meeting the population's demand will be a major challenge in the near future. For this reason, assessing the situation of the water-energy-food (WEF) nexus is of great importance to know the vulnerabilities of the system and take actions to correct or improve them. The contribution of this work is the formulation of a composite index called the WEF-Waste index that includes 13 indicators, 4 of which are indicators to measure aspects of the water sector that include availability, independence, treatment and recycling; 3 energy indicators that include availability, independence and renewable energy; 4 food indicators that measure availability, food independence, ecological area planted and food waste; and 2 urban solid waste indicators that measure the level of separation and reuse. The WEF-Waste index was evaluated in Spain at the national level and in the 17 autonomous communities over a period of 10 years in order to focus on the spatial and temporal distribution pattern of the WEF nexus. Results show that the indicator with the lowest scores over the years was water availability, which indicates a very important water deficiency. On the other hand, high values in the water treatment indicator were obtained, showing that a high percentage of the water supplied to the network and used is processed in wastewater treatment plants. The WEF-Waste index has an improving trend from 2010 to 2014. However, by 2016 it suffered a decay and from that year to 2020, it again presented a positive trend in the scores of the communities.



Contents lists available at [ScienceDirect](https://www.sciencedirect.com)

Environmental Science and Policy

journal homepage: www.elsevier.com/locate/envsci



Incorporating deep learning predictions to assess the water-energy-food nexus security

Alma Yunuen Raya-Tapia, Francisco Javier López-Flores, José María Ponce-Ortega^{*}

Chemical Engineering Department, Universidad Michoacana de San Nicolás de Hidalgo, Francisco J. Múgica S/N, Ciudad Universitaria, Morelia, Michoacán 58060, Mexico

ARTICLE INFO

Keywords:

Forecasts
Water consumption
Nexus
Energy security
Food production
Sustainability

ABSTRACT

Water, energy and food (WEF) are experiencing significant stress due to an increase in their demand and scarcity, and this situation will worsen in the coming years. For this reason, this paper proposes a WEF nexus index, which consists of 6 indicators of availability and accessibility to measure water, energy and food security. The proposed methodology, based on indicators and a scoring system, allows decision-makers to evaluate the nexus security and implement actions to achieve the sustainability of the three resources by 2050. Models based on deep learning are developed for the projection of the production and consumption of resources for the case study of Mexico. The Long Short-Term Memory and Gated Recurrent Unit networks are considered. Projections for 2050 resulted in water consumption of 121,679 hm³, electricity generation of 772,486 GWh and electricity consumption of 932,764 GWh, while food production will reach 351,802,080 tons. This represents an increase of 51.7% in water consumption, 180.33% in electricity generation, 254.54% in electricity demand and 103.05% in food production, compared to 2010. The WEF nexus index has an upward trend because the accessibility of water and energy will increase by 2050, but their availability will decrease; the opposite is the case in the food sector, where availability will increase and access will decrease.



Contents lists available at ScienceDirect

Trends in Food Science & Technology

journal homepage: www.elsevier.com/locate/tifs



A typology country framework to evaluate the SDG progress and food waste reduction based on clustering analysis

Alma Yunuen Raya-Tapia, Xate Geraldine Sánchez-Zarco, Brenda Cansino-Loeza, César Ramírez-Márquez, José María Ponce-Ortega

Chemical Engineering Department, Universidad Michoacana de San Nicolás de Hidalgo, Francisco J. Múgica S/N, Ciudad Universitaria, Morelia, Michoacán, 59060, Mexico

ARTICLE INFO

Handling Editor: Dr AR Jambrak

Keywords:

Sustainable development goals
Food sector
Clustering
2030 Agenda
Food waste

ABSTRACT

Countries are far from achieving the 17 SDGs by 2030 with the crises generated by the COVID-19 pandemic, the Russia-Ukraine war, and climate change. For this reason, this paper proposes a way of grouping countries based on the k-means machine learning technique to better understand the differences between countries beyond just having the score of meeting the 17 SDGs. In the first scenario, clustering analysis was applied involving the 17 SDGs and in the second scenario, the 17 SDGs and the Household Food Waste Indicator were considered for the clustering analysis. The results show that for the first scenario three clusters are formed, where one cluster called "High Sustainability" is characterized by the highest scores on fifteen SDGs and the lowest scores on SDG 12: Responsible Production and Consumption and SDG 13: Climate Action. In the second scenario, four groups were obtained, where the group "High Sustainability" with the highest scores in the SDGs has the lowest amount of household food waste, while the countries in the group with medium-high sustainability have the highest amount of household food waste. Thus, more appropriate compliance pathways can be established for each typology, as they share similar progress in meeting the 17 SDGs.



Contents lists available at ScienceDirect

Computers and Chemical Engineering

journal homepage: www.elsevier.com/locate/compchemeng

Comparative framework of representative weeks selection methods for the optimization of power systems

Alma Yunuen Raya-Tapia^a, Francisco Javier López-Flores^a, Javier Tovar-Facio^b,
José María Ponce-Ortega^{a, *}

^a Chemical Engineering Department, Universidad Michoacana de San Nicolás de Hidalgo, Francisco J. Múgica S/N, Ciudad Universitaria, Morelia, Michoacán, 58060, Mexico

^b Faculty of Chemical Sciences, Universidad Autónoma de Chihuahua, Circuito Universitario S/N, Campus UACH II, Chihuahua, Chih. 31125, Mexico

ARTICLE INFO

Keywords:

Clustering
Time
Periods
Power system
K-means
Regions

ABSTRACT

Considering the reliability and flexibility to supply future energy demand, power grid planning models are composed of mathematical formulations that represent investments in the installation and operation of generation and storage systems to reduce costs and environmental impacts. However, these can be computationally intractable to solve for many periods. Hence, in this paper, three methods are compared to obtain representative weeks in terms of their accuracy in representing the net load duration curve (NLDC) of the 5 regions that compose the Mexican peninsular electric system and in the objective function domain of a proposed model. The selection methods used for representative weeks were k-means with Euclidean metric, k-means with dynamic time warping (DTW) metric and a combinatorial method. It was observed that the combinatorial method obtained a root mean square error (RMSE) in the representation of 2.80, followed by k-means with DTW metric with 3.21 and finally k-means with Euclidean metric with 5.49. K-means with DTW metric requires about 17 and 70 times more computational time than the combinatorial method and k-means with Euclidean metric, because it had no restrictions on the amount of deformation allowed. In terms of the objective function, the combinatorial method had higher total system costs with $\$ 4.4274 \times 10^{10}$, while they were 0.1 % and 0.2 % lower in k-means with DTW and k-means with Euclidean metric, respectively. These lower costs are due to underestimation of the system cost, as the methods do not adequately reflect operational situations and generate less expensive scenarios than are actually the case.

Alma Yunuen Raya Tapia

Incorporación del Aprendizaje Automático en la Evaluación del Nexo WEF, la Planificación Energética

 Universidad Michoacana de San Nicolás de Hidalgo

Detalles del documento

Identificador de la entrega

trn:oid:::3117:484958148

Fecha de entrega

20 ago 2025, 10:25 a.m. GMT-6

Fecha de descarga

20 ago 2025, 10:55 a.m. GMT-6

Nombre del archivo

Incorporación del Aprendizaje Automático en la Evaluación del Nexo WEF, la Planificación Energé....pdf

Tamaño del archivo

5.7 MB

153 páginas

38.786 palabras

219.889 caracteres

12% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- Texto citado
- Texto mencionado
- Coincidencias menores (menos de 10 palabras)

Fuentes principales

- 12%  Fuentes de Internet
- 9%  Publicaciones
- 0%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

Formato de Declaración de Originalidad y Uso de Inteligencia Artificial

Coordinación General de Estudios de Posgrado
Universidad Michoacana de San Nicolás de Hidalgo



A quien corresponda,

Por este medio, quien abajo firma, bajo protesta de decir verdad, declara lo siguiente:

- Que presenta para revisión de originalidad el manuscrito cuyos detalles se especifican abajo.
- Que todas las fuentes consultadas para la elaboración del manuscrito están debidamente identificadas dentro del cuerpo del texto, e incluidas en la lista de referencias.
- Que, en caso de haber usado un sistema de inteligencia artificial, en cualquier etapa del desarrollo de su trabajo, lo ha especificado en la tabla que se encuentra en este documento.
- Que conoce la normativa de la Universidad Michoacana de San Nicolás de Hidalgo, en particular los Incisos IX y XII del artículo 85, y los artículos 88 y 101 del Estatuto Universitario de la UMSNH, además del transitorio tercero del Reglamento General para los Estudios de Posgrado de la UMSNH.

Datos del manuscrito que se presenta a revisión		
Programa educativo	Doctorado en Ciencias en Ingeniería Química	
Título del trabajo	Incorporación del Aprendizaje Automático en la Evaluación del Nexo WEF, la Planificación Energética y la Sostenibilidad Global: Un Enfoque desde la Ingeniería Química	
	Nombre	Correo electrónico
Autor/es	Alma Yunuen Raya Tapia	alma.raya@umich.mx
Director	José María Ponce Ortega	jose.ponce@umich.mx
Codirector		
Coordinador del programa	José Apolinar Cortés	doc.cs.ingenieria.quimica@umich.mx

Uso de Inteligencia Artificial		
Rubro	Uso (sí/no)	Descripción
Asistencia en la redacción	no	

Formato de Declaración de Originalidad y Uso de Inteligencia Artificial

Coordinación General de Estudios de Posgrado
Universidad Michoacana de San Nicolás de Hidalgo



Uso de Inteligencia Artificial		
Rubro	Uso (sí/no)	Descripción
Traducción al español	no	
Traducción a otra lengua	no	
Revisión y corrección de estilo	no	
Análisis de datos	no	
Búsqueda y organización de información	no	
Formateo de las referencias bibliográficas	no	
Generación de contenido multimedia	no	
Otro	no	

Datos del solicitante	
Nombre y firma	
Lugar y fecha	Morelia, Michoacán de Ocampo, Agosto de 2025