



MAESTRÍA PROFESIONAL
INGENIERÍA DEL SOFTWARE ENFASIS EN INTELIGENCIA ARTIFICIAL

Proyecto de Investigación Aplicada

Modelado y predicción del consumo energético de vehículos eléctricos ligeros en hogares costarricenses a partir de patrones de carga y características técnicas.

Chacón Garro Maverick Josué
López López Marni Andrei

10 de Agosto, 2025

Declaratoria de derechos de autor

Nosotros, Marni Andrei Lopez Lopez y Maverick Josué Chacón Garro, en calidad de coautores y titulares de los derechos patrimoniales del presente trabajo de investigación titulado "Modelado y predicción del consumo energético de vehículos eléctricos ligeros en hogares costarricenses a partir de patrones de carga y características técnicas", autorizamos su consulta y reproducción con fines exclusivamente académicos, de conformidad con la normativa vigente de la institución.

Cualquier otro uso distinto al académico, incluyendo fines comerciales o de difusión no autorizada, queda expresamente prohibido sin el consentimiento escrito de ambos autores.

[Firma del autor 1]

Marni Lopez Lopez

[Firma del autor 2]

Maverick Chacón Garro

San Jose, Agosto del 2025

Tabla de contenidos

CAPÍTULO 1. INTRODUCCIÓN	8
1.1. GENERALIDADES	8
1.2. ANTECEDENTES DEL PROBLEMA.....	8
1.3. DEFINICIÓN Y DESCRIPCIÓN DEL PROBLEMA	9
1.4. JUSTIFICACIÓN	9
1.5. VIABILIDAD	10
1.6. OBJETIVOS.....	10
1.6.1. <i>General</i>	10
1.6.2. <i>Específicos</i>	11
1.7. ALCANCES Y LIMITACIONES	11
1.7.1. <i>Alcances</i>	11
1.7.2. <i>Limitaciones</i>	12
1.8. MARCO REFERENCIAL ORGANIZACIONAL Y SOCIOECONÓMICO	13
1.8.1. <i>Historia</i>	13
1.8.2. <i>Tipo de negocio y mercado meta</i>	13
1.8.3. <i>Motivación del proyecto</i>	14
1.8.4. <i>Colaboración intra-institucional y apoyo institucional</i>	14
1.9. REVISIÓN DE LITERATURA	14
1.9.1. <i>Revisión sistemática</i>	14
1.9.2. <i>Estado de la cuestión</i>	15
1.9.3. <i>Ejecución de la fuente ACM</i>	15
1.9.4. <i>Ejecución de la fuente IEE</i>	17
1.9.5. <i>Ejecución de la fuente Google Scholar</i>	23
1.9.6. <i>Ejecución de la fuente Research Gate</i>	28
1.10. SÍNTESIS DEL ESTADO DE LA CUESTIÓN Y JUSTIFICACIÓN DEL MODELO PROPUESTO	32
CAPÍTULO 2. MARCO CONCEPTUAL.....	33
2.1. FIGURA DE CONCEPTOS SOBRE EL CONTENIDO	33
2.2. MAPA CONCEPTUAL JERÁRQUICO	34
2.3. CONCEPTOS.....	35
CAPÍTULO 3. MARCO METODOLÓGICO.....	52
3.1. TIPO DE INVESTIGACIÓN.....	52
3.2. ALCANCE INVESTIGATIVO.....	53
3.3. ENFOQUE.....	53
3.4. DISEÑO.....	54
3.5. POBLACIÓN Y MUESTREO	55
3.6. INSTRUMENTOS DE RECOLECCIÓN DE DATOS.....	56

3.6.1. <i>Revisión documental</i>	56
3.6.2. <i>Encuestas estructuradas</i>	57
3.7. TÉCNICAS DE ANÁLISIS DE INFORMACIÓN	62
3.7.1. <i>Análisis exploratorio de datos</i>	62
3.7.2. <i>Técnicas de Análisis Cuantitativas (Encuestas)</i>	63
3.7.3. <i>Técnicas de Análisis Cualitativas (Revisión Documental)</i>	64
CAPÍTULO 4. ANÁLISIS DEL DIAGNOSTICO	65
4.1. APLICACIÓN DE ENCUESTAS.....	65
4.1.1. <i>Criterios ambientales</i>	66
4.1.2. <i>Factores socioeconómicos</i>	68
4.1.3. <i>Factores que frenan la compra de vehículos eléctricos</i>	71
4.1.4. <i>Percepción del incremento en la factura eléctrica tras la adquisición de un vehículo eléctrico</i>	72
4.1.5. <i>Uso de herramientas de IA y estrategias de optimización en la recarga de vehículos eléctricos</i>	73
CAPÍTULO 5. PROPUESTA DE SOLUCION	76
5.1. ANALISIS DE DATOS EXPLOPRATORIO	76
5.1.1. <i>Descripción del conjunto de datos</i>	76
5.1.2. <i>Distribución de la variable objetivo</i>	77
5.1.3. <i>Correlaciones</i>	79
5.1.4. <i>Distribución de los datos</i>	79
5.2. LIMPIEZA DE DATOS	81
5.2.1. <i>Filtrado por Alcance (Scope Filtering)</i>	82
5.2.2. <i>Valores atípicos y extremos</i>	82
5.2.3. <i>Consistencia entre variables</i>	82
5.2.4. <i>Manejo de valores faltantes</i>	82
5.2.5. <i>Normalización de unidades</i>	83
5.3. INGENIERIA DE CARACTERISTICAS.....	83
5.3.1. <i>Calculo de estado de la carga (State of Charge)</i>	83
5.3.2. <i>Estimación de energía consumida según el estado de la carga</i>	84
5.3.3. <i>Unidad de eficiencia energética</i>	84
5.3.4. <i>Cálculo de la potencia promedio suministrada</i>	85
5.3.5. <i>Eficiencia de carga</i>	85
5.3.6. <i>Imputación de variable objetivo</i>	86
5.4. ENTRENAMIENTO DE MODELOS	86
5.4.1. <i>División del conjunto de datos</i>	86
5.4.2. <i>Estandarización de variables</i>	87
5.4.3. <i>Arquitectura del modelo</i>	87

5.5. COMPARACIÓN DE MODELOS	91
5.5.1. Regresión Lineal.....	91
5.5.2. XGBoost.....	92
5.5.3. Redes Neuronales Artificiales (ANN).....	92
5.6. APLICACIÓN Y CALCULO FINAL	92
5.6.1. Lectura y consumo medido.....	93
5.6.2. Bloques de consumo	93
5.6.3. Cargos fijos y variables.....	94
5.6.4. Tarifas horarias.....	94
5.6.5. Impuestos y cargos adicionales.....	95
5.7. SIMULADOR DE TARIFAS PROTOTIPO	95
5.7.1. Diseño de la aplicación.....	96
5.7.2. Alcances	97
5.7.3. Limitaciones.....	98
CAPÍTULO 6. CONCLUSIONES Y RECOMENDACIONES	99
CAPÍTULO 7. REFLEXIONES FINALES	102
CAPÍTULO 8. GLOSARIOS	103
CAPÍTULO 9. REFERENCIAS	105

Tabla de figuras

FIGURA 1. PARÁMETROS DE BÚSQUEDA EN ACM.....	15
FIGURA 2. CRITERIOS DE BÚSQUEDA.....	17
FIGURA 3. FILTRO APLICADO A GOOGLE SCHOLAR.....	24
FIGURA 4. NUBE DE CONCEPTOS.....	33
FIGURA 5. MAPA CONCEPTUAL JERÁRQUICO.....	34
FIGURA 6. DISTRIBUCIÓN DE PROPIETARIOS.....	66
FIGURA 7. FACTORES AMBIENTALES.....	67
FIGURA 8. IMPACTO AMBIENTAL.....	67
FIGURA 9. DEPENDENCIA DE COMBUSTIBLES FÓSILES.....	68
FIGURA 10. INCENTIVOS GUBERNAMENTALES.....	70
FIGURA 11. CARGOS DE MANTENIMIENTO.....	70
FIGURA 12. PRINCIPALES BARRERAS PARA LA ADQUISICIÓN DE VEHÍCULOS ELÉCTRICOS.....	72
FIGURA 13. PERCEPCIÓN Y CUANTIFICACIÓN DEL INCREMENTO EN LA FACTURA ELÉCTRICA TRAS LA ADOPCIÓN DE UN VEHÍCULO ELÉCTRICO.....	73
FIGURA 14. USO DE HERRAMIENTAS DE INTELIGENCIA ARTIFICIAL PARA ESTIMAR CONSUMO DE RECARGA.....	74
FIGURA 15. IMPLEMENTACIÓN DE ESTRATEGIAS DE OPTIMIZACIÓN ENERGÉTICA PARA LA RECARGA.....	74
FIGURA 16. DISTRIBUCIÓN DE LA VARIABLE OBJETIVO.....	78
FIGURA 17. MAPA DE CORRELACIONES.....	79
FIGURA 18. DIAGRAMA DE DISPERSIÓN SOBRE DATOS DE TIPO DE CARGADOR.....	80
FIGURA 19. DIAGRAMA DE DISPERSIÓN SOBRE TIPOS DE CARGADOR SELECCIONADOS.....	81
FIGURA 20. ARQUITECTURA DE MLP.....	87
FIGURA 21. VARIABLES PRINCIPALES.....	89
FIGURA 22. CURVA DE APRENDIZAJE.....	90
FIGURA 23. TARIFARIO POR BLOQUE DE CONSUMO.....	94
FIGURA 24. TARIFARIO RESIDENCIAL HORARIA.....	95
FIGURA 25. PROTOTIPO DE HERRAMIENTA DE SIMULACIÓN 1.....	96
FIGURA 26. PROTOTIPO DE PÁGINA DE RESULTADOS DEL SIMULADOR.....	97

Índice de tablas

TABLA 1. ESTUDIOS DE ACM.....	16
TABLA 2. PUBLICACIONES Y ESTUDIOS DE IEEE.....	17
TABLA 3. ESTUDIOS DE GOOGLE ACADÉMICO.....	24
TABLA 4. ESTUDIOS DE RESEARCH GATE.....	28
TABLA 5. ENCUESTA ESTRUCTURADA SOBRE EV.....	57
TABLA 6. DESCRIPCIÓN DE LAS CARACTERÍSTICAS DEL CONJUNTO DE DATOS.....	76
TABLA 7. ELEMENTOS DEL MODELO DE RED NEURONAL.....	87

TABLA 8. MÉTRICAS DE DESEMPEÑO89

TABLA 9. EJEMPLO: DATOS DE ENTRADA90

TABLA 10. COMPARATIVA DE MODELOS91

CAPÍTULO 1. Introducción

1.1. Generalidades

El presente estudio se apoya en un conjunto de datos públicos extraídos de la plataforma Kaggle, específicamente del recurso titulado Electric Vehicle Population (Maharaj, 2024). Esta base de datos contiene información detallada sobre el parque vehicular eléctrico registrado en el estado de Washington, Estados Unidos, incluyendo variables como tipo de vehículo, fabricante, año de fabricación, tipo de cargador, autonomía estimada y ubicación geográfica.

Aunque los datos no corresponden directamente al contexto costarricense, se realizó una selección y procesamiento de variables relevantes con el fin de identificar patrones generales de comportamiento en el uso de vehículos eléctricos. Esta estrategia busca adaptar los datos internacionales a la realidad nacional y así desarrollar un modelo predictivo que logre estimar el consumo energético domiciliario asociado al uso de vehículos eléctricos en Costa Rica.

La metodología propuesta contempla el análisis de patrones de consumo, estructuras tarifarias y hábitos de uso que puedan extrapolarse a partir de las características locales, incluyendo el perfil energético costarricense, su infraestructura eléctrica, y las políticas públicas en materia de movilidad sostenible.

1.2. Antecedentes del problema

Ante la creciente demanda de vehículos eléctricos (EV) en Costa Rica la cual según Barahona Carmona et al. (2025), entre diciembre de 2020 y setiembre de 2024, el número total de vehículos eléctricos pasó de 3300 a 20020 lo que representa un aumento de 507%. Sin embargo, al 2025 existen preocupaciones y mitos sobre el consumo energético de los EV, la vida útil de las baterías de litio, temas de infraestructura como la capacidad de la red eléctrica, patrones de carga y desinformación en la población costarricense sobre los costos de vehículos eléctricos. Estos factores dificultan la transición hacia una movilidad sostenible con el medio ambiente a pesar de ser el país en Latinoamérica con una alta tasa de adopción de EV en la flota vehicular.

En consecuencia, esta investigación pretende servir como base para futuros proyectos relacionados con el impacto socioeconómico, energético y ecológico de la adquisición de vehículos eléctricos en los hogares costarricenses.

1.3. Definición y Descripción del problema

La adopción de vehículos eléctricos se ve afectada por la incertidumbre de los consumidores respecto al impacto en su factura eléctrica. La falta de información clara sobre el consumo adicional generado por la carga del vehículo, dependiendo del modelo, la tarifa contratada y la frecuencia de uso, puede generar costos inesperados y afectar la percepción de viabilidad de la movilidad eléctrica. Este problema limita la toma de decisiones informadas y puede frenar la transición hacia el uso de EV. Por ello, es necesario desarrollar herramientas y estrategias que permitan estimar de manera precisa el impacto en el consumo eléctrico, brindando a los compradores información confiable que facilite su decisión y promueva la adopción de vehículos eléctricos.

1.4. Justificación

Para justificar el presente estudio, se siguieron las recomendaciones de Hernández, Fernández y Baptista (2014) en el sentido de hacer referencia a cinco criterios esenciales para sustentar una investigación: “la conveniencia del estudio, la relevancia social, las implicaciones prácticas, el valor teórico y la utilidad metodológica” (p. 40).

Según los datos proporcionados por Ureña (2025) para finales del año 2025 en Costa Rica se espera que la flota de vehículos eléctricos supere las 30 mil unidades, posicionándose Costa Rica, entre los países con mayor ocupación de vehículos eléctricos después de Brasil y México. Aunque la flota vehicular del país cerró el 2024 con un total de 3,021,220 unidades (Hidalgo, 2025) los vehículos eléctricos representan apenas 0.7% de dicha cifra. Es por eso por lo que en esta investigación se pretende modelar y predecir el consumo eléctrico de vehículos ligeros en hogares costarricenses.

Para ello, se busca desarrollar un algoritmo predictivo basado en inteligencia artificial que permita estimar este consumo, fundamentándose en la caracterización de los patrones de carga de los vehículos eléctricos y sus características técnicas.

Este enfoque busca generar información precisa y accesible para futuros estudios, con el fin de combatir la desinformación sobre el uso, los beneficios y las limitaciones de los EV, y así apoyar una transición más informada y sostenible hacia la movilidad eléctrica en los hogares costarricenses.

1.5. Viabilidad

Hoy en día se cuenta con una gran cantidad de datos sobre el consumo energético de distintos modelos de vehículos eléctricos. Además, existen herramientas y modelos especializados que permiten calcular cómo estos consumos adicionales impactan la factura de electricidad según las tarifas vigentes y los hábitos de uso de cada usuario. Para este análisis, se usaron software de modelado por aprendizaje automático, que ha demostrado ser efectivo.

La investigación se llevó a cabo en tiempos razonables porque la información requerida (bases de datos públicas y registros de consumo) está al alcance. Los métodos de análisis seleccionados son ágiles y probados, de modo que no se generen demoras innecesarias. Para recopilar los datos, se revisarán registros de las compañías distribuidoras y se hizo una revisión documental exhaustiva. Antes de comenzar el levantamiento masivo, se validarán estos instrumentos con un piloto para asegurarse de la calidad de la información. Asimismo, se cuenta con el respaldo de la institución académica y la voluntad de expertos voluntarios, lo que permite cumplir con los plazos que se han planteado.

1.6. Objetivos

1.6.1. General

Desarrollar un modelo predictivo que, a partir de patrones de consumo eléctrico, estructuras tarifarias y características técnicas de los vehículos eléctricos, estime el impacto en el consumo energético domiciliario y la facturación eléctrica en Costa Rica para evaluar su viabilidad económica y sostenibilidad con la información recopilada durante el proceso de investigación en el periodo comprendido desde el mes de enero de 2025 hasta diciembre de 2026.

1.6.2. Específicos

- Analizar un conjunto de datos públicos que incluye tamaños y tipos de batería, tiempos de carga, modelos de múltiples vehículos eléctricos, con el fin de identificar patrones y relaciones entre las características técnicas y los comportamientos de carga.
- Diseñar un modelo de inteligencia artificial predictivo capaz de estimar el incremento en el recibo eléctrico tras la adopción de un vehículo eléctrico orientado a facilitar la toma de decisiones por parte de consumidores, instituciones públicas y actores del sector eléctrico.
- Comparar los modelos predictivos de consumo energético en vehículos eléctricos propuestos en investigaciones previas, con el fin de identificar sus enfoques metodológicos, variables utilizadas y niveles de precisión.

1.7. Alcances y Limitaciones

1.7.1. Alcances

El proyecto contempla el desarrollo de un modelo predictivo que estime el impacto del uso de vehículos eléctricos en el consumo energético domiciliario y en la facturación eléctrica en Costa Rica. El estudio se enfocó en el análisis de patrones de consumo registrados en puntos de carga así como el comportamiento habitual de los usuarios con respecto a las estructuras tarifarias vigentes y características técnicas de los EV disponibles en el mercado costarricense.

El alcance del proyecto está conformado por los siguientes componentes principales.

- Simulación tarifaria: Se desarrolló un prototipo que permita simular distintos escenarios de consumo según tipo de vehículo, frecuencia de carga y tiempo estimado de carga, integrando los distintos esquemas tarifarios actualmente vigentes en la red energética nacional, para calcular el costo adicional que representaría el uso de EV a nivel doméstico.

- **Recomendaciones prácticas:** Se diseñó una herramienta que, basada en los datos analizados, brinde recomendaciones y buenas prácticas para optimizar el consumo energético en hogares que utilizan vehículos eléctricos. Esta herramienta buscará promover la eficiencia energética y reducir los costos de facturación.
- **Informe final e implementación:** El proyecto culminó con la elaboración de un informe técnico que integre resultados cuantitativos (provenientes del modelo predictivo y simulaciones) y cualitativos (derivados del análisis contextual y las recomendaciones). Este informe estuvo orientado a facilitar la toma de decisiones por parte de consumidores, instituciones públicas y actores del sector eléctrico, y permitió la reimplementación del modelo en otros contextos socioeconómicos.

El periodo de ejecución del proyecto está delimitado entre enero de 2025 y diciembre de 2026, y considera únicamente el contexto costarricense. No se contempla la inclusión de vehículos de transporte público ni de uso industrial, ni la evaluación de tecnologías futuras aún no disponibles en el país durante el periodo de estudio.

1.7.2. Limitaciones

El proyecto pretende brindar una estimación precisa y contextualizada del impacto del uso de vehículos eléctricos (EV) en el consumo energético domiciliario en Costa Rica, es importante reconocer las siguientes limitaciones que pudieron influir en la generalización y aplicabilidad de los resultados

- El análisis se fundamenta en conjuntos de datos correspondientes al año 2024, los cuales pueden presentar inconsistencias, vacíos o limitaciones en su granularidad. La precisión del modelo predictivo dependerá en gran medida de la calidad y representatividad de estos datos, así como de la disponibilidad de registros detallados de carga por tipo de vehículo y ubicación geográfica.
- Dado el ritmo acelerado de innovación en el ámbito de la movilidad eléctrica, las características técnicas de los vehículos considerados en el estudio

podrían quedar desactualizadas en el corto plazo. Esto podría limitar la vigencia del modelo predictivo más allá del periodo de análisis (2025 – 2026).

- El prototipo de simulación tarifaria se construirá con base en las estructuras tarifarias vigentes durante el periodo de estudio, sin contemplar posibles reformas regulatorias o cambios en la política energética que podrían alterar las condiciones del mercado eléctrico en el futuro.

Estas limitaciones no reducen la relevancia del estudio, pero sí acotan el marco de interpretación de sus resultados y la aplicabilidad de sus recomendaciones. Se espera que futuras investigaciones complementen este enfoque con análisis ampliados, longitudinales y multivariados.

1.8. Marco Referencial organizacional y socioeconómico

El Proyecto se enmarca en un contexto en el que la conciencia ambiental y la búsqueda de soluciones energéticas eficientes son prioridades tanto para la sociedad como para el ámbito académico, el mismo se desarrolla como una iniciativa académica sin fines de lucro, impulsada por el compromiso de generar un impacto positivo en la sociedad a través de la promoción de la movilidad sostenible y el uso eficiente de electricidad.

1.8.1. Historia

Esta investigación nace en el contexto del crecimiento de la movilidad eléctrica en Costa Rica y la necesidad de comprender su impacto en el consumo energético residencial. Surge como una iniciativa académica con enfoque aplicado, orientada a brindar herramientas que faciliten decisiones informadas sobre el uso de vehículos eléctricos en hogares, integrando tecnologías de inteligencia artificial y análisis energético contextualizado.

1.8.2. Tipo de negocio y mercado meta

Este proyecto no tiene fines comerciales, sino que se enmarca en la investigación académica aplicada. Está dirigido a hogares costarricenses con vehículos eléctricos, instituciones públicas del sector energético, empresas

distribuidoras de electricidad, y actores del ámbito académico y tecnológico interesados en movilidad sostenible, consumo energético y herramientas predictivas.

1.8.3. Motivación del proyecto

La motivación principal de la creación del Proyecto radica en la necesidad de ofrecer alternativas al pueblo costarricense y una herramienta a la sociedad que permita adaptarse al constante cambio de la información disponible sobre vehículos eléctricos, así facilitando decisiones informadas y promoviendo prácticas sostenibles en el ámbito doméstico y colectivo.

1.8.4. Colaboración intra-institucional y apoyo institucional

El proyecto no se asocia directamente con una empresa privada o pública en particular, cuenta con el respaldo y la colaboración de diversas instituciones académicas y redes profesionales. Este apoyo se materializa a través de la participación voluntaria de expertos, profesores y estudiantes, lo que enriquece el desarrollo del proyecto mediante el intercambio de conocimientos y el acceso a recursos académicos y tecnológicos.

1.9. Revisión de literatura

1.9.1. Revisión sistemática

Para establecer una base sólida en el análisis del impacto del consumo eléctrico asociado a la adopción de vehículos eléctricos, se aplicó una revisión sistemática de literatura. Esta revisión incluyó criterios de inclusión y exclusión con el fin de identificar estudios relevantes, recientes y de alta calidad. Se priorizaron investigaciones que abordaran metodologías predictivas, consumo energético y planificación de carga, constituyendo así la base conceptual y empírica para el modelo desarrollado en este estudio.

1.9.1.1. Selección de fuentes

Debido a la calidad de los artículos académicos y cantidad de artículos recientes, de acuerdo con el tema investigado, se considera la utilización de las siguientes fuentes:

1. ACM Digital Library.
2. IEEE Digital Library.
3. Scholar Google.
4. Research Gate.

1.9.2. Estado de la cuestión

La literatura revisada revela un cuerpo significativo de investigaciones centradas en la eficiencia y el rendimiento de los VE. Sin embargo, se identificó una laguna importante: la falta de estudios que analicen de forma detallada el impacto económico del consumo eléctrico en la factura del usuario final. Esta ausencia justifica el desarrollo de una herramienta de estimación que facilite la toma de decisiones informadas, tanto para usuarios como para operadores del sistema eléctrico.

1.9.3. Ejecución de la fuente ACM

1.9.3.1. Estrategia de búsqueda

Se aplicaron los siguientes términos clave: *Electric Vehicle*, *Forecasting* y *Consumption*, siguiendo las recomendaciones metodológicas de Blanco et al. (2007).

Figura 1. Parámetros de búsqueda en ACM.

Search Run Date:	2025-03-12 at 18:52:18 PDT
Search Result Count:	1
Query Syntax:	"query": {Title:(electric vehicle) AND Title:(forecasting) AND Title:(consume)} "filter": {ACM Content: DL}

Fuente: ACM

1.9.3.2. Resultado seleccionado

Tabla 1. Estudios de ACM

ACM DIGITAL LIBRARY

TITULO	Learning from historical data to predict electric vehicle taxi consumption and charging time.
PUBLICACIÓN	WSC '18: Proceedings of the 2018 Winter Simulation Conference
AUTORES	Kim Rioux-Paradis, Jonathan Gaudreault, Chloé Redmond, Kento Otomo-Lauzon, Frédéric Bernard, Anthony Deschênes, Claude-Guy Quimper, Simon Boivin, and Pascal Blouin
URL	https://dl.acm.org/doi/10.5555/3320516.3320667

Fuente: Elaboración propia.

1.9.3.3. Revisión de la fuente ACM

La selección de estudios primarios se hace tras realizar una revisión de los abstract y contenido incluido en cada artículo. Para la revisión de estos artículos, los mismos fueron ordenados de acuerdo con la cantidad de citas.

1.9.3.4. Extracción de la fuente ACM

1.9.3.4.1. Learning from historical data to predict electric vehicle taxi consumption and charging time

La simulación de una flota de taxis eléctricos requiere una gran cantidad de datos de difícil acceso. Aprendimos a partir de datos históricos para predecir el consumo de los vehículos eléctricos y el tiempo de carga. Aunque la simulación era el objetivo principal, los modelos desarrollados serán utilizados por el equipo de despacho de la empresa. Además, el proceso de análisis de datos nos permitió descubrir fallos en la infraestructura (por ejemplo, estaciones defectuosas y baterías en mal estado).

Aportes del estudio

- Predicción del Consumo Energético: El estudio se centra en utilizar datos históricos para predecir el consumo de energía y el tiempo de carga de taxis eléctricos. Este enfoque permite anticipar las necesidades energéticas y optimizar la gestión de flotas de vehículos eléctricos.

- Simulación de Flotas de Taxis Eléctricos: La investigación destaca la importancia de las simulaciones en la gestión de flotas de taxis eléctricos, utilizando datos históricos para predecir el consumo de energía y el tiempo de carga.
- Optimización de Recursos de Carga: Al predecir con precisión el consumo energético y los tiempos de carga, es posible mejorar la asignación de recursos de carga y la eficiencia operativa de las flotas de taxis eléctricos.

1.9.4. Ejecución de la fuente IEE

1.9.4.1. Estrategia de búsqueda

Siguiendo las recomendaciones provistas por (Blanco, et al., 2007), se realiza la búsqueda de estudios iniciales basados en los siguientes parámetros:

- Electric Vehicle
- Forecasting
- Consumption

Figura 2. Criterios de búsqueda.

Advanced Search	Command Search	Citation Search	
Enter keywords and select fields.			
Search Term Electric Vehicle		in	All Metadata ▼
AND ▼	Search Term forecasting	in	All Metadata ▼
AND ▼	Search Term consumption	in	All Metadata ▼

Fuente: IEEE

Tras realizar la búsqueda utilizando los parámetros mencionados, se encontraron 1084 resultados, de los cuales fueron seleccionados 5 tras aplicar el método de exclusión propuesto. A continuación, se presenta el detalle de los mismos

1.9.4.2. Estudios Seleccionados y síntesis

Tabla 2. Publicaciones y estudios de IEEE.

IEEE

TITULO	Calculation Method of Electric Vehicle Power Consumption Based on Naive Bayes Classification
PUBLICACIÓN	2021 IEEE Sustainable Power and Energy Conference (iSPEC)
AUTORES	Fu Zhixin; Bao Hanzhou; Yuan Yue
URL	https://ieeexplore.ieee.org/document/9735457/
TITULO	Forecasting Energy Consumption of Electric Vehicles
PUBLICACIÓN	2023 5th Global Power, Energy and Communication Conference (GPECOM)
AUTORES	Hasan Huseyin Coban; Mohit Bajaj; Vojtech Blazek; Francisco Jurado; Salah Kamel
URL	https://ieeexplore.ieee.org/document/10175761/
TITULO	Electric Energy and Power Consumption by Light-Duty Plug-In Electric Vehicles
PUBLICACIÓN	IEEE Transactions on Power Systems (Volume: 26, Issue: 2, May 2011)
AUTORES	Di Wu; Dionysios C. Aliprantis; Konstantina Gkritza
URL	https://ieeexplore.ieee.org/document/5524052/
TITULO	Neural Network-based Load Forecasting Model for Efficient Charging of Electric Vehicles
PUBLICACIÓN	2022 7th Asia Conference on Power and Electrical Engineering (ACPEE)
AUTORES	Hassan Khan; Muhammad Junaid Khan; Amir Qayyum
URL	https://ieeexplore.ieee.org/document/9783828/
TITULO	A step-by-step load forecasting method considering electric vehicle charging stations
PUBLICACIÓN	2024 3rd International Conference on Energy, Power and Electrical Technology (ICEPET)
AUTORES	Jingjing Huang; Chao Zhu; Qiu Liang; Nian Jiang; Shiwei Luo; Qian Wu

URL

<https://ieeexplore.ieee.org/document/10627620/>

Fuente: Elaboración propia.

1.9.4.3. Revisión de la selección

La selección de estudios primarios se hace tras realizar una revisión de los resúmenes y contenido incluido en cada artículo. Para la revisión de estos artículos, los mismos fueron ordenados de acuerdo con la cantidad de citas.

1.9.4.4. Extracción de la selección

1.9.4.4.1. Calculation Method of Electric Vehicle Power Consumption Based on Naive Bayes Classification

La previsión de la carga de vehículos eléctricos es clave para la planificación de estaciones de carga y la gestión del despacho de vehículos eléctricos. Un aspecto fundamental de esta previsión es el cálculo del consumo de energía. Este estudio propone un método basado en la clasificación Naïve Bayes para calcular dicho consumo. Primero, se analizan los desafíos del cálculo del consumo de energía y la aplicación de Naïve Bayes en este contexto.

Luego, se desarrolla un modelo de cálculo basado en este enfoque. Finalmente, utilizando datos de viajes de vehículos eléctricos en Nanjing en junio de 2021, se realizaron simulaciones en Python. Los resultados muestran que el método propuesto es preciso y fácil de implementar.

Aportes del estudio

- **Importancia del tema:** Se resalta que la previsión de la carga de vehículos eléctricos es fundamental para la planificación de estaciones de carga y la gestión del despacho de estos vehículos.
- **Relevancia del consumo de energía:** Se menciona que el cálculo del consumo de energía es un aspecto clave dentro de la previsión de carga.
- **Uso de Naïve Bayes:** Se enfatiza que el estudio propone un método basado en la clasificación Naïve Bayes, un enfoque probabilístico que permite modelar el consumo de energía.

- Metodología del estudio: Se describe brevemente el proceso del estudio, desde el análisis de los problemas hasta la creación del modelo y su validación con datos reales.
- Validación con datos reales: Se destaca que el modelo fue probado con datos de viajes de vehículos eléctricos en Nanjing en junio de 2021, lo que refuerza su aplicabilidad en situaciones reales.
- Resultados clave: Se menciona que el método propuesto es preciso y fácil de implementar, lo que resalta su eficacia y viabilidad para su uso en la industria.

1.9.4.4.2. Forecasting Energy Consumption of Electric Vehicles

Para reducir las emisiones de gases de escape que contribuyen al cambio climático, muchos países buscan reemplazar los motores de combustión interna con vehículos eléctricos (EV). A medida que se produce esta transición, es fundamental comprender el impacto de los EV en la red de distribución eléctrica. Se requiere una planificación rápida para garantizar la flexibilidad de la red, minimizando los costos adicionales. Estudios previos han utilizado encuestas inconsistentes o muestras pequeñas y no representativas de hogares con medidores de EV. Este estudio presenta una estimación escalada de la carga doméstica de vehículos eléctricos en Turquía.

Se emplean métodos de efectos fijos para datos de panel con el fin de estimar el impacto de la adopción de EV en la carga eléctrica. Se encontró que, en promedio, un vehículo eléctrico aumenta la carga del hogar en 3.1 kWh por día, concentrándose principalmente en horas nocturnas, un valor inferior al estimado por los reguladores de la red. Dado que los EV parecen recorrer menos kilómetros de lo esperado con energía eléctrica, su integración en el sistema energético es un desafío, ya que la carga descontrolada podría afectar negativamente el funcionamiento de las redes de distribución.

Aportes del estudio

- La adopción de vehículos eléctricos requiere una planificación eficiente para evitar sobrecargas en la red y minimizar costos adicionales.

- El estudio muestra que el consumo diario de un EV (3.1 kWh) es menor de lo esperado por los reguladores, lo que sugiere que los EV están recorriendo menos kilómetros con energía eléctrica de lo previsto.
- La falta de gestión en la carga de los EV podría afectar negativamente el funcionamiento de las redes de distribución, destacando la necesidad de estrategias para integrar de manera eficiente estos vehículos en el sistema energético.

1.9.4.4.3. Electric Energy and Power Consumption by Light-Duty Plug-In Electric Vehicles

El artículo propone metodologías para estimar el consumo de energía y potencia de los vehículos eléctricos enchufables ligeros (PEVs). Utilizando los patrones de viaje de vehículos ligeros en Estados Unidos, obtenidos de la Encuesta Nacional de Viajes del Hogar de 2009, se estiman el consumo de energía y potencia de los PEVs en dos escenarios de carga no controlada

Aportes del estudio

- Los resultados indican que la adopción de PEVs incrementa la carga eléctrica diaria de los hogares en aproximadamente 3.1 kWh, concentrándose principalmente durante las horas nocturnas. Este aumento es menor al asumido por los reguladores de la red, lo que sugiere que los PEVs podrían estar recorriendo menos kilómetros de lo esperado utilizando energía eléctrica. El estudio destaca la importancia de planificar la flexibilidad de la red para mitigar los posibles efectos adversos de la carga no controlada de PEVs en las redes de distribución eléctrica.

1.9.4.4.4. Neural Network-based Load Forecasting Model for Efficient Charging of Electric Vehicles

En la actualidad, los vehículos eléctricos (EV) representan una solución clave para el transporte sostenible y la reducción de los problemas ambientales. Sin embargo, la carga descontrolada de EV aumenta la presión sobre la red eléctrica, lo que hace necesaria una programación inteligente de carga con costos mínimos.

Este estudio propone el uso de modelos de aprendizaje automático para predecir la carga base diaria y optimizar el proceso de carga.

El enfoque presentado modela la tasa de llegada de EV a las estaciones de carga mediante distribuciones Uniforme y de Poisson. Además, el costo de carga se representa como una función lineal de la carga total en un intervalo determinado. Para la previsión de carga, se utilizan datos históricos de consumo eléctrico y temperatura. Se realizó un análisis experimental con un conjunto de datos de referencia, comparando los métodos de regresión lineal, regresión de árboles ensamblados y redes neuronales artificiales. Los resultados muestran que las redes neuronales artificiales ofrecen la mayor precisión, especialmente en horas pico, lo que destaca su eficacia para la gestión eficiente de la carga de EV.

Aportes del estudio

- Optimización de la carga de EV: Propone una estrategia inteligente para minimizar los costos y reducir la sobrecarga en la red eléctrica.
- Uso de aprendizaje automático: Aplica modelos como regresión lineal, árboles ensamblados y redes neuronales artificiales para mejorar la previsión de carga.
- Mayor precisión con redes neuronales: Los resultados demuestran que las redes neuronales logran la menor tasa de error, especialmente durante las horas pico, lo que las convierte en una herramienta eficaz para la planificación de carga de EV.

1.9.4.4.5. A step-by-step load forecasting method considering electric vehicle charging stations

Con el crecimiento de los vehículos eléctricos, la previsión de carga de estaciones de carga, alimentadores y redes de suministro se ha vuelto fundamental para la planificación de la red de distribución. Este estudio propone un método de previsión de carga paso a paso que considera las estaciones de carga de EV y se divide en cuatro etapas.

Primero, se separa la carga en la zona de la subestación y se agrupan cargas con características similares. Luego, se realiza la previsión de carga para cargas convencionales y postes de carga, abordando métodos específicos para postes con datos históricos limitados. En la tercera etapa, se utiliza la previsión de

la subestación para estimar la carga de los alimentadores de 10kV y unidades/redes de suministro. Finalmente, se presentan cálculos de casos reales para validar la efectividad del modelo propuesto.

Aportes del estudio

- Previsión de carga detallada: Aborda la carga de estaciones de carga, alimentadores y redes de suministro.
- Metodología escalonada: Divide la previsión en cuatro pasos clave para mayor precisión.
- Solución para datos limitados: Propone métodos para estimar la carga de postes de carga con pocos datos históricos.
- Validación con casos reales: Demuestra la efectividad del modelo con cálculos específicos.
- Optimización del sistema energético: Mejora la integración de EV y la planificación de la red eléctrica.

1.9.5. Ejecución de la fuente Google Scholar

Siguiendo las recomendaciones provistas por (Blanco, et al., 2007), se realiza la búsqueda de estudios iniciales basados en los siguientes parámetros:

- Electric Vehicle
- Forecasting
- Consumption

Figura 3. Filtro aplicado a Google Scholar.

×
Advanced search
Q

Find articles

with **all** of the words

with the **exact phrase**

with **at least one** of the words

without the words

where my words occur anywhere in the article
 in the title of the article

Return articles **authored by**
e.g., "PJ Hayes" or McCarthy

Return articles **published in**
e.g., J Biol Chem or Nature

Return articles **dated between** —
e.g., 1996

Fuente: Google Scholar

Tras efectuarse la búsqueda se encontraron más de 20.000 publicaciones, de las cuales fueron seleccionados 2 tras aplicar el método de exclusión propuesto. A continuación, se presenta el detalle de los mismos

Tabla 3. Estudios de Google Académico

GOOGLE SCHOLAR

TITULO	Review on Scheduling, Clustering, and Forecasting Strategies for Controlling Electric Vehicle Charging: Challenges and Recommendations
PUBLICACIÓN	IEEE Access® 2017, volume 7
AUTORES	Ali Saadon Al-Ogaili; Tengku Juhana Tengku Hashim; Nur Azzammudin Rahmat; Agileswari K. Ramasamy; Marayati Binti Marsadek; Mohammad Faisal
URL	https://dl.acm.org/doi/10.5555/3320516.3320667

TITULO	Forecasting electric energy consumption using neural networks
PUBLICACIÓN	IEEE Access® 2017, volume 7
AUTORES	SSAK Javeed Nizami, Ahmed Z Al-Garni
URL	https://www.sciencedirect.com/science/article/abs/pii/S0301421595001166?via=ihub

Fuente: Elaboración propia.

1.9.5.1. Revisión de la selección

La selección de estudios primarios se hace tras realizar una revisión de los abstract y contenido incluido en cada artículo. Para la revisión de estos artículos, los mismos fueron ordenados de acuerdo con la cantidad de citas.

1.9.5.2. Extracción de la información

1.9.5.2.1. Review on Scheduling, Clustering, and Forecasting Strategies for Controlling Electric Vehicle Charging: Challenges and Recommendations

El artículo aborda la gestión eficiente de la carga de vehículos eléctricos ante su creciente adopción a nivel mundial. Se destaca que la penetración masiva de VE plantea nuevos retos en las redes de energía, ya que la carga no controlada de estos vehículos puede ocasionar caídas de voltaje, pérdidas de potencia, desequilibrios en la red y reducir la vida útil de los transformadores, entre otros problemas

Aportes del estudio

- Impacto de la carga de VE en la red y necesidad de estrategias de control: La integración masiva de vehículos eléctricos sin control en su recarga puede generar graves problemas en la red eléctrica, como picos de carga elevados, incrementos en el consumo y degradación de la calidad de energía

- Estudios previos han mostrado que la carga no gestionada de VEs puede sobrepasar la capacidad de transformadores y causar caídas de tensión fuera de rangos seguros
- Este marco involucra comunicación bidireccional constante: el operador predice la demanda base y recibe las señales de solicitud de carga de los VEs, luego envía instrucciones optimizadas a los puntos de carga para que ejecuten el plan
- La relevancia de este marco radica en que integra las distintas estrategias de control dentro de un proceso unificado, proporcionando una arquitectura de gestión de energía para la recarga inteligente de VEs en el contexto de las redes eléctricas inteligentes (smart grids). En la práctica, este esquema guía a operadores de red y desarrolladores a estructurar sistemas de control de VE eficientes que consideren desde la obtención de datos hasta la acción de carga final.
- Estrategias de programación de la carga de VE (Scheduling): La programación de la carga busca planificar cuándo y cómo cargan los vehículos para mantener el equilibrio entre la oferta y la demanda eléctrica, mejorando la estabilidad del sistema
- Una buena coordinación en los horarios de carga puede incluso habilitar servicios de vehículo a red (V2G), devolviendo energía a la red cuando sea beneficioso
- En el artículo se distinguen dos enfoques principales de programación, centralizado y descentralizado. En el enfoque centralizado, un agente agregador o controlador central toma decisiones por todos los VEs; recopila datos de los vehículos y del estado de la red, y resuelve un problema de optimización global para determinar el plan de carga óptimo para cada VE
- Este controlador utiliza información como los horarios de carga históricos, capacidades de la red y niveles de batería para decidir la mejor estrategia, con el fin de minimizar costos energéticos y reducir picos de demanda, manteniendo a la vez las necesidades de los usuarios
- Por ejemplo, un estudio citado implementó un controlador central para un estacionamiento de VEs que consideraba el tamaño de la batería, el estado de carga (SOC) y las condiciones de la red, logrando minimizar las puntas de carga y a la vez satisfacer las expectativas de los conductores.

1.9.5.2.2. Forecasting electric energy consumption using neural networks

Presenta un modelo de red neuronal artificial para pronosticar el consumo de energía eléctrica. El objetivo central es relacionar el consumo eléctrico (en la Provincia Oriental de Arabia Saudita) con variables independientes como el clima (temperatura, humedad), la radiación solar global y la población. Utilizan una red neuronal de alimentación directa (feedforward) de dos capas (una capa oculta más la capa de salida) entrenada con datos históricos de siete años. Los autores evalúan la adecuación teórica del modelo mediante técnicas estadísticas: una inspección visual de los resultados y una prueba de chi-cuadrado para comprobar qué tan bien la red captura el comportamiento del consumo real

Aportes del estudio

- Eficacia de las redes neuronales para modelado energético: El estudio confirma que las redes neuronales artificiales pueden modelar la relación entre la demanda de electricidad y factores determinantes (clima y población) sin necesidad de suposiciones lineales. Una sola capa oculta en la red fue suficiente para captar las dependencias complejas entre las variables independientes y el consumo eléctrico, lo cual demuestra teóricamente la capacidad de las RNA para representar funciones no lineales en sistemas energéticos.
- Entrenamiento y validación del modelo: Se entrenó la RNA con datos de 7 años, incluyendo temperatura, humedad, radiación solar y población como entradas, y consumo eléctrico como salida
- La adecuación del modelo se comprobó teóricamente mediante una prueba de bondad de ajuste chi-cuadrado y evaluación visual de las predicciones vs. datos reales
- Este análisis mostró que la red aprende correctamente el patrón histórico de consumo, ya que no se detectaron desviaciones significativas entre las predicciones de la RNA y los valores reales durante el periodo de entrenamiento (a un nivel de confianza aceptable según chi-cuadrado).
- Capacidad predictiva y generalización: Al probar la red neuronal con datos futuros no utilizados en el entrenamiento, se observó que mantenía una alta precisión predictiva

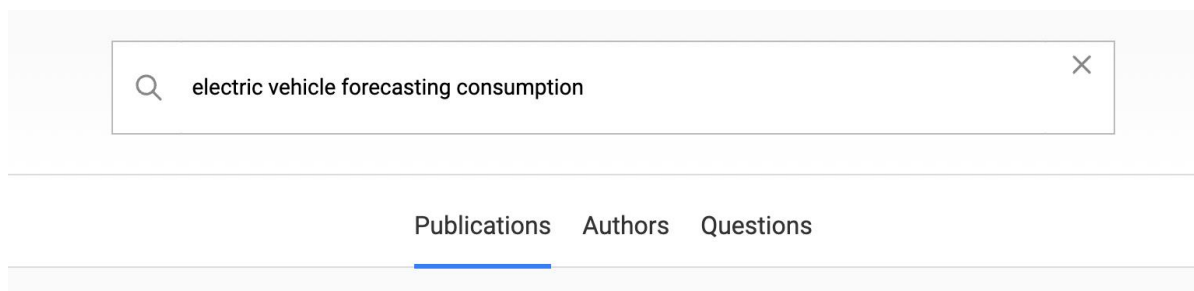
- Comparación teórica con modelos tradicionales: Sin entrar en detalles de otros métodos, el estudio incluye un hallazgo importante: la red neuronal superó a un modelo de regresión lineal en exactitud de pronóstico
- Contribución teórica general: En conjunto, los resultados respaldan la viabilidad de las redes neuronales como método de pronóstico de la demanda eléctrica. La investigación refuerza así, en el plano teórico, el rol de las RNA como herramientas robustas para pronosticar consumos eléctricos a partir de datos históricos.

1.9.6. Ejecución de la fuente Research Gate

Siguiendo las recomendaciones provistas por (Blanco, et al., 2007), se realiza la búsqueda de estudios iniciales basados en los siguientes parámetros:

- Electric Vehicle
- Forecasting
- Consumption

Figura 3. Filtro aplicado en el sitio Research Gate



Fuente: elaboración propia.

Tras efectuarse la búsqueda se encontraron más de 20.000 publicaciones, de las cuales fueron seleccionados 2 tras aplicar el método de exclusión propuesto. A continuación, se presenta el detalle de los mismos.

Tabla 4. Estudios de Research Gate

RESEARCH GATE

TITULO	
	Towards Efficient Battery Electric Bus Operations: A Novel Energy Forecasting Framework

PUBLICACIÓN	World Electric Vehicle Journal
AUTORES	Würtz, Samuel; Bogenberger, Klaus; Göhner, Ulrich; Rupp, Andreas
URL	http://dx.doi.org/10.3390/wevj15010027
TÍTULO	Power consumption prediction for electric vehicle charging stations and forecasting income
PUBLICACIÓN	Scientific Reports. 14
AUTORES	Akshay, K. and Grace, Hannah and G, KANIMOZHI and Samikannu, Ravi
URL	http://dx.doi.org/10.1038/s41598-024-56507-2

Fuente: Elaboración propia.

1.9.6.1. Revisión de la selección

La selección de estudios primarios se hace tras realizar una revisión de los abstract y contenido incluido en cada artículo. Para la revisión de estos artículos, los mismos fueron ordenados de acuerdo con la cantidad de citas.

1.9.6.2. Extracción de la información

1.9.6.2.1. Towards Efficient Battery Electric Bus Operations: A Novel Energy Forecasting Framework

Propone un nuevo enfoque para predecir el consumo energético de autobuses eléctricos de batería (BEBs) mediante la combinación de modelos físicos y basados en datos. La metodología se centra en integrar dos componentes principales: un modelo de energía de propulsión y otro de energía auxiliar, junto con un innovador “generador de entorno” (environment generator, EG). Este EG se encarga de estimar variables operativas críticas (como condiciones climáticas,

carga de pasajeros y patrones de tráfico) que impactan significativamente el consumo de energía, permitiendo así ajustar las predicciones a escenarios futuros realistas.

El estudio se valida con datos reales obtenidos de 16 autobuses eléctricos en Göttingen, Alemania, a lo largo de un año, abarcando aproximadamente 45,000 trayectos.

Los autores exploran distintos niveles de complejidad en los modelos – desde aproximaciones constantes hasta modelos físicos y redes neuronales para la predicción de la energía auxiliar – y demuestran que, al incorporar variables como la elevación, la temperatura ambiente y la carga de pasajeros, se puede reducir significativamente el error en las predicciones energéticas. Estos hallazgos ofrecen importantes implicaciones para la planificación operativa, el dimensionamiento de baterías y la optimización de rutas en sistemas de transporte público eléctrico.

Aspectos relevantes

- Combina modelos de propulsión y energía auxiliar con un generador de entorno que simula condiciones ambientales y operativas (clima, tráfico, carga de pasajeros) para predecir el consumo energético.
- Se basa en un amplio conjunto de datos (45,000 trayectos) recogidos de 16 autobuses eléctricos en Göttingen durante 13 meses, lo que permite una evaluación detallada de la influencia de factores como elevación, temperatura y tráfico.
- Combina modelos de propulsión y energía auxiliar con un generador de entorno que simula condiciones ambientales y operativas (clima, tráfico, carga de pasajeros) para predecir el consumo energético.
- Los resultados destacan la importancia de predecir con precisión la demanda energética para optimizar la planificación de rutas, los horarios de carga y la gestión de la flota, contribuyendo a la eficiencia operativa y al aprovechamiento óptimo de la infraestructura de carga.
- Ofrece un marco modular que permite a los operadores de transporte público adoptar soluciones de predicción energética adaptadas a sus datos y condiciones locales, facilitando la transición hacia sistemas de transporte más sostenibles.

1.9.6.2.2. Power consumption prediction for electric vehicle charging stations and forecasting income

El estudio propone modelos de series temporales para predecir el consumo energético y los ingresos de estaciones de carga de vehículos eléctricos (EV). Utilizando datos de Colorado (EE.UU.) y Kerala (India), se comparan los modelos ARMA, ARIMA y SARIMA, siendo este último el más preciso. La investigación revela que las estaciones de carga DC y los vehículos de cuatro ruedas consumen más energía que sus contrapartes. Además, se analizan patrones de uso, ingresos por planes de suscripción y tendencias de carga por tipo de vehículo y estación. Los hallazgos permiten optimizar la ubicación de estaciones, planificar infraestructura eléctrica y diseñar estrategias de precios más eficientes. El modelo SARIMA se posiciona como una herramienta clave para anticipar demandas energéticas y mejorar la rentabilidad operativa de las redes de carga de EV.

Aportes del estudio

- Se determinó que las estaciones de carga DC presentan un mayor consumo energético en comparación con las estaciones AC, especialmente en vehículos de cuatro ruedas, que consumen más electricidad que los de dos y tres ruedas.
- El análisis temporal evidenció patrones de uso específicos, con mayor consumo los días viernes y en horarios pico (10 a.m. y 3 p.m.), información útil para la gestión de demanda y planificación de infraestructura.
- Se aplicaron modelos de series temporales a datos de suscripciones, permitiendo predecir ingresos económicos y orientar estrategias de precios más eficientes.
- La segmentación del consumo por tipo de estación y tipo de vehículo permitió una predicción más precisa y una mejor comprensión de la carga por segmento.
- Los resultados ofrecen recomendaciones prácticas para la optimización de la infraestructura de carga, apoyando la toma de decisiones de empresas eléctricas, gobiernos y operadores de estaciones de carga.

- El uso de datos reales de dos regiones distintas (Colorado, EE.UU. y Kerala, India) valida la aplicabilidad del modelo en contextos geográficos diversos.

1.10. Síntesis del estado de la cuestión y justificación del modelo propuesto

El análisis exhaustivo de la literatura académica especializada permitió identificar avances importantes en torno al consumo energético de los vehículos eléctricos, las metodologías de predicción de demanda y la eficiencia de carga. Sin embargo, también reveló una serie de vacíos teóricos y prácticos que justifican plenamente la pertinencia del modelo desarrollado en esta investigación.

Uno de los principales vacíos detectados es la escasa atención al impacto económico directo en la factura eléctrica del usuario residencial, especialmente en contextos latinoamericanos y, con mayor razón, en el caso costarricense. Si bien se ha trabajado en predicciones de consumo general, la mayoría de los estudios se centran en contextos urbanos densos o flotas comerciales, lo que deja sin abordar adecuadamente el análisis personalizado del uso doméstico de los vehículos eléctricos y su relación con esquemas tarifarios reales. Este vacío limita la capacidad de los hogares para anticipar y gestionar de manera informada su consumo energético al adoptar un VE.

Otro aspecto poco explorado es la adaptación contextual de los modelos predictivos existentes a entornos como el costarricense, que posee una matriz energética con alta penetración de fuentes renovables, tarifas horarias particulares y una creciente pero aún incipiente red de infraestructura de carga.

A partir de estos vacíos, el modelo desarrollado en este proyecto se propone como una respuesta integral que combina: análisis de patrones de carga y características técnicas de los VE, simulaciones tarifarias contextualizadas, y uso de algoritmos de aprendizaje automático validados empíricamente. Esta solución no solo aporta al debate académico sobre el consumo energético vinculado a la movilidad eléctrica, sino que también ofrece una herramienta aplicable para facilitar decisiones más conscientes y sostenibles entre los consumidores costarricenses.

CAPÍTULO 2. Marco Conceptual

Se genera la siguiente nube de palabras con el objetivo de identificar los conceptos más relevantes, que fueron extraídos a partir de su mención dentro de los artículos consultados.

2.1. Figura de conceptos sobre el contenido

Figura 4. Nube de conceptos



Fuente: elaboración propia

2.2. Mapa conceptual jerárquico

Figura 5. Mapa conceptual jerárquico.



Fuente: *Elaboración propia*

En la siguiente sección se presentan los conceptos más mencionados en la documentación consultada y a la vez que cuentan con mayor impacto en el tema de

este proyecto. Los conceptos se encuentran ordenados desde ámbitos generales hasta ámbitos más específicos.

2.3. Conceptos

Vehículos eléctricos

Los EV son una transformación importante en cómo se movilizan las personas en la actualidad. A diferencia de los coches de siempre, que usan gasolina o diésel, los VE usan uno o varios motores eléctricos con baterías que se recargan. Esta tecnología ha cambiado mucho en los últimos veinte años, gracias a las baterías de litio, los motores eléctricos mejorados y la preocupación por el cambio climático (IEA, 2023). Por eso, los VE ya no son solo una prueba, sino una solución buena, que puede crecer y que es necesaria para reducir la contaminación en todo el mundo.

Además de cómo se mueven, los VE cambian cómo se conceptualiza el transporte y la energía. Son silenciosos, gastan menos energía que los motores de gasolina y contaminan menos, lo que los hace muy útiles para las políticas de sostenibilidad. Pero, si mucha gente los usa, se presentan problemas, como manejar la energía que necesitan las casas y dónde recargarlos. Según un informe del *International Council on Clean Transportation* (ICCT, 2021), para que haya VE en muchas casas, hay que cambiar cómo se usa la energía y cómo se planifican las ciudades. En Latinoamérica, y sobre todo en Costa Rica, cada vez hay más coches eléctricos gracias a impuestos más bajos, leyes de transporte limpio y una red eléctrica que usa mucha energía renovable. Pero, usar más coches eléctricos también hace preguntas sobre cómo afectará a la red eléctrica de las casas, especialmente en cuánta energía puede dar, cómo se cargan y cuánto costará la electricidad. Según Maharaj (2024), los países que están empezando a usar coches eléctricos deben pensar en esto para evitar problemas en la red y usar bien la oportunidad de moverse sin contaminar.

En esta investigación, los coches eléctricos son lo más importante que vamos a estudiar. Esto se observa no solo como tecnología, sino como parte de cómo se usa la energía en las casas de Costa Rica. Su uso cambia cómo se gasta energía en casa, añadiendo un gasto nuevo que puede cambiar la factura de la luz, los momentos de más uso y cómo de bien funciona la red. Por eso, es clave entender

cómo funcionan los VE para saber cómo afectarán y planear cómo integrarlos bien en la red eléctrica de las casas.

Factura de luz

La factura de luz es un análisis de cuánta energía gasta una casa. En ella se ve reflejado no solo cuántos kilovatios hora se han usado, sino también las tarifas que se aplican, los costes fijos, las multas por sobrepasarse con el consumo y, en algunos sitios, los beneficios por usar la energía de forma eficiente o por generarla uno mismo. Tal y como señala el CNFL (2024), la factura de la luz nos dice cuánto gastamos, cómo lo gastamos y cuánto estamos pagando por ello, algo fundamental para cambiar a un modelo energético mejor.

La forma en que está diseñada la factura y lo que incluye influye directamente en cómo se comportan los consumidores. De esta manera, si se incluyen tarifas que varían según la hora del día, costes diferentes según cuánto se consume o avisos de precios relacionados con el consumo total de la red, se puede animar a las personas a ser más consciente y eficiente. En países donde se han probado las tarifas dinámicas, se ha notado que baja el consumo en las horas de más demanda, ya que los usuarios cambian sus costumbres para aprovechar las horas en que la energía es más barata (Reguant et al., 2025).

En el contexto de los coches eléctricos, la factura de la luz cobra otra importancia. El incluir un coche eléctrico en casa puede aumentar el consumo mensual, dependiendo de la frecuencia de carga, del tipo de tarifa que se tenga y de lo eficiente que sea el coche. Si no se planifica bien y no se entienden estas cosas, los beneficios para el medio ambiente de usar coches eléctricos podrían verse eclipsados por un aumento importante en lo que se paga de luz.

En este estudio, la factura de luz es como la pieza clave que queremos entender, ya que sus cambios nos permiten ver cómo afecta económicamente cargar coches eléctricos en las casas de Costa Rica. Usando modelos para predecir, se desea ver cómo cambia el precio mensual según diferentes formas de cargar el coche, tipos de tarifa y costumbres de consumo.

Patrones de gasto energético

Los patrones de gasto energético muestran cómo las personas suelen usar la energía con el paso del tiempo. Según la Agencia Internacional de Energías

Renovables (Sadeghian et al., 2023), analizar los hábitos de consumo ayuda a ajustar la oferta a lo que realmente se necesita, haciendo que los sistemas eléctricos funcionen mejor y ayudando a que tanto usuarios como proveedores tomen decisiones más informadas sobre la energía.

En el ámbito del hogar, los patrones de gasto de energía no son fijos. Cambian según las características sociales y demográficas, la cantidad de personas que viven ahí y cómo están relacionadas, qué tan bien funcionan los aparatos eléctricos, el clima y, últimamente, el uso de nuevas tecnologías como los carros eléctricos. Una investigación hecha por Christiansen et al. (2017) mostró que las casas con carros eléctricos tenían momentos de mayor gasto de energía en la noche, lo cual presenta problemas para administrar la red eléctrica y decidir los precios.

Además, saber cómo son estas costumbres ayuda a crear planes para usar la energía de manera más eficiente y manejar la demanda. Por ejemplo, al encontrar las horas en que se usa menos energía en la casa, se puede programar la carga del carro eléctrico en momentos que no sean al mismo tiempo que las demás actividades que usan energía, disminuyendo así la presión en la red y mejorando los costos. Según el Instituto de Investigación Tecnológica (IIT, 2021), las costumbres de gasto bien identificadas permiten usar sistemas de control inteligente que reparten la carga de manera eficiente, sobre todo donde se busca que se recargue en la noche o se usen energías renovables”.

En este proyecto, las costumbres de gasto de energía son importantes para el análisis que predice el futuro, porque se desea hacer un modelo de cómo el agregar carros eléctricos afecta la forma en que los hogares costarricenses los cargan. Usando datos reales o simulados, se crean perfiles de gasto que ayuden a ver las horas y situaciones más comunes en que se recargan los carros. Esta información sirve para mejorar los modelos de predicción y permite dar consejos para reducir el impacto económico y técnico de usar carros eléctricos.

Predicción de la demanda

La predicción de la demanda de energía es crucial para equilibrar y hacer sostenible nuestro sistema eléctrico. Implica estimar con tiempo cuánta energía necesitaremos en el futuro cercano, analizando datos pasados, el clima, cómo se consume y las novedades tecnológicas. Como apuntan Bayomi et al. (2023), si se

predice bien la demanda, los operadores pueden planificar la producción, manejar el almacenamiento y crear estrategias para que el sistema eléctrico se mantenga estable.

En los últimos años, las nuevas técnicas de modelado han cambiado cómo se predice la demanda. A diferencia de los métodos usuales, los modelos inteligentes ven conexiones ocultas entre muchas variables, se adaptan a cada situación y hacen estimaciones más sólidas cuando hay mucha incertidumbre. Por ejemplo, el algoritmo de Naïve Bayes o las redes neuronales han demostrado ser buenos para prever patrones de consumo complejos en ciudades que cambian constantemente (Shen et al., 2022).

La recarga de estos vehículos no solo aumenta el consumo total, sino que también podría cambiar las horas de mayor demanda, creando nuevos picos que antes no teníamos. Según un informe de la Agencia Internacional de la Energía (IEA, 2023), la recarga en casa de los coches eléctricos es un reto para la gestión de la demanda, ya que puede concentrarse en ciertas horas y requerir que la red responda de forma flexible. Por eso, los modelos predictivos deben incluir datos específicos del comportamiento del usuario, precios y características técnicas de los vehículos eléctricos para dar predicciones útiles y prácticas.

En esta investigación, anticipar la demanda es una herramienta clave. Se usan modelos de aprendizaje automático para estimar cuánto más se consume electricidad cuando una familia en Costa Rica empieza a usar un coche eléctrico. Con datos simulados y reales, proyectaremos diferentes escenarios de recarga, teniendo en cuenta precios de la electricidad, hábitos de uso y tipo de cargador.

Recarga eléctrica

La recarga eléctrica es cuando la energía pasa de la red a la batería de un coche eléctrico, siendo algo fundamental en el mundo de la electromovilidad. Según un informe de la Agencia Internacional de la Energía (IEA, 2022), la infraestructura de recarga es esencial para que la gente use más coches eléctricos, y su facilidad de acceso, rapidez y compatibilidad son importantes para la experiencia del usuario. Hay diferentes formas de cargar un coche, cada una pensada para ciertas necesidades y situaciones. La carga rápida, que usa corriente continua, puede llenar el 80% de la batería en menos de una hora y suele encontrarse en lugares públicos o carreteras (Barahona Carmona et al., 2025). Por eso, no se puede tratar todas las cargas de la misma manera.

Aparte de lo técnico, la carga también influye en cómo se actúa y en cómo se organiza la energía. Se decide así cuándo y cómo cargar el coche según lo que cuesta la electricidad, cuánto se puede conducir con una carga, dónde hay enchufes y las costumbres en casa. Como mencionan Ziras et al. (2024), ser flexibles con los horarios de carga ayuda a usar mejor la red, evitar que todos gasten mucha energía a la vez y bajar los gastos para todos.

En este estudio, la carga es muy importante porque conecta el coche con el gasto de energía en casa. Esto ayuda a saber cómo afecta la factura de la luz, cuánta energía extra se necesita por los coches eléctricos y si es buena idea usarlos en Costa Rica. También se analiza cómo los diferentes tipos de carga cambian la eficiencia y la estabilidad de la red.

Carga rápida vs carga lenta

La diferencia entre la recarga rápida y la lenta en coches eléctricos abarca más que el mero tiempo, pues incluye aspectos técnicos, económicos y de energía. La carga lenta, casi siempre en casa, usa corriente alterna con potencias de 3.7 a 7.4 kW, y puede tomar de seis a diez horas para una recarga total, según la batería (IEA, 2023). En cambio, la carga rápida se hace en estaciones públicas con corriente continua sobre 50 kW, llegando al 80% en menos de cuarenta minutos (Barahona Carmona, 2025).

Visto desde la red eléctrica, la carga rápida es más retadora. Su intensidad en poco tiempo causa picos de demanda difíciles de controlar, sobre todo si varios usuarios cargan a la vez en un área. La carga lenta facilita una integración más suave del consumo, evitando sobrecargas y usando los ratos de menor demanda general. Como mencionan Mojlish et al. (2025), unir bien los tipos de carga y las tarifas es clave para la energía y evitar problemas en la red.

Además, elegir entre carga rápida y lenta depende del usuario y de qué tan fácil sea acceder a ellas. Quienes pueden cargar en casa prefieren lo lento por comodidad y precio, pero quienes usan estaciones públicas valoran lo veloz aunque cueste más en energía y dinero. Según la *International Council on Clean Transportation* (ICCT, 2022), al instalar la infraestructura se debe pensar en los distintos usos para que haya buena cobertura.

Este estudio usa el tipo de carga como algo importante, porque lo que elija el usuario afecta directamente su factura de luz y cuánta energía usa en casa. Se

hicieron modelos comparando cómo afectan la carga veloz y la pausada al consumo mensual, el precio y la red. Estos datos ayudan a ver si las estrategias de recarga son posibles en Costa Rica, dando pruebas para orientar sobre cómo cargar y fijar tarifas.

Tarifas de luz y precios dinámicos

Las tarifas de luz se refieren a cómo pagamos por la energía que se gasta, y son una de las mejores formas de animar a las personas a consumir de cierta manera. Pueden ser de precio fijo, por escalones o cambiar según el momento, y su forma decide bastante cómo, cuándo y cuánta electricidad se usa. En muchos lugares, sobre todo donde hay mucha energía renovable y carros eléctricos, están empezando a usar sistemas más flexibles, como los precios dinámicos, que cambian según cuánta energía se necesita o hay disponible (Reguant et al., 2025). Los precios dinámicos pueden ayudar a bajar la demanda en las horas de más consumo, porque animan a usar la energía cuando no hay tanta demanda. Según un estudio de Faruqi y Hledik (2021), si se entiende bien cómo funcionan estos precios y se tienen herramientas para controlarlos automáticamente, se puede reducir el consumo en las horas de más demanda entre un 10% y un 25%. En esta investigación, las tarifas de luz y los precios dinámicos son importantes porque cambian directamente cómo se usa la energía. Se procedió a simular diferentes situaciones con distintos tipos de tarifas para ver cómo cambia el costo total de cargar un carro eléctrico según la hora del día.

Integración de vehículos eléctricos en la red

Este proceso implica conectar un creciente número de VE a la infraestructura eléctrica existente sin comprometer la estabilidad, seguridad ni eficiencia del sistema. A medida que la electrificación del transporte se acelera, los sistemas eléctricos deben adaptarse para absorber esta nueva demanda sin generar sobrecargas ni desequilibrios. Según la International Energy Agency (IEA, 2022), la integración efectiva de VE en la red requiere una planificación coordinada entre operadores del sistema, fabricantes de vehículos, distribuidores de energía y gobiernos.

Uno de los principales desafíos de esta integración radica en la gestión de la demanda agregada. Cuando muchos usuarios cargan sus vehículos en horarios similares, se producen picos de consumo que pueden tensionar las redes de

distribución locales. Este fenómeno, conocido como efecto de sincronización de carga, puede ser mitigado mediante tecnologías como la carga inteligente, la implementación de tarifas horarias o la utilización de almacenamiento distribuido. Otro elemento clave en la integración es la localización geográfica y la concentración de VE. Las zonas residenciales densamente pobladas pueden enfrentar problemas de capacidad transformadora si muchos hogares incorporan VE de forma simultánea. Como plantea Barahona Carmona et al. (2025), la integración eficiente de vehículos eléctricos en la red requiere una combinación de políticas públicas, inversión tecnológica y participación activa de los usuarios en la gestión de su consumo energético.

En esta investigación, la integración de vehículos eléctricos en la red es el contexto estructural dentro del cual se desarrolla el análisis de consumo energético doméstico. Al modelar el comportamiento de carga en hogares costarricenses, se evalúa cómo la presencia de VE altera la dinámica tradicional de demanda eléctrica, y qué implicaciones tiene esto para la red local. A partir de estos hallazgos, se propusieron recomendaciones orientadas a facilitar una integración gradual, eficiente y sostenible, que permita anticiparse a los efectos de una mayor electrificación del parque vehicular residencial.

Infraestructura eléctrica

La infraestructura eléctrica es un entramado que facilita la transferencia de energía desde las fuentes productoras hasta el usuario final. Consta de cuatro pilares básicos: producción, transporte, reparto y uso. Cada fase precisa una coordinación continua para asegurar que la energía fluya de manera constante, segura y con estabilidad. Las redes actuales deben encarar retos que se acrecientan por la dispersión en la producción y el incremento del consumo ligado a avances como los coches eléctricos.

En la actualidad, la red eléctrica debe ser flexible, bidireccional y apta para asumir cargas nuevas y variables. Esto implica un cambio radical en su planteamiento, funcionamiento y control. Según Jenkins et al. (2021), las redes eléctricas del siglo XXI deben dejar de ser estructuras rígidas y reactivas, para convertirse en sistemas dinámicos, capaces de adaptarse en tiempo real a las fluctuaciones en la oferta y la demanda.

Uno de los problemas más apremiantes para las redes eléctricas es el alza del consumo en hogares debido a la adopción de coches eléctricos. A diferencia de otros aparatos, los VE requieren mucha energía al recargarse, lo cual puede alterar el patrón de consumo en zonas residenciales. Si este nuevo consumo no se prevé bien, puede causar sobrecargas en transformadores, caídas de tensión o cortes de luz. Por ello, es crucial aplicar planes basados en modelos predictivos, gestión de la carga y tecnologías inteligentes.

Este estudio forma parte del análisis del efecto que los vehículos eléctricos livianos tienen en la red eléctrica residencial costarricense. Al modelar varios casos de carga en los hogares, se valorará cómo la red actual responde al nuevo consumo, y qué factores deben tenerse en cuenta para su adaptación. Además, los resultados ayudarán a prever zonas críticas donde podría ser preciso reforzar la infraestructura o aplicar políticas de gestión inteligente de la carga, ayudando así a una incorporación responsable y sostenible de la electromovilidad.

Flexibilidad en la red

Se entiende por adaptabilidad de la red eléctrica esa habilidad que tiene el sistema para ajustarse a los cambios que se producen tanto en la cantidad de energía que se ofrece como en la que se necesita, sin que por ello se vea comprometida su firmeza, eficacia y fiabilidad. Según el Consejo Mundial de la Energía (2022), esa capacidad de adaptación de las redes eléctricas será clave para que la transición energética se lleve a cabo de manera segura, eficiente y sin dañar el planeta.

Hay muchas maneras de hacer que la red sea más adaptable. Una de las más importantes es la respuesta de la demanda, que anima a los usuarios a cambiar sus hábitos de consumo según lo que pida el sistema o según los precios. También se puede lograr almacenando energía, usando tecnologías de generación repartida, automatizando la red e introduciendo sistemas predictivos. Esa adaptabilidad puede ser técnica, operativa o de mercado, y si se aplica bien, se pueden evitar grandes inversiones en infraestructuras caras y se puede aprovechar mejor la energía renovable (Zebra et al., 2021).

La cada vez mayor presencia de coches eléctricos plantea nuevos retos y opciones para esa adaptabilidad. Aunque si todas las personas los cargan a la vez se pueden generar atascos y desajustes, una buena organización puede hacer que los coches eléctricos ayuden a estabilizar la red. Como dice la Agencia Internacional

de la Energía (2023), integrar la flexibilidad de los vehículos en el sistema eléctrico es una de las mejores estrategias para afrontar los desafíos de la electrificación. Este proyecto tiene en cuenta la adaptabilidad de la red como un aspecto a valorar para ver cómo influyen los vehículos eléctricos pequeños en el consumo de energía de los hogares de Costa Rica. Mediante simulaciones de cómo se suelen cargar estos vehículos, se estudió si la red eléctrica de las casas puede adaptarse a diferentes formas de recarga, o si habrá que poner en marcha sistemas para gestionar la demanda. Los resultados sirvieron para encontrar opciones de flexibilización a corto y medio plazo, con consejos sobre tecnologías de apoyo, mejores horarios para cargar y medidas de planificación para un uso más equilibrado de la red.

Redes inteligentes

Las redes inteligentes buscan administrar la electricidad de manera más eficaz, fiable y adaptable, facilitando la comunicación en ambos sentidos entre quienes producen y consumen energía. El Instituto de Ingeniería Eléctrica y Electrónica (2022) indica que estas redes combinan tecnologías de la información y comunicación para supervisar, examinar y dirigir el flujo energético al instante, mejorando así el desempeño del sistema en cada aspecto.

Una característica central de las redes inteligentes es su habilidad para manejar la oferta y la demanda de manera flexible, ajustándose a las fluctuaciones en el consumo y a la irregularidad de las energías renovables. Estas redes hacen posible el uso de tarifas dinámicas, la respuesta a la demanda, el mantenimiento predictivo y la colaboración con sistemas de almacenamiento disperso. De acuerdo con Fang et al. (2022), las redes inteligentes crean un entorno energético más robusto, distribuido y ecológico, donde las viviendas con paneles solares, baterías o autos eléctricos pueden actuar como prosumidores.

En el ámbito de la electromovilidad, las redes inteligentes juegan un papel crucial en la integración segura y eficaz de los vehículos eléctricos. Facilitan la identificación de patrones de carga, la optimización del uso de la infraestructura eléctrica existente y la activación de sistemas automatizados para prevenir sobrecargas en los transformadores. Además, mediante los contadores inteligentes, los usuarios pueden observar su consumo en tiempo real y decidir cuándo y cómo cargar sus vehículos. Como destaca la Comisión Europea (2023),

las redes inteligentes son vitales para gestionar el impacto de la electrificación del transporte, permitiendo una coordinación flexible entre usuarios, operadores e infraestructura energética.

En este estudio, este concepto sirve como el cimiento tecnológico que posibilita el funcionamiento eficiente de las viviendas que utilizan vehículos eléctricos ligeros. Partiendo de los resultados de la simulación y el modelado del consumo, se propuso la implementación de soluciones de supervisión y control inteligente como un medio para atenuar los efectos adversos del incremento en la demanda eléctrica. Se sugiere, igualmente, el uso de plataformas digitales de gestión energética residencial como un enfoque accesible para los usuarios costarricenses, incentivando hábitos de consumo informados, sostenibles y acordes con las capacidades técnicas del sistema.

Almacenamiento de energía

Guardar energía es crucial para que el sistema eléctrico sea más adaptable, ecológico y seguro. Esto se refiere al poder acumular energía cuando hay poca necesidad o mucha producción, para usarla cuando haga falta. Hay diversas maneras de hacerlo, desde baterías hasta sistemas térmicos, mecánicos o químicos. Las baterías de litio son las más populares por su buen rendimiento, cuánta energía guardan y lo útiles que son, tanto en aparatos que llevamos con nosotros como en instalaciones fijas. Según un estudio del Foro Económico Mundial (2022), guardar energía es clave para equilibrar los sistemas eléctricos que no dependen de una sola fuente y que no contaminan.

En las redes eléctricas actuales, el almacenamiento no solo ayuda a que la oferta y la demanda estén más equilibradas, sino que también hace que el suministro sea más fiable, disminuye las pérdidas por saturación y facilita la incorporación de energías renovables que no siempre están disponibles, como la solar y la eólica. Como indican Díaz-González et al. (2021), los sistemas de almacenamiento repartidos no solo ayudan al consumidor final, sino también a quien maneja el sistema, dándole más opciones para operar.

En este estudio, se considera el almacenamiento de energía como algo importante que influye en cómo las familias costarricenses podrían manejar el gasto eléctrico al cargar sus coches eléctricos.

Movilidad Sostenible

La concepción de movilidad sostenible ha evolucionado notablemente en años recientes, al reconocer que los sistemas de transporte convencionales no resultan viables ni para el planeta ni para la sociedad. Esta perspectiva busca transformar los métodos de desplazamiento, priorizando opciones que reduzcan la contaminación, optimicen el empleo de la energía y garanticen igualdad de posibilidades para todos. Tal como señala la ONU (2022), una movilidad verdaderamente eco-amigable debe ser segura, accesible, eficiente y respetuosa con el medioambiente, sin dejar atrás a nadie.

La sostenibilidad en el transporte se construye sobre varios pilares: el uso de tecnologías limpias, la planificación urbana inteligente, el fortalecimiento del transporte público y el fomento de modos activos como caminar o andar en bicicleta. La electrificación de la movilidad es una de las herramientas clave dentro de esta transformación, pero no es suficiente por sí sola. Para que los vehículos eléctricos contribuyan a una movilidad sostenible, deben estar integrados en un contexto más amplio que contemple fuentes de energía renovable, estrategias de gestión de la demanda, y políticas que desincentiven el uso excesivo del vehículo privado (Banister, 2005).

Este trabajo toma la movilidad sostenible como una idea central, desde la cual se analiza cómo usan los carros eléctricos pequeños en los hogares de Costa Rica. Más allá de los detalles técnicos de la carga o el gasto de electricidad, se observa si esta adopción ayuda de verdad a cambiar hacia formas de transporte más responsables y que tengan sentido con las metas nacionales de reducir la contaminación.

Electromovilidad

La movilidad eléctrica se refiere al uso de vehículos que funcionan con electricidad, presentándose como una alternativa a los medios de transporte tradicionales que dependen de combustibles fósiles. Este cambio va más allá de la mera tecnología; implica transformaciones profundas en la manera en que nos movemos, en la infraestructura de nuestras ciudades y en los sistemas energéticos. La movilidad eléctrica abarca coches, motos, autobuses, bicicletas eléctricas e incluso el transporte ferroviario, y se considera una de las estrategias clave para reducir las emisiones de gases de efecto invernadero asociadas al sector del transporte, que representa cerca del 24% de las emisiones globales de CO₂ (IEA, 2023).

A diferencia de los motores de combustión interna, los vehículos eléctricos no generan emisiones directas durante su funcionamiento, lo que contribuye a mejorar la calidad del aire en las áreas urbanas. Sin embargo, su impacto ambiental y energético también depende de otros factores, por lo que es fundamental analizar la movilidad eléctrica desde una perspectiva de ciclo de vida. Según el Banco Interamericano de Desarrollo (BID, 2023), la movilidad eléctrica solo será realmente sostenible si se combina con una matriz energética limpia, una adecuada planificación urbana y políticas de estímulo bien diseñadas. En América Latina, la movilidad eléctrica ha cobrado impulso en los últimos años, impulsada por la necesidad de diversificar el transporte, reducir la dependencia de los hidrocarburos importados y cumplir con los compromisos internacionales sobre cambio climático. Costa Rica, por ejemplo, ha establecido metas ambiciosas en su Plan Nacional de Descarbonización, promoviendo la electrificación del transporte tanto privado como público a través de incentivos fiscales, inversiones en infraestructura y campañas de concienciación (MIDEPLAN, 2025).

Este proyecto se enmarca en el ámbito de la movilidad eléctrica al estudiar cómo la adopción de vehículos eléctricos en los hogares costarricenses influye en el consumo de energía residencial y en la factura eléctrica. Por medio del modelado de patrones de carga y la simulación de distintos escenarios tarifarios, se pretende aportar datos empíricos sobre la factibilidad técnica y económica de esta transición, analizando no solo los beneficios ambientales, sino también las adaptaciones que requerirá el sistema eléctrico para respaldarla de manera eficaz y duradera.

Incentivos gubernamentales

Los estímulos que ofrece el gobierno son cruciales para impulsar tecnologías nuevas y amigables con el planeta, como la movilidad eléctrica. Estos estímulos se presentan de diversas maneras y buscan facilitar que la gente compre tecnologías limpias al reducir los costos. Según Thaller et al. (2021), si los gobiernos crean buenas políticas, las personas adoptará los carros eléctricos hasta cinco veces más rápido que si el mercado actuara solo.

Sin embargo, los estímulos deben tener un sistema de seguimiento técnico y social para asegurar que funcionen bien y sean justos. Investigaciones como la de Yang et al. (2016) indican que si los beneficios no están bien dirigidos, pueden aumentar

las diferencias sociales o causar problemas en el mercado. Por eso, para que una política de estímulos tenga éxito, debe ser clara, temporal, estar bien explicada y poder adaptarse, basándose en objetivos claros de impacto en el medio ambiente, la economía y la sociedad. Su meta final no debe ser solo vender más carros eléctricos, sino transformar el sistema de transporte hacia opciones más sostenibles e integradoras.

El efecto sobre el medio ambiente representa un aspecto clave al evaluar cualquier avance tecnológico en energía y movilidad. Para los VE, el estudio debe superar la simple ausencia de emisiones al usarlos y abarcar toda su existencia: desde obtener los materiales y fabricar las baterías, hasta usar la electricidad y deshacerse de él. Aunque los VE no lanzan gases dañinos directamente, su impacto real depende mucho de cómo se genera la electricidad que usan y cómo se manejan las partes importantes de sus baterías (IEA, 2022).

Los beneficios ambientales más claros de los VE se ven en la mejora del aire en las ciudades, ya que eliminan emisiones locales de óxidos de nitrógeno, partículas finas y dióxido de carbono. Esta disminución directa de contaminantes en el aire se traduce en mejoras para la salud de las personas, sobre todo para quienes son más vulnerables, como niños y ancianos. Según la Organización Mundial de la Salud (OMS, 2023), pasar al transporte eléctrico podría reducir hasta un 40% la exposición a contaminantes en las áreas urbanas con más tráfico. Además, al evitar el uso de combustibles fósiles, los VE ayudan a reducir la dependencia de energía de otros países y a suavizar los efectos del cambio climático.

Aun así, hay problemas ambientales relacionados, como qué hacer con las baterías cuando ya no sirven, la extracción de litio y cobalto, y la necesidad de asegurarse de que la electricidad utilizada venga de fuentes renovables. Algunos estudios han señalado que, si la electricidad que usan los VE proviene de combustibles fósiles, el beneficio real podría verse afectado (Breetz et al., 2021). Por eso, la adopción de los VE debe ir de la mano con planes completos que incluyan reciclar las baterías de forma eficiente, diversificar las fuentes de energía, dar incentivos a las energías limpias y mejorar la eficiencia en la forma en que se fabrican.

Huella de carbono

La huella de carbono es un índice que nos ayuda a calcular la cantidad total de gases de efecto invernadero que se producen, ya sea directamente o no, por algo que hacemos, un producto que usamos o un servicio que recibimos a lo largo de su

existencia. Esta idea se ha vuelto esencial para entender cómo afectan al medio ambiente diferentes industrias, como la del transporte. Tal como lo dice el Panel Intergubernamental sobre Cambio Climático (IPCC, 2022), medir la huella de carbono es fundamental para tomar buenas decisiones sobre cómo reducirla, ya que nos muestra de dónde vienen las mayores emisiones y nos ayuda a decidir qué acciones tomar primero, ya sean para arreglar o para prevenir.

En el caso de los vehículos eléctricos, la huella de carbono se calcula teniendo en cuenta varias fases: la fabricación del coche y su batería, la producción de la electricidad que se usa para cargarlo y qué se hace con él al final de su vida útil. Si la electricidad viene de fuentes renovables, la huella puede ser muy pequeña; pero, si viene de plantas de energía que queman combustibles, el beneficio para el medio ambiente se reduce bastante. Según un estudio de la Agencia Europea del Medio Ambiente (EEA, 2018), un coche eléctrico que se carga con electricidad que proviene en más de un 75% de fuentes renovables puede tener una huella de carbono hasta un 65% menor que un coche normal de gasolina.

Este índice es útil no solo para el medio ambiente: también sirve para comparar tecnologías, tomar mejores decisiones sobre políticas públicas e incluso comunicarnos mejor con los consumidores. Sin embargo, es clave recordar que no todas las huellas son iguales, ya que dependen de dónde estamos, la tecnología que usamos y cómo nos comportamos. Por eso, hay que evaluarla teniendo en cuenta el contexto, con métodos claros y adaptados a la situación energética de cada lugar. Como explican Negro y Bieker (2025), al comparar huellas de carbono, hay que considerar las particularidades de cada país o región, sobre todo en cuanto a cómo se genera la electricidad, la infraestructura y los hábitos de transporte.

En este estudio, la huella de carbono se utiliza como un criterio para entender mejor el impacto energético de cargar vehículos eléctricos en las casas de Costa Rica. Aunque el modelo principal se centra en cuánto se consume y cuánto cuesta, compararemos los datos con estimaciones de emisiones, basándonos en cómo está la red eléctrica del país. Esto nos ayudará a ver si usar vehículos eléctricos realmente reduce las emisiones en Costa Rica, o si es necesario mejorar la generación de energía limpia al mismo tiempo para que los beneficios ambientales sean mayores.

Simulación de costos

La simulación de costos es una herramienta de análisis que nos permite prever los costes relacionados con una inversión, servicio o actividad. Para ello, se toman en cuenta elementos como el precio, la asiduidad de uso, las posibles situaciones futuras y los cambios en las circunstancias del contexto. Esta clase de diseño se emplea extensamente en campos como el energético, el del transporte y el financiero, pues facilita la toma de decisiones bien argumentadas al disminuir la incertidumbre. Como indican Sun et al. (2021), el cálculo anticipado de gastos es clave para valorar las ganancias y la perdurabilidad económica de tecnologías que están surgiendo, sobre todo cuando hay una gran diferencia en sus condiciones de uso.

En lo que se refiere a la movilidad eléctrica, la simulación de costos permite hacer una estimación del coste total de tener un vehículo eléctrico, incluyendo la compra al principio, la conservación, la pérdida de valor, el gasto eléctrico y, en ciertas ocasiones, el valor que le queda al vehículo o a su batería (BNEF, 2023).

Estos cálculos no solo son valiosos a nivel particular, sino también al diseñar políticas públicas. Al diseñar distintas mezclas de elementos, se pueden encontrar límites en los que emplear vehículos eléctricos resulta más provechoso. Aparte, los cálculos ayudan a valorar el beneficio de la inversión para el cliente y a estimar el posible efecto añadido en la red eléctrica y en la economía del país. Tal y como señalan Díaz-Arrieta (2023), el cálculo es un recurso esencial para prever consecuencias económicas que no se ven en un análisis fijo o totalmente teórico.

Energías Renovables

Las energías renovables son aquellas que usan recursos naturales que se recargan continuamente, como el sol, el aire, el agua, la biomasa y el calor bajo tierra. A diferencia de los combustibles fósiles, estas fuentes no se agotan al usarse y su impacto en el entorno es mucho menor. Como menciona la Agencia Internacional de Energías Renovables (Sadeghian et al., 2022), las energías renovables son clave para lograr las metas climáticas, a la vez que dan más seguridad energética e impulsan el desarrollo económico que dura.

Además, el unir energías renovables con cosas como la carga inteligente o el almacenamiento repartido ayuda a usar al máximo la energía y a bajar el costo total. Las familias que utilizan paneles solares y usan coches eléctricos, por ejemplo, pueden ver un gran ahorro en su cuenta de luz, en especial si programan

la carga en las horas de más sol. Como mencionan Timmons et al. (2019), la correlación entre energías renovables y movilidad eléctrica no es solo técnica, sino también económica e intelectuales, ya que abre nuevas formas de ser independiente en energía y de que el usuario participe más en el sistema eléctrico.

Este estudio percibe el análisis de energías renovables como algo muy importante para entender el consumo de energía ligado a la carga de coches eléctricos en las casas de Costa Rica. Se van a tener en cuenta situaciones donde la energía para cargar los coches venga en parte de sistemas de sol en las casas, viendo su efecto en la cuenta de luz y en cómo se consume a diario. Así, se busca ver no solo cuánto cuesta la electromovilidad, sino también si puede servir como plan para un cambio de energía justo y para todos.

Modelado Computacional

El modelado computacional es una forma de plasmar matemáticamente procesos intrincados mediante simulacros llevados a cabo en sistemas digitales. Sirve para ensayar con diversas situaciones sin tener que realizar pruebas tangibles. Estos simulacros permiten ver tendencias, sopesar peligros y anticipar conductas venideras, todo ello apoyado en información veraz o cálculos bien fundamentados. Tal como señalan Macal y North (2021), la simulación informática no sustituye a la realidad, sino que la simplifica de manera organizada para entenderla, preverla y tomar resoluciones más acertadas.

En el sector energético y de la movilidad eléctrica, la simulación informática ha cobrado importancia. Por medio de herramientas como MATLAB, Python, R, o plataformas de simulación concretas, se pueden generar representaciones minuciosas de los hábitos de carga de coches eléctricos, del funcionamiento de la red eléctrica, o del impacto en las tarifas según distintos parámetros. Esto permite, por ejemplo, calcular el efecto de sumar miles de coches eléctricos a una red ya instalada, simular el flujo de energía por horas según tarifas variables, o evaluar cómo cambiaría el consumo al incorporar energías renovables. Como apuntan Galarza-Linares et al. (2021), estas simulaciones brindan una visión anticipada que facilita la organización a nivel del cliente y la toma de decisiones gubernamentales.

El modelado también deja añadir incertidumbre, sensibilidad y aprendizaje gradual, elementos clave al hablar de tecnologías en proceso de expansión como la movilidad eléctrica. Gracias a modelos mixtos se pueden crear panoramas más

sólidos que retraten la realidad con mayor exactitud. Así, el modelado computacional no solo atiende a una exigencia técnica, sino que también se adecúa a enfoques de investigación más flexibles, prácticos y adaptables, cada vez más necesarios en entornos de gran inestabilidad tecnológica y social (Rojek et al., 2023).

Naïve Bayes

El método de clasificación conocido como Naive Bayes se basa en el teorema de Bayes, dando por sentado que las variables predictivas son estadísticamente independientes. A pesar de su simplicidad, este método ha mostrado ser eficaz en diversas situaciones, sobre todo al manejar grandes cantidades de información y cuando se busca una solución que sea tanto rápida como sólida. Su eficiencia a nivel de cálculo y su habilidad para gestionar tanto variables de tipo categórico como continuas hacen que sea una herramienta útil en problemas de predicción, como el análisis de textos, el diagnóstico médico, los sistemas de recomendación y, cada vez más, la predicción de la demanda de energía (Zhang y Ling, 2021).

El accionar de Naive Bayes se funda en la probabilidad condicional: calcula la probabilidad de que una observación encaje en una clase específica, teniendo en cuenta las características que se han observado. Este planteamiento estadístico permite clasificar casos nuevos basándose en información histórica, lo cual viene muy bien cuando se cuenta con muestras que son representativas y se pretende generalizar patrones. En contextos como el energético, donde las decisiones están sujetas a múltiples variables (hora, precio, temperatura, tipo de uso), Bayes Ingenuo hace posible detectar combinaciones de factores que señalan subidas o bajadas en el consumo (Rugpathi et al., 2024). Si bien hay métodos más complejos, su claridad y sencillez para ponerlos en práctica hacen que siga siendo una opción sensata en ambientes tanto académicos como profesionales.

Un punto fuerte de este método es que no exige muchos recursos de computación, así que se puede integrar sin problemas en modelos de simulación de bajo coste, como los que se desarrollan en ambientes educativos o en proyectos piloto. Además, ofrece resultados fáciles de entender, lo cual es muy valioso cuando se necesita explicar cómo funciona el modelo a personas que no son expertas. Sin embargo, su eficacia podría verse afectada si las variables están muy

relacionadas entre sí, por lo que es aconsejable usar técnicas de preprocesamiento y validación cruzada para asegurar su efectividad (Joyokusumo et al., 2020).

En este estudio, se recurrirá al método Naive Bayes como herramienta de modelado predictivo para calcular el impacto del uso de vehículos eléctricos en el consumo de energía de los hogares costarricenses. Usando datos simulados y reales, el modelo clasificará distintos perfiles de consumo y predecirá posibles incrementos en la factura de la luz. Esto hará posible identificar patrones representativos y facilitar la toma de decisiones, tanto para usuarios individuales como para instituciones que diseñan políticas de gestión energética y promoción de la movilidad eléctrica.

CAPÍTULO 3. Marco Metodológico

3.1. Tipo de investigación

La presente investigación se clasifica como de tipo Aplicada, con componentes predictivos y de desarrollo tecnológico. Esta clasificación se fundamenta en su propósito central, el cual no radica en la generación de nuevo conocimiento fundamental o teórico, sino en la aplicación de conocimientos, metodologías y tecnologías existentes para resolver una problemática concreta y atender una necesidad específica dentro del contexto costarricense. Según Hernández Sampieri et al. (2022), la investigación aplicada “busca aportar soluciones inmediatas a problemas particulares, utilizando conocimientos teóricos ya disponibles” (p. 106), lo cual coincide plenamente con el propósito de este trabajo. Asimismo, estos autores sostienen que “el objetivo esencial es usar los hallazgos para tomar decisiones o implementar acciones en contextos específicos” (p. 106).

Específicamente, el estudio se enfoca en evaluar la viabilidad económica y la sostenibilidad del uso de EV en el consumo energético domiciliario y su impacto directo en la facturación eléctrica.

De esta manera, el componente predictivo se justifica en tanto que se busca anticipar el impacto económico y ambiental que tendría la adopción de vehículos eléctricos en el consumo energético de los hogares costarricenses. Esto implica

elaborar proyecciones sobre el comportamiento de la demanda eléctrica y la facturación asociada, con base en modelos y datos empíricos.

Asimismo, se incorpora un enfoque de desarrollo tecnológico, dado que se plantea la evaluación de alternativas innovadoras que involucren tecnologías limpias, como los EV, en función de su factibilidad económica y sostenibilidad. De acuerdo con la UNESCO (2024), la investigación con orientación tecnológica se vincula con la mejora, adaptación o implementación de soluciones tecnológicas que respondan a necesidades sociales o ambientales. En este caso, la integración de los EV al sistema de consumo energético doméstico plantea no solo un reto técnico, sino también una oportunidad de optimización y transformación del uso energético en los hogares.

3.2. Alcance investigativo

El presente estudio tiene un alcance correlacional con componentes descriptivos, ya que busca analizar la relación entre la adquisición de vehículos eléctricos y el impacto que esta decisión genera en el consumo energético y la factura eléctrica de los hogares. Para ello, se recolectará y analizará información sobre patrones de consumo, costos energéticos y tipos de tarifas, con el fin de identificar asociaciones que permitan comprender la viabilidad económica y sostenibilidad del uso de estos vehículos.

Adicionalmente, se incluirá una caracterización descriptiva de los usuarios, los esquemas tarifarios y los contextos de consumo, a fin de contextualizar los resultados. Hernández Sampieri et al. (2022) afirman que los estudios descriptivos “buscan especificar las propiedades importantes de personas, grupos, comunidades o cualquier otro fenómeno que sea sometido a análisis” (p. 91), lo cual aplica directamente al perfil de consumidores de EV. Este enfoque, al identificar las asociaciones entre las variables, permitirá predecir la probabilidad de ciertos comportamientos y tendencias, sentando a su vez las bases para futuras investigaciones de alcance explicativo que busquen establecer relaciones causales.

3.3. Enfoque

En esta investigación se adopta un enfoque cuantitativo, el cual “permite examinar los datos de manera objetiva y emplear herramientas estadísticas para

identificar patrones y relaciones entre variables” (Tamayo y Tamayo, 2005, p. 89), permitiendo estimar de forma precisa el impacto en la factura eléctrica tras la incorporación de vehículos eléctricos.

Se parte del método deductivo, el cual “procede de lo general a lo particular, estableciendo hipótesis a partir de teorías existentes que luego se contrastan empíricamente” (Sierra Bravo, 2001, p. 92). Dentro de este también se aplican modelos predictivos como el algoritmo de Naïve Bayes y las redes neuronales para generalizar los resultados obtenidos a partir de muestras representativas.

Este enfoque, sustentado en el paradigma positivista y en el método nomotético, tiene como finalidad “establecer leyes generales que expliquen y predigan fenómenos observables en contextos sociales o naturales” (Sierra Bravo, 2001, p. 85), buscando así la comprobación de tendencias generales que expliquen la relación entre la adopción de vehículos eléctricos y el incremento en el consumo eléctrico, proporcionando resultados con un alto grado de certeza.

Además, la investigación se complementa con una revisión sistemática de la literatura y el análisis contextual de aspectos operativos y económicos lo que enriquece la interpretación de los hallazgos y permite abordar de manera integral el fenómeno estudiado.

3.4. Diseño.

El diseño adoptado en esta investigación es de tipo cuantitativo, no experimental, con enfoque correlacional. Esta elección responde a la necesidad de analizar el impacto de la adopción de EV en el consumo energético de los hogares, sin manipular directamente las variables involucradas. Se busca establecer relaciones estadísticas entre variables observadas como la frecuencia de carga, el tipo de tarifa eléctrica y el incremento en la factura mensual. Según Hernández Sampieri et al. (2022), en los estudios no experimentales “no se manipulan deliberadamente las variables independientes; lo que se hace es observar fenómenos tal como ocurren en su contexto natural” (p. 117). El enfoque correlacional, por su parte, permite examinar el grado de asociación entre variables como la frecuencia de carga, el tipo de tarifa eléctrica y el incremento en la factura mensual. Tal como afirma Bisquerra (2004), “la investigación correlacional permite

medir la relación entre dos o más variables sin establecer una relación causal directa” (p. 119).

La investigación se centra en un método deductivo, partiendo de teorías previas sobre patrones de consumo y estudios existentes sobre movilidad eléctrica. A partir de esta base, se formularán hipótesis que serán contrastadas mediante técnicas de modelado predictivo, empleando algoritmos como Naïve Bayes y redes neuronales artificiales. Estas técnicas permitirán estimar con alta precisión el impacto energético de la carga de EV en distintos escenarios tarifarios.

Adicionalmente, se desarrollarán simulaciones computacionales orientadas a visualizar el comportamiento futuro del consumo eléctrico bajo diversas condiciones (tarifa dinámica, hábitos de carga, incorporación de energías renovables). Estas simulaciones contribuirán a consolidar un marco metodológico replicable y robusto, útil para los consumidores interesados en adquirir vehículos eléctricos (Baggio, 2017; Rojek et al., 2023).

3.5. Población y muestreo.

Esta investigación se fundamenta en el análisis de un conjunto de datos públicos sobre el consumo de energía de vehículos eléctricos en estaciones de carga de uso doméstico, específicamente aquellos que son 100 % dependientes de baterías eléctricas. Se excluyen de este estudio los vehículos híbridos, ya que, aunque utilizan baterías, también operan con hidrocarburos y no dependen exclusivamente de la electricidad. No se contempla la recolección de datos primarios mediante encuestas.

La población de datos corresponde a los 177,860 registros de consumo de EV disponibles en el *dataset* seleccionado . La muestra de datos será el subconjunto utilizado para el entrenamiento, validación y prueba de los modelos predictivos de inteligencia artificial.

Este enfoque metodológico ofrece acceso a grandes volúmenes de datos, asegurando la robustez de los modelos de IA y la replicabilidad del estudio. Un análisis exploratorio de datos se llevará a cabo para comprender la distribución y calidad de las variables, lo cual guiará el preprocesamiento necesario para la aplicación de algoritmos como Naïve Bayes y redes neuronales en la estimación del consumo y su impacto.

3.6. Instrumentos de Recolección de Datos

En línea con el enfoque de la investigación, que no contempla la recolección de datos primarios, el instrumento principal de "recolección" lo constituye un *dataset* público existente. Este *dataset* sirve como la única fuente de información para el análisis y el desarrollo del modelo predictivo.

La "recolección" de datos, en este contexto, se refiere a la adquisición, descarga y estructuración de este recurso digital. El *dataset* contiene registros históricos detallados sobre el consumo de energía de vehículos eléctricos en estaciones de carga, incluyendo variables como los registros de consumo, marcas de tiempo y, si disponibles, identificadores de estaciones/vehículos u otras características relevantes.

Previo al modelado, se realizará un análisis exploratorio del *dataset*. Este proceso es fundamental para comprender la naturaleza, calidad y distribución de los datos, identificar anomalías y realizar el preprocesamiento necesario. Así, el *dataset* no solo actúa como instrumento de datos, sino que su análisis inicial es una fase crítica para asegurar la validez y pertinencia de los insumos para los algoritmos de inteligencia artificial.

3.6.1. Revisión documental

La revisión documental constituye una técnica fundamental en esta investigación, orientada a la recopilación y análisis de fuentes secundarias pertinentes al fenómeno estudiado. Este proceso implicó la búsqueda sistemática, selección y análisis crítico de literatura académica, informes técnicos, estadísticas oficiales, normativas sobre movilidad eléctrica y documentos especializados en consumo energético y tarifas eléctricas.

La finalidad de esta revisión fue construir el marco teórico-conceptual, identificar antecedentes empíricos relevantes y ubicar el estado actual del conocimiento sobre el impacto del uso de vehículos eléctricos en el consumo energético doméstico. Además, permitió delimitar las variables clave y sustentar la formulación del problema y los objetivos (Hernández Sampieri, Mendoza Torres, & Baptista Lucio, 2014).

Esta revisión no solo proporciona sustento teórico, sino que también orienta el diseño del estudio empírico y la interpretación de los resultados (Tamayo y Tamayo, 2004).

3.6.2. Encuestas estructuradas

Como instrumento para la recolección de datos secundarios, se diseñó una encuesta estructurada dirigida a usuarios actuales de vehículos eléctricos. Su objetivo es recopilar información directa sobre hábitos de carga, frecuencia de uso, percepción de los costos energéticos, experiencia con el sistema tarifario y criterios de sostenibilidad económica vinculados a la movilidad eléctrica.

La encuesta fue construida a partir de los hallazgos obtenidos en la revisión documental y se compone principalmente de preguntas cerradas, utilizando escalas tipo Likert, opciones múltiples y dicotómicas, lo que facilita su codificación y análisis estadístico.

Este tipo de instrumento es común en investigaciones cuantitativas por su estandarización y capacidad para generar información comparable (Arias, 2012).

Los datos recolectados servirán para complementar el análisis derivado del *dataset* primario, permitiendo contrastar comportamientos observables con percepciones reales y enriquecer así la interpretación de los resultados.

Tabla 5. Encuesta estructurada sobre EV.

Sección	Ítem	Resultado esperado
<p>Razones para comprar un carro eléctrico.</p>	<p>¿Le interesa reducir su impacto ambiental?</p> <p>¿Desea ahorrar en combustible a largo plazo?</p> <p>¿Le atrae la innovación y tecnología de los autos eléctricos?</p> <p>¿Está motivado por incentivos gubernamentales</p>	<p>Esta sección de la encuesta tiene como objetivo identificar las principales razones que motivan la compra de un vehículo eléctrico. A través de una escala Likert de 5 puntos, se evalúan factores ambientales,</p>

	<p>(subsidios, reducción de impuestos)?</p> <p>¿Quiere disminuir su dependencia de combustibles fósiles?</p> <p>¿Le preocupa el cambio climático?</p> <p>¿Considera que el mantenimiento de un vehículo eléctrico es más económico?</p> <p>¿Ha tenido influencia de personas cercanas que ya poseen un vehículo eléctrico?</p> <p>¿Valora el silencio y confort del vehículo eléctrico?</p> <p>¿Quiere estar a la vanguardia en tendencias de movilidad?</p>	<p>económicos, tecnológicos, sociales y de confort. Se espera que las motivaciones ambientales (como reducir el impacto ecológico y preocupación por el cambio climático) y económicas (ahorro en combustible y mantenimiento) obtengan los puntajes más altos. Las razones tecnológicas y de comodidad también podrían mostrar alta valoración, mientras que la influencia social puede presentar mayor variabilidad. Los resultados permitirán clasificar los factores predominantes y establecer relaciones con otras variables del estudio.</p>
<p>Uso Energético, Gestión y Percepción del Vehículo Eléctrico.</p>	<p>¿Carga tu vehículo eléctrico principalmente en horario nocturno?</p> <p>¿Tienes contratada una tarifa dinámica (con horarios valle/punta)?</p>	<p>Se espera que los participantes indiquen una preferencia por cargar sus vehículos eléctricos en horario nocturno y que utilicen tarifas dinámicas, motivados por la</p>

	<p>Del 1 al 10, ¿cómo calificarías el incremento que has observado en tu factura eléctrica mensual tras adoptar un vehículo eléctrico?</p> <p>¿Consideras que la carga rápida en estaciones públicas es más eficiente energéticamente que la carga lenta en tu domicilio?</p> <p>Del 1 al 10, ¿en qué medida ha sido útil para ti integrar fuentes de energía renovable (p.ej., paneles solares) en la recarga de tu EV?</p> <p>¿Utilizas alguna estrategia de optimización (p. ej., programación de carga, ajuste de potencia, smart plugs) para reducir el coste energético de la recarga?</p>	<p>optimización de costos. La mayoría probablemente percibirá un aumento moderado en la factura eléctrica mensual, aunque compensado en parte por estrategias de eficiencia como la programación de carga. Es probable que exista una percepción positiva sobre la reducción de la huella de carbono. El conocimiento sobre incentivos gubernamentales puede ser limitado, y se anticipa un uso incipiente de herramientas basadas en inteligencia artificial para la gestión del consumo. En general, esta sección permitirá identificar patrones de uso energético y el nivel de conciencia tecnológica y ambiental de los usuarios de vehículos eléctricos.</p>
--	--	--

	<p>Del 1 al 10, ¿qué tan familiarizado estás con los incentivos gubernamentales para la compra y uso de vehículos eléctricos?</p> <p>¿Has percibido caídas de tensión o interrupciones en tu suministro eléctrico asociadas a la recarga de tu EV?</p> <p>Del 1 al 10, ¿cómo valoras la reducción de la huella de carbono de tu EV comparada con un vehículo de combustión interna?</p> <p>¿Has utilizado herramientas basadas en IA para estimar tu consumo de recarga?</p>	
<p>Razones para no considerar un carro eléctrico.</p>	<p>El precio inicial de compra es demasiado alto.</p> <p>La autonomía (kilómetros que puede recorrer) es insuficiente.</p>	<p>Esta sección busca identificar las principales barreras percibidas para adoptar un vehículo eléctrico. Se espera que los encuestados manifiesten alto acuerdo con</p>

	<p>No hay suficientes estaciones de carga en mi zona.</p> <p>La recarga toma demasiado tiempo.</p> <p>Desconozco cómo funciona un vehículo eléctrico.</p> <p>Me preocupa el costo de reparación o mantenimiento.</p> <p>No confío en la duración de la batería.</p> <p>Prefiero esperar a que la tecnología madure.</p> <p>Creo que los vehículos eléctricos no son adecuados para largos trayectos.</p> <p>No estoy convencido de que realmente sean más ecológicos.</p>	<p>afirmaciones relacionadas con el precio elevado, autonomía limitada, escasa infraestructura de carga y tiempo de recarga. También podrían expresar preocupaciones sobre el mantenimiento, la duración de la batería y el desconocimiento del funcionamiento del vehículo. Algunas respuestas reflejarán escepticismo sobre su impacto ecológico o preferencia por esperar a que la tecnología madure. Estos resultados ayudarán a comprender las resistencias actuales y orientar estrategias para fomentar su adopción.</p>
--	---	---

Fuente: Elaboración propia.

3.7. Técnicas de análisis de información

En el marco de esta investigación, se emplean técnicas de análisis cuantitativas y cualitativas, en correspondencia con la naturaleza mixta de las fuentes de información utilizadas. Las encuestas estructuradas constituyen la base del análisis cuantitativo, mientras que la revisión documental se aborda desde un enfoque cualitativo. A continuación, se describen las técnicas aplicadas en cada caso.

3.7.1. Análisis exploratorio de datos

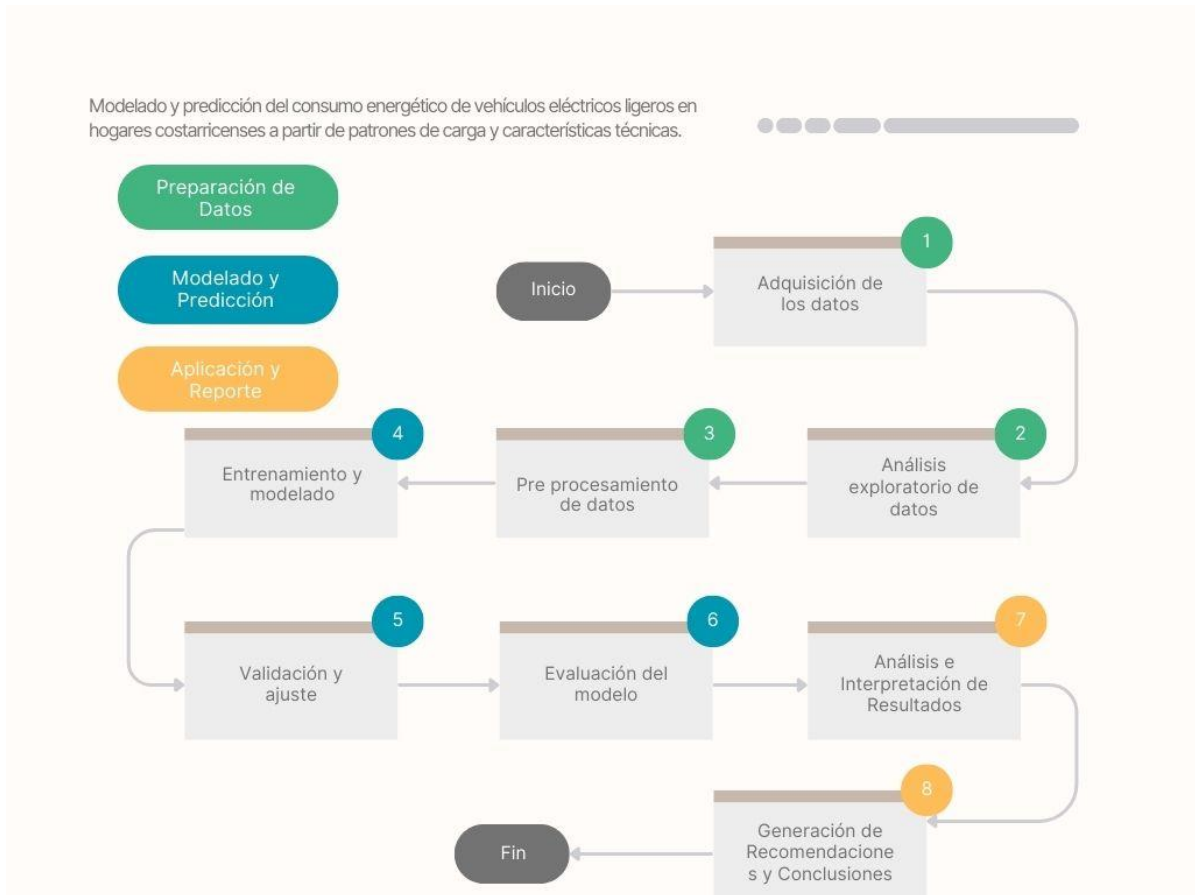
El Análisis Exploratorio de Datos (EDA, por sus siglas en inglés) es una etapa fundamental en proyectos de inteligencia artificial, ya que permite comprender la estructura, calidad y patrones presentes en la información antes de aplicar modelos predictivos (Martínez-Plumed et al., 2019). En esta investigación, el EDA se lleva a cabo a partir de un conjunto de datos públicos sobre consumo energético de vehículos eléctricos.

Para una mejor comprensión del proceso, se utiliza un diagrama de flujo que describe las fases de adquisición, limpieza, procesamiento y análisis de los datos. Este procedimiento incluye la detección y tratamiento de valores faltantes, la eliminación de duplicados, la transformación de variables, el análisis estadístico descriptivo, la identificación de patrones, tendencias y posibles outliers, así como la visualización de relaciones entre variables relevantes (Han et al., 2022).

El objetivo del EDA es garantizar que los datos utilizados sean fiables y representativos, lo que permite estimar de forma precisa el consumo energético, evaluar su impacto y generar simulaciones y recomendaciones. Este proceso culmina con la construcción de un modelo predictivo de IA capaz de evaluar escenarios y proponer soluciones para optimizar el consumo de vehículos eléctricos (Provost & Fawcett, 2013).

3.7.1.1. Diagrama de flujo

Figure 7. Diagrama de flujo: Marco metodológico.



3.7.2. Técnicas de Análisis Cuantitativas (Encuestas)

3.7.2.1. Análisis de frecuencias absolutas y relativas

El análisis de frecuencias permite describir la distribución de los datos a través del conteo de respuestas (frecuencias absolutas) y el cálculo de porcentajes (frecuencias relativas), siendo una técnica fundamental para el análisis descriptivo de variables categóricas o discretas (Hernández Sampieri, Mendoza Torres, & Baptista Lucio, 2014). (Bernal, 2010)

3.7.2.2. Gráficos estadísticos

La representación gráfica de los datos, mediante diagramas de barras, sectores o histogramas, facilita la identificación de tendencias, comparaciones y

patrones en las respuestas. Estos recursos visuales apoyan la interpretación de los resultados y la comunicación clara de hallazgos cuantitativos (Bernal, 2010).

3.7.2.3. Cálculo de medidas de tendencia central

Las medidas de tendencia central —media, mediana y moda— permiten sintetizar los datos cuantitativos y obtener un valor representativo para variables con escalas de intervalo u ordinales. Son especialmente útiles en ítems tipo Likert para conocer el nivel promedio de acuerdo o desacuerdo de los participantes (Arias, 2012).

3.7.2.4. Análisis de correlación

El análisis de correlación permite identificar relaciones entre variables cuantitativas. El coeficiente de correlación de Pearson es uno de los más utilizados para establecer el grado de asociación lineal entre dos variables, siendo útil para explicar comportamientos simultáneos o dependencias estadísticas (Hernández Sampieri, Mendoza Torres, & Baptista Lucio, 2014).

3.7.3. Técnicas de Análisis Cualitativas (Revisión Documental)

3.7.3.1. Análisis de contenido temático

El análisis de contenido temático es una técnica cualitativa que permite examinar textos para identificar temas recurrentes, patrones conceptuales y estructuras de significado. Según (Flick, 2012) esta técnica es adecuada para estudios que buscan comprender fenómenos desde el contexto discursivo y conceptual en el que emergen.

3.7.3.2. Matrices de sistematización

Las matrices de sistematización son herramientas que permiten organizar la información relevante de los documentos revisados de forma comparativa y estructurada. Según (Gibbs, 2012), estas matrices son útiles para codificar información cualitativa y establecer relaciones entre categorías, conceptos y autores, lo que favorece el análisis cruzado de fuentes documentales.

CAPÍTULO 4. Análisis del diagnóstico

Este capítulo presenta el análisis de los datos recopilados mediante encuestas estructuradas y fuentes documentales, con el objetivo de diagnosticar los factores que influyen en la adopción de vehículos eléctricos, así como los hábitos de recarga y las percepciones asociadas al consumo energético. Se abordan también las barreras identificadas por los usuarios para no considerar esta tecnología, junto con el análisis de un conjunto de datos enfocado en el consumo eléctrico en estaciones de carga. La información aquí desarrollada permite integrar los distintos componentes del estudio y ofrecer una visión crítica sobre la viabilidad económica y sostenibilidad del uso de vehículos eléctricos en el contexto actual.


4.1. Aplicación de encuestas

Las encuestas se aplicaron a un total de 48 personas, incluyendo propietarios de vehículos de combustibles fósiles, de movilidad eléctrica y aquellas que están considerando adquirir un vehículo eléctrico. El objetivo fue conocer las razones que respaldan la motivación de esta investigación. Para ello, se consultó a los participantes sobre sus patrones de carga, preferencias, motivaciones y experiencias relacionadas con el uso de vehículos eléctricos en el territorio costarricense.

La proporción casi igual entre propietarios y no propietarios de vehículos eléctricos indica un mercado dividido y con potencial para crecimiento. El hecho de que solo un reducido grupo esté considerando la compra sugiere que, para impulsar la adopción, podrían requerirse incentivos adicionales, mejoras en infraestructura de carga y mayor difusión de beneficios. Ver figura 6.

Figura 6. Distribución de propietarios

¿Posee actualmente un vehículo eléctrico?
48 respuestas

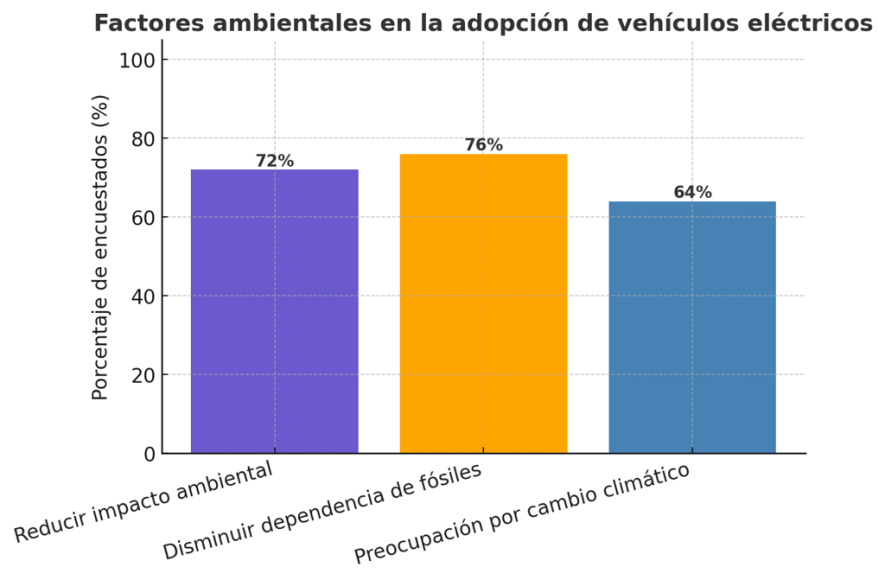


Fuente: Elaboración propia

4.1.1. Criterios ambientales.

Los resultados de la encuesta muestran que los factores ambientales tienen un peso relevante en la decisión de adoptar un vehículo eléctrico. El 76 % de los encuestados manifestó un alto interés en disminuir su dependencia de combustibles fósiles, mientras que el 72 % expresó que busca reducir su impacto ambiental. Asimismo, el 64 % indicó un elevado nivel de preocupación por el cambio climático, reconociéndolo como un problema que requiere atención prioritaria. Estos datos reflejan que, aunque las motivaciones económicas también influyen, existe una base sólida de conciencia ambiental que respalda la transición hacia la movilidad eléctrica y refuerza su vínculo con los objetivos de sostenibilidad y reducción de emisiones.

Figura 7. Factores ambientales




Fuente: Elaboración propia

Figura 8. Impacto ambiental

Me interesa reducir mi impacto ambiental

25 respuestas




Fuente: elaboración propia de datos de encuesta.

Figura 9. Dependencia de combustibles fósiles

Quiero disminuir mi dependencia de combustibles fósiles

25 respuestas




Fuente: Elaboración propia de datos de la encuesta

Figura 10. Conciencia sobre el cambio climático.

Me preocupa el cambio climático

25 respuestas



Fuente: Elaboración de datos propios.

4.1.2. Factores socioeconómicos

El análisis de los gráficos muestra que los factores socioeconómicos ejercen una influencia significativa en la decisión de adoptar un vehículo eléctrico.

En primer lugar, el coste de mantenimiento se percibe como una ventaja clara: el 84 % de los encuestados seleccionó la puntuación máxima (5) y un 24 % puntuó con 4, evidenciando que la mayoría considera que el mantenimiento de un vehículo eléctrico es más económico que el de uno de combustión interna (ver figura 11).


En cuanto a los incentivos gubernamentales (subsidios y reducción de impuestos), el 44 % otorgó la máxima puntuación, mientras que un 20 % puntuó con 4 y un 24 % con 3. Esto indica que, aunque los incentivos son un factor motivador, no generan un consenso tan alto como otros criterios económicos directos.

Por último, el ahorro en combustible a largo plazo es el factor con mayor consenso: el 84 % marcó la puntuación máxima, lo que refleja que la expectativa de reducción de gastos en energía es una motivación determinante.

Figura 11. Ahorro en combustibles.

Deseo ahorrar en combustible a largo plazo

25 respuestas




Fuente: Elaboración propia.

Figura 10. Incentivos gubernamentales

Estoy motivado por incentivos gubernamentales (subsidios, reducción de impuestos)

25 respuestas




Fuente: Elaboración propia de datos de encuesta

Figura 11. Cargos de mantenimiento.

Considero que el mantenimiento es más económico

25 respuestas



Fuente: Elaboración propia de datos de encuesta

En conjunto, estos resultados muestran que la percepción de beneficios económicos tangibles, especialmente el ahorro en combustible y el menor coste de mantenimiento los cuales tienen un peso muy alto en la motivación para la adopción de vehículos eléctricos, complementando los incentivos externos como las políticas gubernamentales.

4.1.3. Factores que frenan la compra de vehículos eléctricos

En el análisis realizado únicamente con los encuestados que no poseen un vehículo eléctrico o que están considerando adquirir uno, se identificaron diversas barreras que influyen en su decisión. Estas se agrupan en cinco áreas principales

4.1.3.1. Tecnología y desempeño

Un 86,2 % considera que los vehículos eléctricos no son adecuados para largos trayectos y prefiere esperar a que la tecnología madure antes de realizar una compra. Asimismo, un 73,9 % manifestó desconfianza en la duración de la batería y un 60 % percibe que la autonomía es insuficiente para sus necesidades.

4.1.3.2. Económicos

El 73,9 % expresó preocupación por el costo de reparación o mantenimiento, mientras que el 43,4 % identificó el precio inicial elevado como una limitación relevante.

4.1.3.3. Tiempo y practicidad

Respecto al tiempo de recarga, el 47,8 % consideró en el nivel máximo (5) que el proceso es demasiado lento, seguido de un 34,8 % que lo evaluó con un 4. Solo un 17,4 % se mantuvo en una posición intermedia (nivel 3) y no se reportaron valoraciones en los niveles más bajos (1 y 2). Esto refleja que, además de la disponibilidad, la velocidad de carga constituye una barrera práctica para la adopción de esta tecnología.

4.1.3.4. Conocimiento y percepción

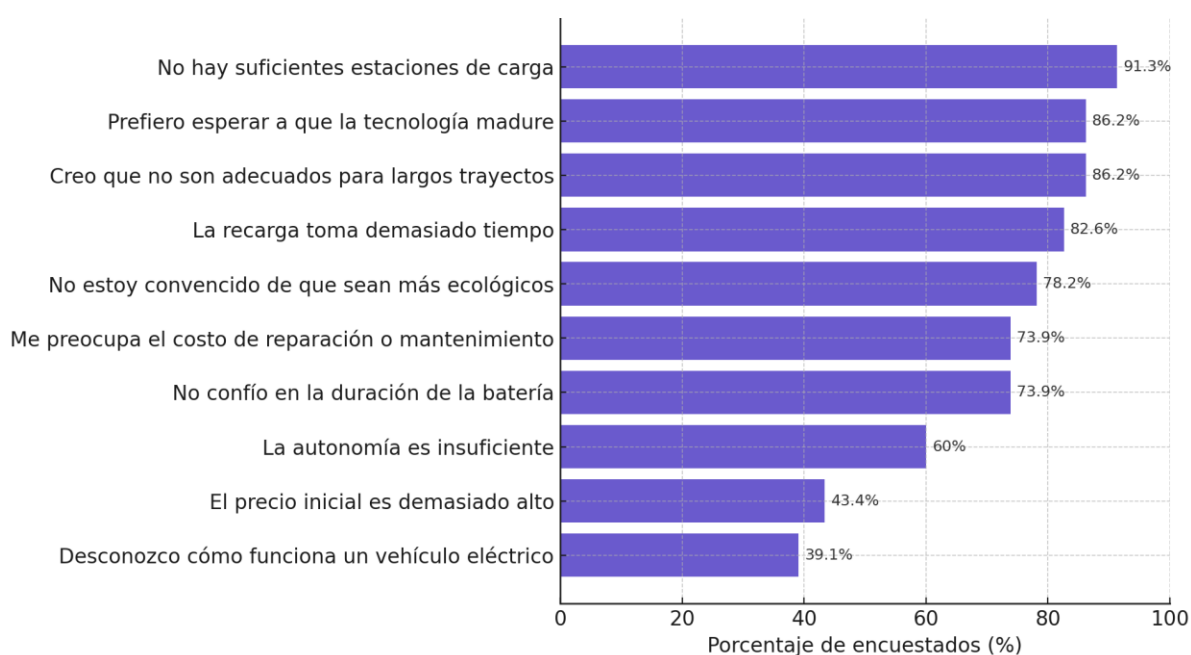
Un 78,2 % manifestó no estar convencido de que los vehículos eléctricos sean realmente más ecológicos, y el 39,1 % reconoció desconocer su funcionamiento.

4.1.3.5. Infraestructura de recarga

El 91,3 % indicó que no hay suficientes estaciones de carga en su zona, lo que refleja una percepción generalizada de insuficiencia en la cobertura y disponibilidad de puntos de recarga.

Estos resultados evidencian que las principales limitaciones para la adopción de vehículos eléctricos en este grupo de la población están asociadas a percepciones sobre la madurez tecnológica, preocupaciones operativas, dudas respecto a la sostenibilidad real, consideraciones económicas y limitaciones en la infraestructura. Abordar dichas barreras mediante estrategias de comunicación, educación tecnológica, incentivos financieros, mejoras en la red de carga y avances en la tecnología de baterías podría favorecer la transición hacia una movilidad más sostenible.

Figura 12. Principales barreras para la adquisición de vehículos eléctricos.



Fuente: Elaboración propia.

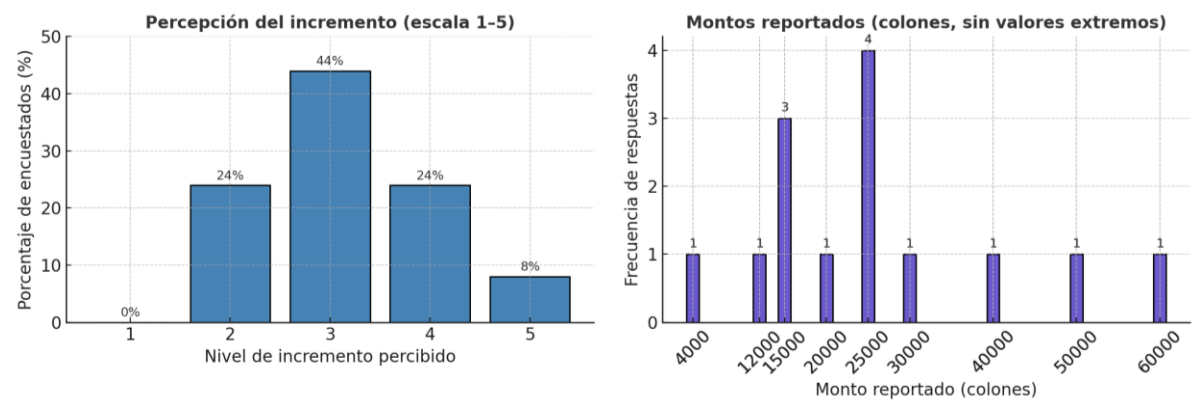
4.1.4. Percepción del incremento en la factura eléctrica tras la adquisición de un vehículo eléctrico

El análisis de los resultados revela que los propietarios de vehículos eléctricos presentan un nivel moderado de conciencia respecto al incremento en su factura eléctrica mensual. En la escala de 1 a 5, la mayor proporción (44 %) se ubicó en el nivel 3, seguido por un 24 % en los niveles 2 y 4, y un 8 % en el nivel 5.

Tras depurar valores extremos, los montos reportados de aumento oscilan entre ₡4.000 y ₡60.000 colones mensuales, con concentraciones más frecuentes en ₡15.000 (12 %) y ₡25.000 (16 %). La dispersión de los valores sugiere que, aunque los usuarios perciben un incremento, este varía significativamente según sus hábitos de carga, tipo de tarifa eléctrica y uso del vehículo.

Este hallazgo evidencia la necesidad de ofrecer herramientas de monitoreo y proyección de consumo que permitan a los usuarios estimar de forma más precisa el impacto económico de la carga de un vehículo eléctrico.

Figura 13. Percepción y cuantificación del incremento en la factura eléctrica tras la adopción de un vehículo eléctrico.



Fuente: Elaboración propia

4.1.5. Uso de herramientas de IA y estrategias de optimización en la recarga de vehículos eléctricos


Los resultados muestran que el uso de tecnologías avanzadas para la gestión y optimización de la recarga de vehículos eléctricos es limitado entre los encuestados. Solo el 16 % ha utilizado herramientas basadas en inteligencia artificial para estimar su consumo de recarga, mientras que el 84 % no ha hecho uso de este tipo de soluciones. Esto evidencia una baja penetración de tecnologías predictivas en la gestión del consumo energético residencial vinculado a la movilidad eléctrica.

En lo que respecta a las estrategias de optimización tales como la programación de carga, el ajuste de potencia o el uso de enchufes inteligentes; el 32 % de los encuestados declaró implementarlas, frente a un 68 % que no emplea ningún mecanismo de este tipo.

La baja adopción de herramientas de IA y estrategias de optimización sugiere un potencial de mejora significativo en la gestión eficiente de la energía para recarga. Promover el acceso a tecnologías de monitoreo y control, junto con la capacitación de los usuarios, podría traducirse en una reducción de costes y un uso más racional de la energía.

Figura 14. Uso de herramientas de inteligencia artificial para estimar consumo de recarga


¿Has utilizado herramientas basadas en IA para estimar tu consumo de recarga?
25 respuestas



Fuente: Elaboración propia

Figura 15. Implementación de estrategias de optimización energética para la recarga

¿Utilizas alguna estrategia de optimización (p. ej., programación de carga, ajuste de potencia, smart plugs) para reducir el coste energético de la recarga?
25 respuestas



Fuente: Elaboración propia

CAPÍTULO 5. Propuesta de solución

La propuesta de solución planteada se centra en el diseño y desarrollo de un modelo de inteligencia artificial orientado a estimar de forma precisa el impacto económico que implica la recarga de un vehículo eléctrico en la facturación mensual de un hogar. Este modelo busca establecer una correlación robusta entre múltiples variables clave, como la capacidad de las baterías, la edad del vehículo, los patrones de carga y el comportamiento de uso.

Un elemento complementario es la creación de un simulador interactivo, que permitirá al usuario visualizar escenarios y proyecciones de costos bajo diferentes condiciones, facilitando así la comprensión y utilización de los resultados generados por el modelo de IA.

5.1. Analisis de datos exploratorio

Con el fin de preparar la solución se realiza un análisis académico sobre el consumo energético en sesiones de carga de vehículos eléctricos (EV), basado en un conjunto de datos de 1,320 registros. El propósito es comprender los factores que determinan el consumo de energía y proponer metodologías predictivas que permitan optimizar tanto la experiencia del usuario como la infraestructura de carga.

5.1.1. Descripción del conjunto de datos

El conjunto de datos consta de 20 variables, siendo la variable objetivo Energy Consumed (kWh). Las variables se agrupan en cuatro categorías principales.

Tabla 6. Descripción de las características del conjunto de datos

Categoría	Descripción	Variables
Vehículo y batería	Incluye información relevante del vehículo y la batería tales como modelo, antigüedad y potencia de la batería.	Vehicle Model, Battery Capacity (kWh), Vehicle Age (years).
Contexto de carga	Describe el comportamiento de carga del vehículo, como por ejemplo si el hecho ocurrió en el hogar con una conexión	Charger Type, Charging Rate (kW), Charging Duration (hours).


	domestica de 110v - 240v o en estaciones de carga rapida.	
Estado de la carga	Se refiere al estado inicial y posterior de la carga de la bateria del vehiculo.	Start %, End %.
Entorno y comportamiento	Caracteristicas relacionadas con el entorno como la temperatura exterior del vehiculo, distancia recorrida antes de la sesion de carga y el tipo de usuario.	Temperature (°C), Distance Driven, User Type.

Fuente: Elaboración propia

5.1.2. Distribución de la variable objetivo

La distribución de la variable objetivo presenta un rango entre 0.05 y 152 kWh, con una mediana aproximada de 42.7 kWh y una marcada asimetría positiva. Se identificaron valores atípicos en los extremos: sesiones fallidas (<1 kWh) y consumos muy elevados (>120 kWh).

Figura 16. Distribución de la variable objetivo



Fuente: Elaboración propia

La gráfica confirma que la mayoría de las sesiones se concentran entre 20 y 60 kWh, con una cola larga hacia la derecha. Esto refleja que el consumo energético no sigue una distribución normal, sino una distribución sesgada positiva. Los valores extremos corresponden a sesiones anómalas, a vehículos con baterías de gran capacidad o el tipo de carga ya sea de domiciliar o de estación de carga rápida.

5.1.3. Correlaciones

El análisis de correlación muestra que no existen relaciones lineales fuertes entre *Energy Consumed* y las demás variables. Esto implica que la dinámica del consumo está dominada por relaciones no lineales, lo que orienta hacia la necesidad de modelos más sofisticados para capturar interacciones complejas

Figura 17. Mapa de correlaciones

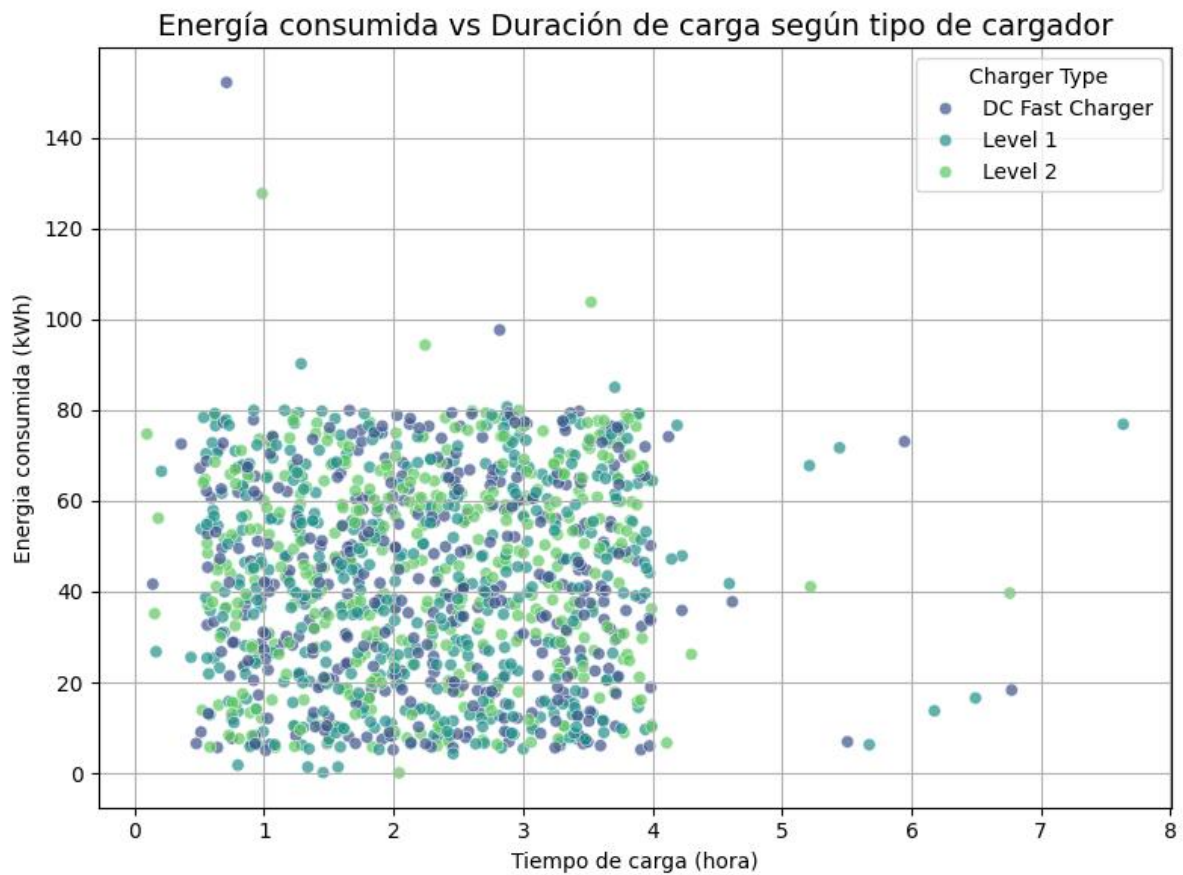


Fuente: Elaboración propia

5.1.4. Distribución de los datos

El siguiente grafico muestra la distribución de las sesiones de carga según tipo de cargador utilizado, entre los cuales están domiciliarios (110v - 240v) y de carga rapida (DC).


Figura 18. Diagrama de dispersión sobre datos de tipo de cargador



Fuente: Elaboración propia

Para los fines de esta investigación, el análisis se centra exclusivamente en el comportamiento de carga en el hogar, restringido al uso de cargadores Level 1 y Level 2. La inclusión de sesiones de DC Fast charging no resulta pertinente, ya que introduce ruido en lugar de aportar claridad al fenómeno estudiado, debido a que operan en un contexto completamente diferente. A continuación se muestra el mismo gráfico pero incluyendo únicamente los tipos de cargas pertinentes a este estudio.

Figura 19. Diagrama de dispersión sobre tipos de cargador seleccionados



Fuente: *Elaboración propia*

El análisis de los patrones de carga muestra diferencias claras entre los distintos tipos de cargadores. Por ejemplo, los cargadores de tipo 1 (110v) presentan una pendiente muy plana en la relación entre energía consumida y duración de la carga. Esto significa que entregan energía de manera lenta, requiriendo sesiones prolongadas de varias horas para acumular cantidades moderadas de kWh. En contraste, los cargadores tipo 2 (240v) muestran una pendiente mucho más pronunciada, lo que refleja una mayor capacidad de entrega de energía por unidad de tiempo.

5.2. Limpieza de datos

La calidad de los datos constituye un factor determinante en la validez de cualquier modelo predictivo. En el contexto de este estudio sobre consumo energético en sesiones de carga de vehículos eléctricos, se identificaron diversas fuentes de ruido y valores anómalos que requieren ser tratados antes de la fase de

modelado. El proceso de limpieza de datos se desarrolló bajo los siguientes lineamientos:

5.2.1. Filtrado por Alcance (Scope Filtering)

Se mantuvieron únicamente las sesiones de carga con cargadores Level 1 y Level 2, excluyendo aquellas correspondientes a DC Fast, dado que el foco de la investigación se limita al comportamiento de carga en el hogar.

5.2.2. Valores atípicos y extremos

La variable objetivo presentó consumos anormalmente bajos (<1 kWh) y extremadamente altos (>120 kWh). Los primeros suelen corresponder a sesiones abortadas o fallidas, mientras que los segundos, aunque posibles en baterías de gran capacidad, se consideran sospechosos y requieren verificación. La decisión metodológica adoptada consistió en:

- ⇒ **Excluir valores menores a 1 kWh**, por su baja representatividad.
- ⇒ **Mantener los valores altos solo cuando se verifican coherentes** con la capacidad de batería reportada.

5.2.3. Consistencia entre variables

Se aplicaron reglas de validación cruzada para garantizar consistencia entre campos. Por ejemplo, el consumo de energía (`Energy Consumed`) no puede superar la capacidad de la batería (`Battery Capacity`). Asimismo, se verificó que `End %` sea mayor que `Start %` en la mayoría de los casos, salvo sesiones interrumpidas.

5.2.4. Manejo de valores faltantes

Los valores faltantes fueron abordados mediante técnicas de imputación con el objetivo de conservar la mayor cantidad posible de información y mantener la calidad del conjunto de datos. Para ello, se estimaron los datos ausentes utilizando la información disponible y aplicando métodos adecuados según el tipo y comportamiento de cada variable.

Cuando fue factible, se recurrió a estimaciones fundamentadas en el conocimiento del dominio para obtener valores consistentes con la realidad del

sistema. En los casos restantes, se aplicaron métodos estadísticos simples, como el uso de la media o la mediana, garantizando así un conjunto de datos completo, coherente y útil para el análisis posterior.

5.2.5. Normalización de unidades

Se verificó la consistencia en las unidades de medida: kWh para energía, kW para potencia y °C para temperatura. Esta revisión permitió evitar inconsistencias derivadas de conversiones erróneas o registros heterogéneos.

5.3. Ingeniería de características

5.3.1. Calculo de estado de la carga (State of Charge)

En esta etapa se implementó una de las transformaciones más relevantes del proceso de feature engineering: la creación de la variable SoC_diff, definida como la diferencia entre el estado de carga final y el inicial de la batería durante una sesión de carga.

$$\Delta\text{SoC} = \text{SoC}_f - \text{SoC}_i$$

Donde:

ΔSoC : Cambio en el Estado de Carga (la diferencia).

SoC f : Estado de Carga final (final/end).

SoC i : Estado de Carga inicial (initial/start).

Esta nueva característica permite cuantificar directamente el incremento en el estado de carga de la batería, proporcionando una representación más explícita del proceso de carga. Además de su utilidad para el modelado predictivo, SoC_diff facilita el análisis exploratorio al ofrecer una medida intuitiva de la cantidad de energía almacenada durante cada sesión.

Previo a su utilización, se llevó a cabo una verificación de calidad de datos para asegurar que los valores de SoC_diff se mantuvieran dentro de un rango físicamente plausible (0 % a 100 %). Cualquier valor fuera de este rango fue tratado como dato faltante para evitar sesgos en los procesos posteriores.

5.3.2. Estimación de energía consumida según el estado de la carga

Para facilitar la precisión del modelo se crea la variable derivada `Energy_est_SoC` la cual representa la energía estimada necesaria para aumentar el nivel de carga. Es una aproximación directa del consumo esperado y el predictor más importante del modelo.

La estimación de la energía consumida a partir del cambio en el estado de carga (`Energy_est_SoC`) se basa en principios descritos en estudios sobre gestión y modelado del SoC en baterías de vehículos eléctricos (Hannan et al., 2017).

Con el objetivo de estimar de forma teórica cuánta energía debería haberse consumido durante una sesión de carga se utiliza la siguiente fórmula.

$$\text{Energy_est_SoC} = \text{Battery Capacity (kWh)} \times (\text{SoC_diff} / 100)$$

Donde:

Battery Capacity (kWh): Capacidad total de la batería del vehículo.

SoC_diff: Diferencia entre el estado de carga final e inicial.

5.3.3. Unidad de eficiencia energética

Energy_per_SoC (*Energy per State of Charge unit*) es una variable derivada que mide la cantidad de energía consumida por cada punto porcentual de incremento en el estado de carga (*State of Charge*, SoC) de la batería. A diferencia de `Energy_est_SoC`, que estima el consumo total esperado, esta métrica se enfoca en la eficiencia energética específica del proceso de carga y su fórmula es.

$$\text{Energy_per_SoC} = \text{Energy Consumed (kWh)} / \text{SoC_diff}$$

La variable `Energy_per_SoC` se utiliza como un indicador de eficiencia energética específica, expresando el consumo por unidad de cambio en el estado de carga, en línea con enfoques descritos por Hu et al. (2016) en el análisis energético de sistemas de almacenamiento.

5.3.4. Cálculo de la potencia promedio suministrada

Con el fin de calcular la potencia promedio suministrada al vehículo eléctrico durante una sesión de carga se crea una característica $Power_proxy$ (*Proxy for Average Charging Power*). La variable $Power_proxy$ se utiliza como estimador de la potencia promedio suministrada durante la sesión de carga, ofreciendo información relevante sobre la dinámica temporal del proceso, en consonancia con enfoques propuestos por Zhang et al. (2018).

$$Power_{proxy} = \frac{E_{\Delta SoC}}{\Delta t_{charge}}$$

Donde:

$E_{\Delta SoC}$: Energía estimada requerida para lograr el incremento de carga.

Δt_{charge} : Tiempo total de la sesión de carga en horas.

Aunque esta característica no representa directamente una medición de potencia real del cargador, sirve como aproximación útil del perfil energético medio, capturando la relación entre energía transferida y tiempo de carga.

5.3.5. Eficiencia de carga

La variable $Charge_Efficiency$ cuantifica el rendimiento energético del proceso de carga, al comparar la energía real suministrada con la energía estimada teórica, siguiendo criterios similares a los empleados por Zou et al. (2015) en el análisis de eficiencia de baterías.

$$\eta_{charge} = \frac{E_b}{E_g}$$

Donde

E_b : Energía real suministrada durante la sesión.

E_g : Energía teórica requerida para el incremento del estado de carga.

5.3.6. Imputación de variable objetivo

Para completar los valores faltantes en *Energy Consumed* (kWh), se estimaron los datos a partir de la relación entre la capacidad de la batería y el aumento en su nivel de carga. Esta estimación se calculó mediante la siguiente expresión.

$$E_c = C \times \frac{\Delta\text{SoC}}{100}$$

Donde:

E_c : Energía consumida

C : Es la capacidad total de la batería en kilovatios-hora (kWh).

ΔSoC : Diferencia en el estado de carga (State of Charge), en puntos porcentuales.

Cuando fue posible, se aplicó este método por reflejar de forma sencilla y coherente el comportamiento real del sistema. En los casos donde faltaba información clave, se utilizaron técnicas estadísticas básicas, como la imputación con la media, para mantener la consistencia del conjunto de datos.

5.4. Entrenamiento de modelos

Para la etapa de modelado se implementaron diferentes modelos de regresión lineal, refuerzo de gradients y un enfoque de red neuronal multicapa (MLP, Multilayer Perceptron), esta última fue seleccionada por su capacidad para capturar relaciones no lineales complejas entre las variables predictoras y la variable objetivo *Energy Consumed* (kWh).

La metodología de propuesta de solución incorpora un pipeline completo que incluye limpieza con coherencia física, ingeniería de características, selección de variables y un modelo de red neuronal (MLP), finalmente después de aplicar y evaluar los modelos anteriores se confirma que MLP ofrece un mejor resultado R^2 y un margen de error (MAE) menor. A continuación se detalla el procedimiento seguido.

5.4.1. División del conjunto de datos

Se dividió el conjunto de datos en dos subconjuntos utilizando la regla de 80/20 en donde:

Entrenamiento: 80 % de las observaciones.

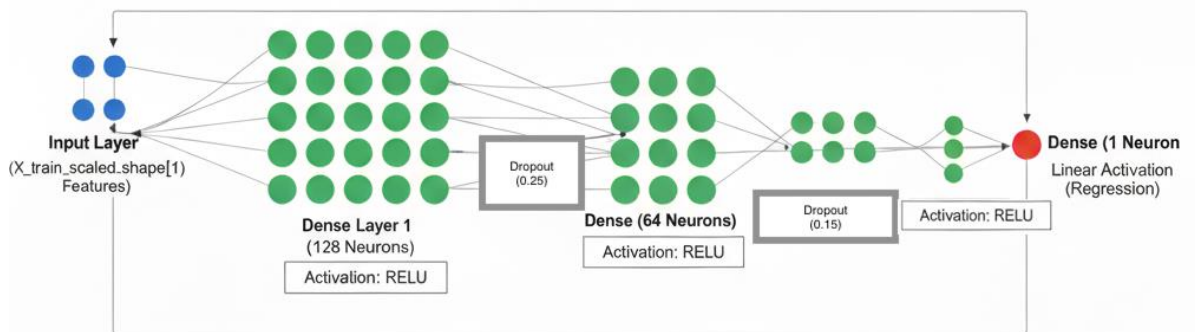
Prueba: 20 % restante, reservado exclusivamente para la evaluación final del modelo.

5.4.2. Estandarización de variables

Antes del entrenamiento, todas las características numéricas fueron escaladas mediante la técnica StandardScaler, centrando los datos en media cero y varianza unitaria. Esto mejora la convergencia del algoritmo y evita que variables con magnitudes mayores dominen el proceso de aprendizaje.

5.4.3. Arquitectura del modelo

Figura 20. Arquitectura de MLP



Fuente: Elaboración propia

5.4.3.1. Estructura

El modelo consta de 5 capas secuenciales de procesamiento: tres capas ocultas densas y una capa de salida.

Tabla 7. Elementos del modelo de red neuronal.

Capa	Neuronas	Activación	Propósito
Capa de Entrada/Oculta 1	128	ReLU	Primera etapa de extracción de características. input_shape indica el número de características de entrada.
Capa Oculta 2	64	ReLU	Reduce la dimensionalidad de las características extraídas.
Capa Oculta 3	32	ReLU	Mayor reducción de dimensionalidad para preparar la salida.

Capa de Salida	1 (Ninguna)	Produce la predicción final. Una sola neurona sin función de activación es estándar para problemas de regresión lineal.
-----------------------	-------------	---

Fuente: Elaboración propia

5.4.3.2. Parametros de entrenamiento

- ⇒ Optimizador (optimizer="adam"). Se utiliza el algoritmo Adam (Adaptive Moment Estimation). Es la opción predeterminada más popular debido a su eficiencia computacional y su capacidad para converger rápidamente adaptando la tasa de aprendizaje para cada peso de la red.
- ⇒ Función de Pérdida (loss="mse"). Se utiliza el Error Cuadrático Medio (Mean Squared Error). Esta es la función de pérdida estándar para problemas de regresión, ya que mide la diferencia cuadrática promedio entre los valores predichos y los valores reales, penalizando más los errores grandes.
- ⇒ Métricas (metrics=["mae"]). Se mide el Error Absoluto Medio (Mean Absolute Error). Esta métrica es más interpretable que el MSE, ya que representa la magnitud promedio de los errores en las mismas unidades que la variable de salida.

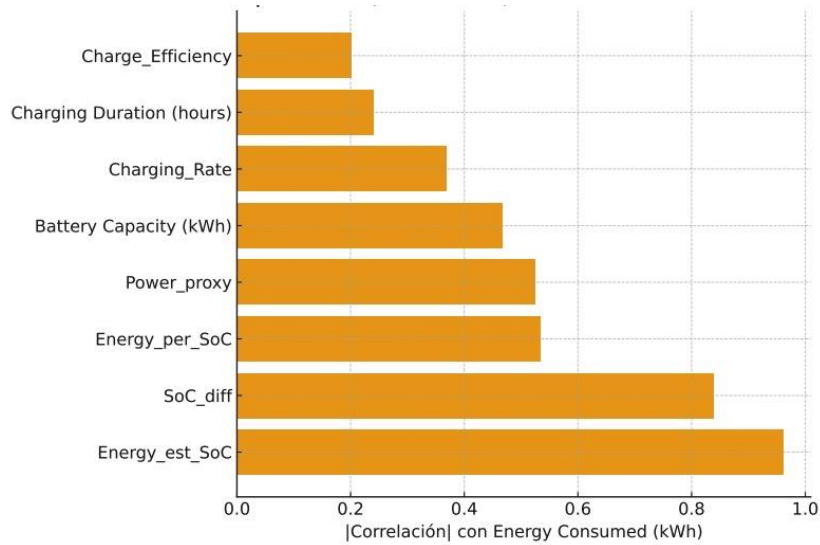
5.4.3.3. Detención temprana (Early Stopping)

Se implementó un mecanismo de validación temprana que interrumpe el entrenamiento si la pérdida no mejora tras un número definido de iteraciones. Esto previene el sobreajuste (overfitting) y mejora la capacidad de generalización.

5.4.3.4. Selección de variables

Para el entrenamiento se seleccionaron las características que presentan mayor correlación incluyendo las variables derivadas que fueron creadas como parte de la optimización del conjunto de datos.

Figura 21. Variables principales



Fuente: Elaboración propia

5.4.3.5. Evaluación del modelo

El desempeño fue evaluado con métricas estándar de regresión las cuales se muestran a continuación.

Tabla 8. Métricas de desempeño

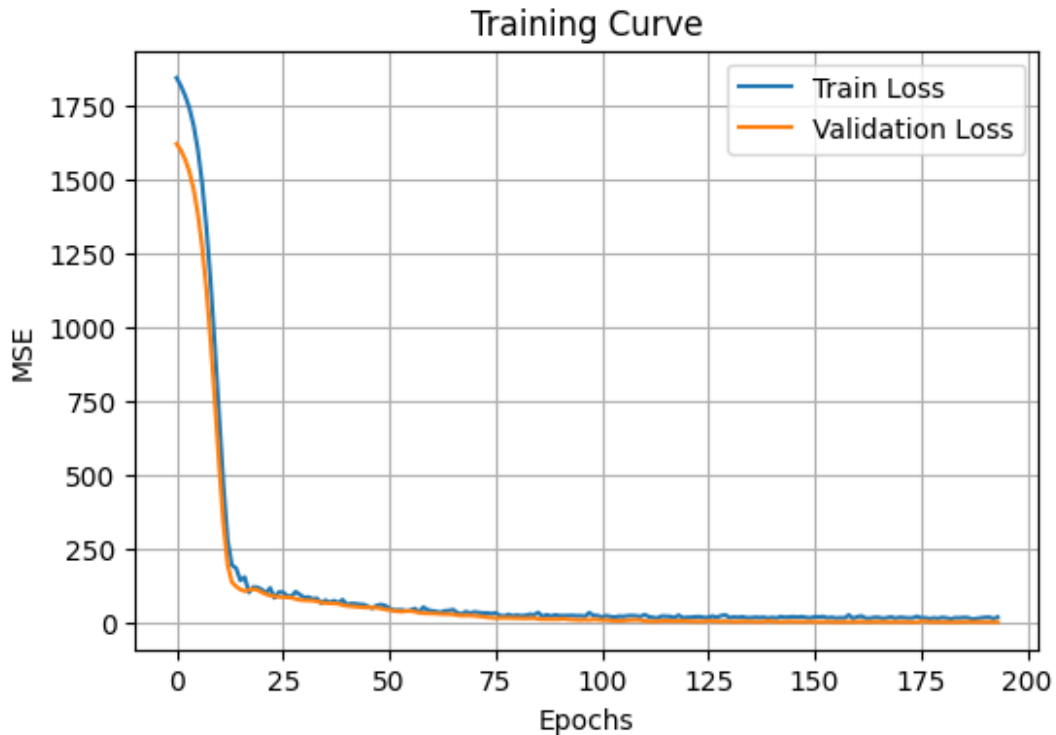
Metrica	Resultado
MAE (Error Absoluto Medio)	1.53 kWh
RMSE (Raíz del Error Cuadrático Medio)	2.12 kWh
R² (Coeficiente de Determinación)	0.987

Fuente: Elaboración propia

En el modelo final de red neuronal (MLP) utilizado para predecir Energy Consumed (kWh), la curva de aprendizaje mostró un descenso constante en la pérdida tanto en entrenamiento como en validación y una posterior estabilización con diferencias mínimas entre ambas. Lo cual demuestra que el modelo logró un equilibrio adecuado entre ajuste y aprendizaje, evitando tanto el sobreajuste como el

subajuste. La implementación de early stopping fue clave para detener el entrenamiento en el punto óptimo y prevenir el sobreentrenamiento.

Figura 22. Curva de aprendizaje



Fuente: Elaboración propia

Finalmente se muestra un ejemplo de predicción del modelo de red neuronal.

Tabla 9. Ejemplo: Datos de entrada

<i>Variable</i>	<i>Valor</i>	<i>Descripción</i>
<i>Energy_est_SoC</i>	57.45 kWh	Energía estimada según el incremento del estado de carga (SoC).
<i>SoC_diff</i>	57.45 %	Diferencia entre el estado de carga final e inicial de la batería.
<i>Energy_per_SoC</i>	1.0589 kWh/%	Energía consumida por cada punto porcentual de carga añadida.
<i>Power_proxy</i>	16.07 kW	Potencia media aproximada durante la sesión de carga.
<i>Battery Capacity (kWh)</i>	100.0 kWh	Capacidad total de la batería del vehículo.
<i>Charging_Rate</i>	16.07 %/h	Tasa promedio de carga por hora.
<i>Charging Duration (hours)</i>	3.57 h	Duración total de la sesión de carga.
<i>Charge_Efficiency</i>	1.0589	Relación entre la energía real consumida y la energía teórica estimada.
<i>Energía estimada (Output)</i>	60.79 kWh	Valor predicho por la red neuronal: energía total consumida en la sesión.

5.5. Comparación de modelos

Con el objetivo de estimar con precisión la variable objetivo *Energy Consumed (kWh)*, se implementaron y evaluaron distintos enfoques de modelado supervisado: Regresión Lineal, XGBoost y Redes Neuronales Artificiales (ANN). Cada uno de estos modelos presenta características particulares en cuanto a complejidad, capacidad de aprendizaje y desempeño predictivo, lo que permitió realizar un análisis comparativo exhaustivo.

El modelo final basado en redes neuronales alcanzó resultados significativamente superiores en comparación con otros enfoques tradicionales:

Tabla 10. Comparativa de modelos

<i>Modelo</i>	<i>MAE (kWh)</i>	<i>RMSE (kWh)</i>	<i>R²</i>
<i>Regresión Lineal</i>	18.78	21.81	-0.005
<i>XGBoost</i>	21.06	25.63	-0.387
<i>Red Neuronal (MLP, final)</i>	1.58	2.12	0.987

Fuente: Elaboración propia

Estos resultados evidencian una mejora sustancial tanto en precisión como en capacidad explicativa, con un aumento drástico del coeficiente de determinación y una reducción del error absoluto medio en más del 90 % respecto a modelos previos.

5.5.1. Regresión Lineal.

Este modelo representa el enfoque más sencillo, basado en relaciones lineales entre las variables predictoras y la variable objetivo. Su principal ventaja es la interpretabilidad y la rapidez en el entrenamiento. Sin embargo, debido a la naturaleza no lineal del proceso de carga de vehículos eléctricos y la interacción compleja entre variables como *SoC_diff*, *Battery Capacity* o *Charging Duration*, su capacidad predictiva fue limitada. El modelo obtuvo un coeficiente de determinación (R^2) cercano a 0, lo que indica que apenas logró explicar la variabilidad de la energía consumida.

5.5.2. XGBoost.

Como alternativa más avanzada, se aplicó un modelo basado en *gradient boosting*, el cual combina múltiples árboles de decisión para capturar interacciones no lineales y efectos complejos entre las variables. A pesar de mejorar ligeramente la capacidad predictiva respecto a la regresión lineal, el modelo no alcanzó un rendimiento satisfactorio ($R^2 \approx -0.38$). Este resultado sugiere que, aunque XGBoost maneja no linealidades, su desempeño se ve afectado por el nivel de ruido presente en los datos y la ausencia de ciertas relaciones físicas explícitas en las variables originales.

5.5.3. Redes Neuronales Artificiales (ANN).

Finalmente, se implementó un modelo basado en redes neuronales profundas, acompañado de un proceso integral de *feature engineering*, imputación basada en relaciones físicas y limpieza de datos orientada a garantizar la coherencia electroquímica. Este enfoque permitió capturar patrones complejos y no lineales asociados al comportamiento del proceso de carga. El modelo alcanzó un rendimiento significativamente superior, con un error absoluto medio (MAE) de 1.58 kWh y un coeficiente de determinación (R^2) de 0.987, demostrando una capacidad predictiva notable y una alta concordancia con los valores reales observados.

En conclusión, la comparación evidencia que, si bien los modelos tradicionales ofrecen ventajas en interpretabilidad y simplicidad, el uso de redes neuronales profundas, en conjunto con una adecuada preparación de datos y generación de variables derivadas, resulta claramente superior para predecir el consumo energético durante el proceso de carga. Esto confirma que la complejidad inherente a este fenómeno requiere modelos con mayor capacidad de representación no lineal para lograr predicciones precisas y consistentes.

5.6. Aplicación y calculo final

La Autoridad Reguladora de los Servicios Públicos (ARESEP) es la institución responsable de establecer y aprobar las tarifas de electricidad en Costa

Rica. En el caso del servicio residencial, la metodología tarifaria se fundamenta en principios de recuperación de costos, eficiencia económica y equidad social. En el mercado energético costarricense el consumo eléctrico residencial se mide según los Kilovatios por hora consumidos, para dicha investigación se utiliza el tarifario impuesto por la ARESEP para el periodo de 2024-2025, debido a que sus tarifas son fluctuantes se aclara en este documento que los precios y cálculos realizados pueden sufrir cambios posteriores a la publicación de este documento.




5.6.1. Lectura y consumo medido

El punto de partida es la lectura mensual del medidor eléctrico, que registra el consumo de energía en kilovatios hora (kWh). Este valor representa la cantidad de energía demandada por el hogar durante el periodo mensual de facturación.

5.6.2. Bloques de consumo

Independientemente de la compañía que provee el servicio energético ARESEP aprueba esquemas de bloques tarifarios progresivos. Bajo este sistema, los primeros kWh consumidos se cobran a una tarifa más baja, mientras que los bloques superiores aplican precios más altos.

Figura 23. Tarifario por bloque de consumo

Tarifas eléctricas		Tarifa Residencial T-RE		Tarifa Residencial Prepago T-RP	
Tarifa Residencial Horaria T-REH		Bloque de 0-30 kWh Cargo fijo		Bloque de 0-30 kWh Cargo fijo	
Consumo de 0 a 500 kWh		Cada kWh		Cada kWh	
Punta	₡156,96	Cada kWh		Cada kWh	
Valle	₡64,34	Cada kWh		Cada kWh	
Nocturno	₡26,94	Cada kWh		Cada kWh	
Consumos mayores a 501 kWh		Bloque de 201-300 kWh Cada kWh		Bloque de 201-300 kWh Cada kWh	
Punta	₡194,09	Cada kWh		Cada kWh	
Valle	₡78,33	Cada kWh		Cada kWh	
Nocturno	₡36,26	Cada kWh		Cada kWh	
Definición de periodos		Bloque mayor a 300 kWh Cada kWh adicional		Bloque mayor a 300 kWh Cada kWh adicional	
 Punta de 10:01 a 12:30 pm y de 17:31 a 20:00		 Valle De 6:01 a 10:00 y de 12:31 a 17:30		 Nocturno de 20:01 a 6:00	

Fuente: Comisión Nacional de Fuerza y Luz, Costa Rica.

5.6.3. Cargos fijos y variables

La tarifa residencial incluye dos componentes principales:

- ⇒ Cargo fijo mensual: cubre costos de disponibilidad del servicio, operación y mantenimiento de la red.
- ⇒ Cargo por energía: se calcula multiplicando el consumo (kWh) por la tarifa correspondiente al bloque en el que se ubique el usuario.

5.6.4. Tarifas horarias

En ciertos casos, ARESEP ha autorizado la implementación de tarifas horarias residenciales, en las que el precio de la energía varía según la franja del día:

- ⇒ Punta: horas de mayor demanda, con costo más alto.
- ⇒ Valle: horas intermedias, con costo moderado.
- ⇒ Nocturno: horas de baja demanda, con costo reducido.

Figura 24. Tarifario residencial horaria

Tipo de tarifa	DescripcionTarifa	Bloque	Tarifa
<input type="checkbox"/> T-REH	<input type="checkbox"/> Residencial horaria	Periodo Noche	76.45
		Periodo Punta	152.53
		Periodo Valle	104.80

Fuente: Autoridad Reguladora de los Servicios Públicos (ARESEP)

5.6.5. Impuestos y cargos adicionales

Al monto calculado se le aplican los impuestos vigentes (como el Impuesto al Valor Agregado – IVA), así como otros cargos aprobados por ARESEP para financiar programas específicos del sector eléctrico.

La factura mensual final se determina al sumar:

1. El cargo fijo.
2. El cargo por energía consumida según el bloque tarifario.
3. Los impuestos y recargos aplicables.

Este modelo asegura que los usuarios paguen en proporción a su consumo y que los ingresos del sistema reflejen los costos reales de prestación del servicio eléctrico (Autoridad Reguladora de los Servicios Públicos (ARESEP), 2025).

5.7. Simulador de tarifas (prototipo)

Como parte de la propuesta metodológica, se ha desarrollado un simulador de tarifas orientado a estimar de forma precisa el costo asociado a las sesiones de carga de vehículos eléctricos en un entorno residencial. Esta herramienta, diseñada con un enfoque centrado en el usuario, se basa en una base de datos actualizada con información de vehículos eléctricos disponibles en el mercado para el año 2025, lo que garantiza su relevancia y aplicabilidad en contextos reales.

El simulador considera como entradas principales los siguientes datos:

- ⇒ Modelo del vehículo: a partir del cual, mediante inferencia y vinculación con la base de datos, se obtiene información técnica relevante del fabricante, incluyendo capacidad de batería y parámetros de consumo energético.
- ⇒ Estado de carga de la batería: representa el porcentaje de carga inicial y final del vehículo antes y después de la sesión de recarga.
- ⇒ Duración de la sesión de carga: tiempo total requerido para completar el proceso de recarga, expresado en horas.

Estos datos constituyen la base para el cálculo automatizado del costo total de la sesión de carga, el cual se presenta en colones costarricenses considerando la estructura tarifaria residencial vigente aprobada por la Autoridad Reguladora de los Servicios Públicos (ARESEP).

5.7.1. Diseño de la aplicación

Un ejemplo del prototipo de la herramienta se muestra en la siguiente figura:

Figura 25. Prototipo de herramienta de simulación 1

EV Charge Estimator
Mobile wireframe

EV model
Nissan LEAF

Charge range 20% → 85%

Start charge
0% 100%

End charge
20% 100%

Duration (hours, minutes)

Hours: 4 Minutes: 30

Submit Reset

Wireframe only — no calculations yet. Replace placeholders with your logic.

Fuente: Elaboración propia

La herramienta proporciona al usuario información detallada sobre el costo total de la sesión de carga, el bloque tarifario aplicable y otros indicadores energéticos relevantes derivados del modelo de inteligencia artificial utilizado en el proceso de estimación.

Figura 26. Prototipo de página de resultados del simulador



Fuente: Elaboración propia

5.7.2. Alcances

⇒ La aplicación ofrece un catálogo de vehículos eléctricos basado en información recopilada desde portales de venta oficiales y fuentes técnicas confiables.

- ⇒ El simulador utiliza datos de entrada fácilmente accesibles para el usuario final, lo que facilita su uso sin requerir conocimientos técnicos avanzados.
- ⇒ Los resultados generados incluyen el costo total de la sesión de carga expresado en colones costarricenses e incorporan el bloque tarifario residencial correspondiente.

5.7.3. Limitaciones

- ⇒ El simulador no contempla el sistema tarifario basado en prepago ni la facturación por franjas horarias, limitando su aplicación a esquemas tarifarios estándar.
- ⇒ El modelo de inteligencia artificial se enfoca exclusivamente en escenarios de carga residencial de baja potencia, excluyendo cargadores de carga rápida (DC Fast) utilizados en entornos comerciales.
- ⇒ La base de datos de vehículos eléctricos está restringida a aquellos modelos para los cuales se pudo obtener información técnica detallada, lo que podría limitar el alcance del simulador frente a la totalidad del mercado.

CAPÍTULO 6. Conclusiones y Recomendaciones

Esta investigación revela la posibilidad de predecir y calcular el consumo energético de los vehículos eléctricos, los cuales representan una población significativa en la flota vehicular. Sin embargo, su crecimiento es exponencial y, en conjunto con políticas fiscales e incentivos comerciales, es probable que la demanda de estaciones de carga aumente. Dada la escasez de estas estaciones a lo largo del país, el propósito de este estudio es mostrar a los usuarios la facilidad y factibilidad de utilizar la energía doméstica para dicho fin.

6.1. Conclusiones

Al finalizar la investigación, se concluye lo siguiente:

6.1.1. Integración efectiva de la IA en la predicción del consumo energético.

El estudio confirma que tanto los modelos de aprendizaje automático como las redes neuronales artificiales ofrecen una alta capacidad predictiva sobre el consumo energético durante la carga de los vehículos eléctricos. Dicha implementación permite anticipar patrones de demanda y optimizar el uso de la red energética residencial, lo que facilita una mejor utilización de los recursos.

6.1.2. Relevancia del contexto costarricense en la modelación de datos.

Aunque la base de datos proviene del mercado estadounidense, la adaptación metodológica y la calibración de las variables derivadas permiten obtener resultados positivos y extrapolables al contexto costarricense. Este proceso demuestra la posibilidad de importar metodologías internacionales al ámbito local, desarrollando una contextualización correcta de los parámetros.

6.1.3. Impacto económico para los usuarios residenciales.

Se identifica que el incremento en el consumo energético doméstico y su efecto en la factura mensual se puede mitigar mediante estrategias de carga

inteligente, dependiendo del sistema tarifario que utilice el usuario (por ejemplo, residencial por horario o por bloques). Dicho análisis se facilita mediante la predicción del consumo energético y del estado de la batería, ya que, según los datos, el consumo será mayor o menor dependiendo del estado de carga inicial. Este análisis se pone a disposición del usuario mediante una herramienta de simulación de carga.

6.1.4. Contribución a la sostenibilidad energética del país.

El estudio integra aspectos tecnológicos, ambientales y socioeconómicos, fortaleciendo la visión de energía sostenible promovida por Costa Rica. Esta investigación respalda los esfuerzos hacia la descarbonización y el fomento de la movilidad eléctrica como pilar del desarrollo sostenible.

6.2. Recomendaciones

Como resultado de esta investigación y a partir de la experiencia adquirida durante el diseño, desarrollo y orquestación de modelos de inteligencia artificial para la predicción del consumo energético y los patrones de carga, se formulan las siguientes recomendaciones:

6.2.1. Ampliación de la base de datos local

Si bien fue posible utilizar datos obtenidos de modelos de carga estadounidenses, se recomienda recopilar información empírica a nivel costarricense sobre el consumo energético en hogares que posean un vehículo eléctrico. Esto permitiría refinar no solo este modelo predictivo, sino también otros, y aumentar la validez de los datos aplicados en el contexto costarricense.

6.2.2. Colaboración con empresas proveedoras de servicios eléctricos para el desarrollo de una herramienta de simulación

Si bien en esta investigación se implementó una aplicación prototipo para integrar el modelo de inteligencia artificial diseñado, se recomienda establecer alianzas estratégicas con las principales empresas distribuidoras de electricidad del país. El objetivo sería co-desarrollar una herramienta de simulación robusta,

orientada a la educación del usuario final y a la difusión de buenas prácticas en materia de carga eficiente y consumo responsable de energía.

6.2.3. Extensión del modelo a nuevos ámbitos de estudio

Dado que el alcance del presente estudio se limitó a vehículos livianos, recarga residencial y tarifas eléctricas por bloques, se sugiere ampliar la investigación para incluir flotas de transporte público e institucional eléctrico. Asimismo, se recomienda realizar un análisis comparativo entre las distintas zonas geográficas del país y los regímenes tarifarios vigentes. Esta expansión permitiría enriquecer el modelo, generar hallazgos más diversos y aumentar su aplicabilidad en múltiples escenarios de movilidad sostenible.

CAPÍTULO 7. Reflexiones finales

La presente investigación ha permitido explorar, el impacto que la adopción de vehículos eléctricos puede tener en el consumo energético residencial costarricense. A partir del análisis de datos, la revisión de literatura especializada y la planificación de desarrollo de un modelo predictivo basado en inteligencia artificial, se ha descubierto evidencia valiosa que contribuye al debate sobre la viabilidad técnica, económica y ambiental de la movilidad eléctrica en el país.

Otro aspecto relevante es que la transición hacia la electromovilidad en Costa Rica aún cuenta con desafíos en infraestructura de carga y cobertura informativa. Esto representa una oportunidad para consolidar un modelo de inteligencia artificial, que aproveche la información disponible en el mercado sobre los vehículos eléctricos y sus impactos ambientales, económicos y culturales con el objetivo de informar a la población y que estos puedan tomar una decisión más informada con respecto a la adquisición de un vehículo eléctrico.

CAPÍTULO 8. Glosarios

Autonomía: Distancia máxima que puede recorrer un vehículo eléctrico con una carga completa de su batería. Se expresa en kilómetros y depende de factores como la capacidad de la batería, la eficiencia del motor y las condiciones de conducción.

Capacidad de batería: Cantidad de energía que puede almacenar la batería de un vehículo eléctrico, medida normalmente en kilovatios-hora (kWh).

Carga rápida: Proceso de recarga de la batería de un vehículo eléctrico que emplea potencias elevadas (generalmente superiores a 22 kW) para reducir el tiempo necesario de carga (International Electrotechnical Commission, 2017).

Carga lenta: Método de recarga de la batería que emplea potencias más bajas (habitualmente inferiores a 3,7 kW), con tiempos de carga prolongados (International Electrotechnical Commission, 2017).

Inteligencia artificial (IA): Rama de la informática que estudia y desarrolla sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje, la percepción y la toma de decisiones (Russell & Norvig, 2021).

Modelo predictivo: Algoritmo o sistema diseñado para estimar valores futuros o desconocidos a partir de datos históricos y patrones detectados (Han et al., 2022).

Movilidad eléctrica: Conjunto de medios de transporte impulsados total o parcialmente por energía eléctrica, incluyendo vehículos eléctricos de batería, híbridos enchufables y de pila de combustible (Agencia Internacional de Energía, 2022).

Patrones de carga: Comportamientos repetitivos en los horarios, frecuencia y duración de la recarga de un vehículo eléctrico.

PIA-02: Curso de la Maestría en Ingeniería del Software con énfasis en Inteligencia Artificial Aplicada, en el cual se desarrollará y entrenará el modelo propuesto en esta investigación.

Simulador: Herramienta de software que reproduce de manera interactiva el funcionamiento o comportamiento de un sistema real para su análisis o experimentación.

Tarifa dinámica: Modalidad de cobro por el consumo eléctrico en la que el precio varía según el horario (horas valle y horas pico) y la demanda de energía.

Vehículo eléctrico (EV): Automóvil que funciona total o parcialmente con energía eléctrica almacenada en baterías recargables, prescindiendo total o parcialmente del uso de combustibles fósiles (Agencia Internacional de Energía, 2022).

CAPÍTULO 9. Referencias

- Agencia Europea del Medio Ambiente. (2018). Electric vehicles from life cycle and circular economy perspectives. EEA Report.
<https://www.eea.europa.eu/en/analysis/publications/electric-vehicles-from-life-cycle>
- Agencia Internacional de Energía. (2022). Global EV Outlook 2022.
<https://www.iea.org/reports/global-ev-outlook-2022>
- Arias, F. (2012). El proyecto de investigación: Introducción a la metodología científica (6.ª ed.). Editorial Episteme.
- Autoridad Reguladora de los Servicios Públicos (ARESEP). (2025, June 17). Tarifas vigentes de electricidad - ARESEP. ARESEP
<https://aresep.go.cr/electricidad/tarifas/>
- Baggio, Jacopo. (2017). Complex Adaptive Systems, Simulations and Agent-based Modeling.
- Banco Interamericano de Desarrollo. (2023). Electromovilidad en América Latina y el Caribe: avances y perspectivas. Publications IADB.
<https://publications.iadb.org/publications/spanish/document/Hacia-una-integracion-sostenible-el-potencial-de-la-electromovilidad-en-America-Latina-y-el-Caribe.pdf>
- Banister, D. (2005). Unsustainable Transport: City Transport in the New Century. Routledge.
- Barahona Carmona, L. E. (10 de Febrero de 2025). Movilidad eléctrica en Costa Rica: Oportunidades para una sociedad descarbonizada. Avances 2020–

2024. Obtenido de Ministerio de Planificación Nacional y Política Económica.:

<https://documentos.mideplan.go.cr/share/s/GW2p8OrYR7yCV6y0Cj-qTw>

Bayomi, G., Hamdy, A., Hasheem., M., Ali, A. (2023). Prediction of Smart Grid Stability Utilizing Machine Learning Algorithms. 2023 International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC), Cairo, Egypt, pp. 1-6, doi: 10.1109/MIUCC58832.2023.10278320.

Bernal, C. A. (2010). Metodología de la investigación (3.^a ed.). Pearson.

BloombergNEF (BNEF). (2023). Electric Vehicle Outlook 2023.

<https://about.bnef.com/electric-vehicle-outlook/>

Breetz, H. L., Mildenerger, M., & Stokes, L. C. (2021). The political logics of clean energy transitions. *Business and Politics*, 23(1), 1–28.

doi:10.1017/bap.2018.14

Christensen, T. H., Friis, F., & Skjølsvold, T. M. (2017). Changing practices of energy consumption: The influence of smart grid solutions in households.

NTNU. <https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/2466857>

CNFL. (2024). Interprete su factura residual. CNFL.

<https://www.cnfl.go.cr/interes/servicio-electrico/interprete>

Comisión Nacional de Fuerza y Luz (CNFL). (2025, October 13). Tarifas vigentes.

<https://www.cnfl.go.cr/servicios/electricos/inmuebles/tramites/tarifas>

Comisión Europea. (2023). Smart grids and the energy transition. IEF.

<https://www.ief.org/news/smart-grids-support-the-energy-transition-heres-how>

- Díaz-Arrieta, J. P., Valverde, J. R., & Allen, J. (2023). Análisis de perspectivas y políticas públicas enfocadas al transporte público eléctrico modalidad autobús en Costa Rica (2018-2022). *Infraestructura Vial*, 25(44), 28-45.
- Fang, X., Misra, S., Xue, G., & Yang, D. (2011). Smart Grid—The New and Improved Power Grid: A Survey. *IEEE Communications Surveys & Tutorials*, 24(1), 1–30. doi: 10.1109/SURV.2011.101911.00087
- Flick, U. (2012). *Introducción a la investigación cualitativa*. Ediciones Morata.
- Galarza-Linares, Jose, Condezo-Hurtado, David, Saenz-Loayza, Bartolome, & Huarac-Rojas, David. (2021). Evaluación de la red de distribución: conexión del vehículo eléctrico híbrido enchufable. *Revista Tecnología en Marcha*, 34(4), 50-62. <https://dx.doi.org/10.18845/tm.v34i4.5384>.
- Gibbs, G. (2012). *El análisis de datos cualitativos en investigación cualitativa*. Ediciones Morata.
- Han, J., Pei, J., & Kamber, M. (2022). *Data mining: Concepts and techniques (4th ed.)*. Morgan Kaufmann.
- Hannan, M. A., Lipu, M. S. H., Hussain, A., & Mohamed, A. (2017). A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations. *Renewable and Sustainable Energy Reviews*, 78, 834–854. <https://doi.org/10.1016/j.rser.2017.05.001>
- Hernández Sampieri, R., Mendoza Torres, C. P., & Baptista Lucio, M. P. (2022). *Metodología de la investigación (7.ª ed.)*. McGraw-Hill.
- Hernández Sampieri, R., Mendoza Torres, C., & Baptista Lucio, P. (2014). *Metodología de la investigación (6.ª ed.)*. McGraw-Hill Education.

Hidalgo, K. (09 de Enero de 2025). Amelia Rueda. Obtenido de Costa Rica registró en 2024 la mayor cifra de importación de vehículos: se inscribieron más de 470 automotores por día: <https://ameliarueda.com/noticia/flota-vehicular-cifra-importacion-registro-noticias-costa-rica>

Hu, X., Jian, L., Zhang, Y., & Egardt, B. (2016). Battery health prognosis for electric vehicles using sample entropy and Hilbert–Huang transform. *IEEE Transactions on Industrial Electronics*, 63(4), 2645–2656.
<https://doi.org/10.1109/TIE.2016.2518100>

IEEE. (2022). Smart Grid Overview. Institute of Electrical and Electronics Engineers.
<https://smartgrid.ieee.org/>

Instituto de Investigación Tecnológica. (2021). Gestión inteligente de la demanda y patrones de consumo residencial. Universidad Pontificia Comillas.
https://www.iit.comillas.edu/documentacion/revista/IIT-13-131A/Gesti%C3%B3n_de_la_demanda_el%C3%A9ctrica.pdf

International Electrotechnical Commission. (2017). IEC 61851-1: Electric vehicle conductive charging system. IEC.

International Energy Agency. (2022). Charging Infrastructure for Electric Vehicles: A Global Review. IEA. <https://www.iea.org/reports/global-ev-outlook-2022>

IPCC. (2022). Sixth Assessment Report: Mitigation of Climate Change.
<https://www.ipcc.ch/report/ar6/wg3>

Jenkins, J. D., Luke, M., & Thernstrom, S. (2018). Getting to Zero Carbon Emissions in the Electric Power Sector. *Joule*, 5(9), 2450–2467.

Joyokusumo, I., Fatchurrahman, R., Putra, H., Maulana, R. (2020). Performance Evaluation of Naïve-Bayes Classifier in Predicting the Energy Not Served

(ENS) Class of Electric Power Distribution System. 2020 International Conference on Technology and Policy in Energy and Electric Power (ICT-PEP), pp. 214-218, doi: 10.1109/ICT-PEP50916.2020.9249933.

Lopes, J. A. P., Soares, F. J., & Almeida, P. M. R. (2021). Integration of electric vehicles in the electric power system. *Proceedings of the IEEE*, 99(1), 168–183. <https://doi.org/10.1109/JPROC.2010.2066250>

Macal, C. M., & North, M. J. (2021). Agent-based modeling and simulation: An overview. *Complex Adaptive Systems Modeling*, 9(1), 1–14. <https://ieeexplore.ieee.org/document/5429318>

Maharaj, S. (2024). Full Electric Vehicle Dataset 2024. Obtenido de kaggle: <https://www.kaggle.com/datasets/sahirmaharajj/electric-vehicle-population>

Martínez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernández-Orallo, J., & Kull, M. (2019). *Fairness and Discrimination in Machine Learning*. Springer.

Ministerio de Planificación Nacional y Política Económica (MIDEPLAN). (2025). Plan Nacional de Descarbonización de Costa Rica 2020-2050. Gobierno de Costa Rica. <https://cambioclimatico.minae.go.cr/plan-nacional-de-descarbonizacion/>

Mojlish, S. A. K., Sutanto, D., & Muttaqi, K. M. (2025). Impacts of ultra-fast charging of electric vehicles on power grids: State-of-the-art technologies, case studies, and a proposed improvement using a solid-state transformer. *Journal of Energy Storage*, 107, 114913.

Naciones Unidas. (2022). Movilidad sostenible: clave para la Agenda 2030. ONU. <https://sdgs.un.org/es/goals>

- Negri, M., & Bieker, G. (2025). Life-cycle greenhouse gas emissions from passenger cars in the European Union. ICCT.
<https://theicct.org/publication/electric-cars-life-cycle-analysis-emissions-europe-jul25/>
- Organización Mundial de la Salud. (2023). Contaminación del aire y salud urbana.
[https://www.who.int/es/news-room/fact-sheets/detail/ambient-\(outdoor\)-air-quality-and-health](https://www.who.int/es/news-room/fact-sheets/detail/ambient-(outdoor)-air-quality-and-health)
- Programa Estado de la Nación. (2022). Informe Estado de la Nación en Desarrollo Humano Sostenible. https://estadonacion.or.cr/wp-content/uploads/2022/11/PEN_informe_estado_nacion_completo_2022.pdf
- Provost, F., & Fawcett, T. (2013). Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking. O'Reilly Media.
- Ragupathi, C., Dhanasekaran, S., Vijayalakshmi, N., & Salau, A. O. (2024). Prediction of electricity consumption using an innovative deep energy predictor model for enhanced accuracy and efficiency. *Energy Reports*, 12, 5320-5337.
- Reguant, M., Fabra, N., Wang, J. (2025). The Distributional Effects of Time-Varying Electricity Pricing. Wordpress. https://nataliafabra.org/wp-content/uploads/2025/07/The_Distributional_Impacts_of_Real_Time_Pricing.pdf
- Rojek, I., Mroziński, A., Kotlarz, P., Macko, M. y Mikołajewski, D. (2023). Modelo computacional basado en IA para la transformación sostenible de los mercados energéticos. *Energies*, 16 (24), 8059.
<https://doi.org/10.3390/en16248059>

- Rojek, Izabela & Mroziński, Adam & Kotlarz, Piotr & Macko, Marek & Mikołajewski, Dariusz. (2023). AI-Based Computational Model in Sustainable Transformation of Energy Markets. *Energies*. 16. 1-26. 10.3390/en16248059.
- Sadeghian, O., Oshnoei, A., Mohammadi-Ivatloo, B., Vahidinasab, V., & Anvari-Moghaddam, A. (2022). A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges. *Journal of Energy Storage*, 54, 105241.
- Shen, X., Zhao, H., Xiang, Y., Lan, P., & Liu, J. (2022). Short-term electric vehicles charging load forecasting based on deep learning in low-quality data environments. *Electric Power Systems Research*, 212, 108247.
- Sierra Bravo, R. (2001). *Técnicas de investigación social: Teoría y ejercicios* (9.^a ed.). Paraninfo.
- Sun, D. J., Zheng, Y., & Duan, R. (2021). Energy consumption simulation and economic benefit analysis for urban electric commercial-vehicles. *Transportation Research Part D: Transport and Environment*, 101, 103083.
- Tamayo y Tamayo, M. (2004). *El proceso de la investigación científica*. Limusa.
- Tamayo, C. y Tamayo, M. (2005). *El proceso de investigación científica* (5.^a ed.). Limusa.
- Thaller, A., Posch, A., Dugan, A., & Steininger, K. (2021). How to design policy packages for sustainable transport: Balancing disruptiveness and implementability. *Transportation Research Part D: Transport and Environment*, 91, 102714.

Timmons, D., Dhunny, A. Z., Elahee, K., Havumaki, B., Howells, M., Khoodaruth, A., ... & Surroop, D. (2019). Cost minimization for fully renewable electricity systems: A Mauritius case study. *Energy Policy*, 133, 110895.

UNESCO. (2024). Science, technology and innovation policy review: Tools for sustainable development. United Nations Educational, Scientific and Cultural Organization. <https://www.unesco.org/en/articles/science-technology-and-innovation-policy-instruments-sustainable-development-goals-global-outlook>

Ureña, S. (13 de Enero de 2025). Periodico La República . Obtenido de Costa Rica cierra el 2024 con una cifra histórica en vehículos eléctricos:
<https://www.larepublica.net/noticia/costa-rica-cierra-el-2024-con-una-cifra-historica-en-vehiculos-electricos>

World Energy Council. (2022). Future energy system flexibility: The key to energy transition. <https://fev.vc/flexibility-the-key-to-accelerating-energy-transition/>

Yang, Z., Slowik, P., Lutsey, N., & Searle, S. (2016). Principles for effective electric vehicle incentive design. International Council Clean Transportation June.
https://theicct.org/sites/default/files/publications/ICCT_IZEV-incentives-comp_201606.pdf

Zebra, E. I. C., van der Windt, H. J., Nhumaio, G., & Faaij, A. P. (2021). A review of hybrid renewable energy systems in mini-grids for off-grid electrification in developing countries. *Renewable and Sustainable Energy Reviews*, 144, 111036.

Zhang, H., & Ling, C. X. (2013). An improved understanding of Naïve Bayes classifier and its applications. *Expert Systems with Applications*, 178, 115008. doi: 10.1109/ANTHOLOGY.2013.6784818.

Zhang, C., Jiang, J., Zhang, W., Liu, Y., & Gao, Y. (2018). A review on charging power control strategies for electric vehicles. *Renewable and Sustainable Energy Reviews*, 81, 687–700. <https://doi.org/10.1016/j.rser.2017.08.056>

Ziras, C., Thingvad, M., Fog, T., Yousefi, G., & Weckesser, T. (2024). An empirical analysis of electric vehicle charging behavior based on real Danish residential charging data. *Electric Power Systems Research*, 234, 110556.

Zou, Y., Hu, X., Ma, H., & Li, S. E. (2015). Combined state of charge and state of energy estimation of lithium-ion battery with unscented Kalman filter for electric vehicles. *Journal of Power Sources*, 273, 793–803. <https://doi.org/10.1016/j.jpowsour.2014.09.146>