

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

Maverick Chacón Garro  
Software Engineer  
Akamai Technologies  
Guanacaste, Costa Rica  
mchacong@ucenfotec.ac.cr

Marny Andrey Lopez Lopez  
Software Engineer  
MyndsIT  
San Jose, Costa Rica  
marny@myndsit.com

**Resumen**—El acelerado crecimiento de vehículos eléctricos (VE) en Costa Rica ha generado la necesidad de comprender el impacto energético y económico asociado a la recarga residencial. Este artículo presenta un enfoque predictivo basado en aprendizaje automático para estimar el consumo energético y el incremento en la factura eléctrica en hogares costarricenses. Se emplearon datos del *Electric Vehicle Population Dataset* de 2024 y se procesaron mediante ingeniería de características, selección de variables, algoritmos de regresión, *XGBoost* y redes neuronales artificiales. Los resultados muestran que el modelo MLP logra un desempeño sobresaliente ( $R^2 = 0,89$ ), superando alternativas tradicionales. Se integra además una simulación tarifaria basada en tarifas reales de Costa Rica, permitiendo estimar costos y generar escenarios de uso. El trabajo aporta una base técnica y metodológica para la adopción informada de electromovilidad en la región.

**Index Terms**—Vehículos eléctricos, consumo energético residencial, aprendizaje automático, redes neuronales artificiales, *XGBoost*, regresión multivariable, modelado predictivo, estado de carga (SoC), simulación tarifaria, tarifas eléctricas, movilidad eléctrica, Costa Rica.

## I. INTRODUCCIÓN

La transición hacia la movilidad eléctrica se ha consolidado como un eje estratégico para la sostenibilidad energética a nivel global, impulsada por la necesidad de mitigar emisiones de gases de efecto invernadero y cumplir con los compromisos climáticos internacionales [1], [2], [3], [4], [5]. En Costa Rica, la adopción de vehículos eléctricos (VE) ha crecido de manera exponencial, pasando de aproximadamente 3 300 unidades en 2020 a más de 20 000 en 2024, lo que representa un incremento superior al 500% [6], [7]. Este fenómeno responde a la combinación de incentivos gubernamentales, metas nacionales de descarbonización y una matriz eléctrica con alta participación de fuentes renovables [8], [9], [10].

A pesar de estos avances, persiste incertidumbre entre los consumidores respecto al impacto real que la recarga del vehículo puede generar en la factura eléctrica mensual. Esta preocupación se ve acentuada por la percepción de insuficiencia en la infraestructura disponible y por barreras

sociotécnicas asociadas a la modernización del transporte [11], [12], [13]. Según los datos recopilados (1), el 91,3% de los participantes indicó que no existen suficientes estaciones de carga en su zona, evidenciando una percepción generalizada de limitada cobertura y disponibilidad de puntos de recarga. Estas inquietudes se alinean con barreras más amplias para la adopción de VE, tales como dudas sobre la madurez tecnológica, preocupaciones operativas, cuestionamientos respecto a la sostenibilidad real, limitaciones económicas y restricciones en la infraestructura de apoyo [10], [14], [15].




Figura 1. Principales barreras para la adquisición de vehículos eléctricos (Fuente: Elaboración Propia).

En este contexto, existe un vacío evidente en la literatura latinoamericana respecto a cómo estimar el consumo energético residencial asociado al uso de vehículos eléctricos, considerando patrones de uso reales, estructuras tarifarias locales y características técnicas específicas de los modelos en el mercado [16], [17], [18]. La ausencia de modelos y herramientas predictivas contextualizadas dificulta la toma de decisiones informadas tanto para consumidores como para instituciones públicas, empresas distribuidoras y actores del sector energético.

El presente estudio contribuye a cerrar esta brecha mediante la construcción de un modelo predictivo basado en técnicas modernas de aprendizaje automático, orientado a estimar el

consumo energético y el impacto económico asociado a la recarga residencial de vehículos eléctricos ligeros en Costa Rica. Adicionalmente, se integra una simulación tarifaria diseñada para reflejar las condiciones reales del sistema eléctrico costarricense, con el fin de ofrecer una herramienta analítica útil para el análisis energético y la planificación de la movilidad eléctrica en el país, en línea con las políticas de transición energética y descarbonización vigentes [8], [9], [19].

## II. ANTECEDENTES DEL PROBLEMA

La adopción de vehículos eléctricos en Costa Rica ha experimentado un crecimiento acelerado, pasando de 3 300 unidades en 2020 a más de 20 000 en 2024 y proyectándose a superar las 30 000 unidades para 2025 [6], [7]. A pesar de este incremento, persisten dudas significativas relacionadas con el consumo energético, el impacto en la vida útil de las baterías, la capacidad de la red eléctrica y los costos reales de operación de un VE en un entorno residencial [10], [15].

La literatura nacional evidencia un vacío importante en torno a herramientas técnicas que permitan estimar de manera confiable el impacto económico de la recarga domiciliaria. Este desconocimiento genera resistencia a la adopción y dificulta la planificación energética, especialmente en un país cuya matriz eléctrica depende en gran medida de fuentes renovables y tarifas horarias diferenciadas [5], [20]. Adicionalmente, la estructura tarifaria vigente y los esquemas de bloques y horarios implementados por las entidades reguladoras ejercen una influencia directa sobre la distribución de los costos y el comportamiento de consumo [21], [22], [23], [24].

## III. ESTADO DEL ARTE

Diversos estudios internacionales han abordado la predicción del consumo energético de VE en contextos de redes inteligentes. Wu et al. [25] analizaron el consumo energético de vehículos enchufables ligeros en Estados Unidos, encontrando que su impacto diario ronda los 3.1 kWh, concentrándose en horas nocturnas. Coban et al. [26] utilizaron modelos de panel para estimar el consumo doméstico, demostrando que métodos de regresión multivariada pueden capturar variaciones de carga con precisión aceptable.

Modelos basados en inteligencia artificial también han sido empleados. Khan et al. [27] demostraron que las redes neuronales superan a métodos lineales en pronósticos de carga en estaciones de recarga, mientras Al-Ogaili et al. [28] subrayaron la importancia de estrategias de control en escenarios de alta penetración de VE. Revisiones recientes sobre carga inteligente, pronóstico de demanda y comportamiento real de carga residencial consolidan el papel de técnicas de aprendizaje profundo, estrategias de gestión de demanda y esquemas de tarificación dinámica [17], [29], [18].

Sin embargo, ninguno de estos trabajos aborda explícitamente el contexto tarifario costarricense ni propone un simulador adaptado al entorno residencial del país, utilizando datos históricos y modelos de inteligencia artificial capaces de realizar predicciones precisas sobre el estado y los patrones

de carga. Este artículo aporta precisamente esa perspectiva contextualizada.

## IV. MARCO CONCEPTUAL

El estudio considera cuatro conceptos fundamentales:

**1) Consumo energético:** cantidad de energía eléctrica transferida al vehículo durante la recarga (kWh), la cual depende de la capacidad de la batería, la eficiencia del vehículo y los patrones de uso [30], [31].

**2) Estado de carga (SoC):** medida del nivel de batería que influye directamente en la energía necesaria para completar una sesión de recarga. La estimación y gestión del SoC constituye un problema ampliamente estudiado en aplicaciones de vehículos eléctricos [31], [32], [33].

**3) Potencia de carga:** relación entre energía suministrada y tiempo de carga, asociada al tipo de cargador (L1, L2 o DC) y a las estrategias de control de potencia [34], [35], [36].

**4) Tarifas eléctricas:** esquemas definidos por distribuidores locales, incluyendo bloques residenciales y tarifas horarias, cuyo diseño influye en el comportamiento de consumo y en la distribución de los costos [21], [22], [24], [37].

## V. METODOLOGÍA

El enfoque metodológico consta de seis fases: análisis exploratorio, limpieza de datos, ingeniería de características, entrenamiento de modelos, evaluación de desempeño y simulación tarifaria, siguiendo lineamientos clásicos de metodología de la investigación cuantitativa aplicada [38], [39], [40], [41]. Para el diseño de los instrumentos de recolección de datos y el análisis de la información cualitativa asociada a percepciones de usuarios se consideraron también referentes en investigación social y análisis de datos cualitativos [42], [43], [44], [45], [46].

### V-A. Descripción del Conjunto de Datos

El conjunto de datos utilizado [47] proporciona una colección amplia y diversa de información que sirve como base para generar variables derivadas y características relevantes. Estas transformaciones permiten obtener relaciones más consistentes entre los atributos y mejorar la capacidad predictiva de los modelos desarrollados [48], [49].

La Tabla I resume el conjunto de datos base.

Cuadro I  
CARACTERÍSTICAS PRINCIPALES DEL CONJUNTO DE DATOS (FUENTE:  
ELABORACIÓN PROPIA).

Variable	Descripción
Vehicle Age (years)	Antigüedad del vehículo
Vehicle Model	Modelo
Battery Capacity (kWh)	Capacidad (kWh)
Charger Type	Tipo de cargador (domestico L1,L2 o DC)
Start %	Estado inicial de la carga del vehículo
End %	Estado al finalizar la carga del vehículo
Charging Duration (hours)	Tiempo total de recarga en horas

### V-B. Análisis Exploratorio

La Figura 2 muestra la distribución del consumo energético esperado.




Figura 2. Distribución de consumo energético (Fuente: Elaboración Propia).

El mapa de correlaciones (Figura 3) evidencia que la capacidad de la batería, la autonomía eléctrica y el tipo de cargador son las variables de mayor impacto. Sin embargo, estas no resultan lo suficientemente cohesivas ni presentan una relación lineal fuerte como para ser utilizadas por sí solas como características principales en un modelo de inteligencia artificial, en coherencia con estudios sobre integración de VE en redes y análisis de impacto en la red de distribución [50], [51].

### V-C. Limpieza de Datos

El proceso de limpieza de datos se diseñó para garantizar la validez del modelado predictivo y reducir ruido y anomalías en el conjunto de datos. Las acciones implementadas fueron las siguientes:

- **Filtrado por alcance:** se conservaron únicamente las sesiones de carga realizadas con cargadores Level 1 y Level 2, excluyendo DC Fast por no corresponder al contexto residencial analizado.
- **Tratamiento de valores atípicos:**
  - se excluyeron consumos menores a 1 kWh por considerarse poco representativos (sesiones fallidas o incompletas),
  - se mantuvieron valores altos únicamente cuando resultaron coherentes con la capacidad de la batería reportada.
- **Consistencia entre variables:** se aplicaron reglas de validación para evitar incongruencias, verificando que:

- el consumo energético no superara la capacidad de la batería,
- el porcentaje final de carga (*End %*) fuese mayor que el inicial (*Start %*), salvo en casos de interrupción.

- **Manejo de valores faltantes:** se emplearon técnicas de imputación basadas en estadísticas descriptivas y conocimiento del dominio para preservar información y mantener un conjunto de datos coherente y completo.

### V-D. Ingeniería de Características

Con el fin de mejorar la capacidad predictiva de los modelos, se generaron diversas características derivadas a partir del conjunto de datos original. Estas permiten capturar relaciones energéticas y patrones de comportamiento no evidentes únicamente con las variables base, en línea con las buenas prácticas de minería de datos y modelado predictivo [48], [49]. Las principales características generadas fueron: **SoC\_diff**, **Energy\_est\_SoC** y **Power\_proxy**.

*V-D1. Diferencia de Estado de Carga (SoC\_diff):* La variable **SoC\_diff** representa el cambio porcentual en el estado de carga entre el inicio y el final de una sesión de uso o recarga. Se define como:

$$\text{SoC}_{\text{diff}} = \text{SoC}_{\text{end}} - \text{SoC}_{\text{start}} \quad (1)$$

donde  $\text{SoC}_{\text{start}}$  corresponde al porcentaje de batería inicial y  $\text{SoC}_{\text{end}}$  al porcentaje final.

*V-D2. Estimación de Energía por Estado de Carga (Energy\_est\_SoC):* La característica **Energy\_est\_SoC** estima la energía requerida para cubrir la variación observada en el estado de carga. Se calcula mediante:

$$\text{Energy}_{\text{est\_SoC}} = \text{BatteryCapacity} \times (\text{SoC}_{\text{start}} - \text{SoC}_{\text{end}}) \quad (2)$$

donde *BatteryCapacity* representa la capacidad útil de la batería en kWh. Esta variable permite aproximar la energía demandada incluso cuando no existen mediciones de consumo directo, coherente con enfoques de estimación de estado de carga y energía presentes en la literatura [31], [33].

*V-D3. Potencia Proxy (Power\_proxy):* Dado que el conjunto de datos no incluye valores explícitos de potencia suministrada, se creó la característica **Power\_proxy** como una aproximación basada en la energía estimada y la duración típica de recarga para cada tipo de cargador:

$$\text{Power}_{\text{proxy}} = \frac{\text{Energy}_{\text{est\_SoC}}}{T_{\text{charger}}} \quad (3)$$

donde  $T_{\text{charger}}$  corresponde al tiempo promedio de recarga para los tipos *Level 1*, *Level 2* o *DC Fast*. Esta característica captura diferencias operativas entre vehículos y métodos de carga, y se alinea con estrategias de modelado de potencia de carga en VE [35], [36].




Figura 3. Correlaciones entre variables (Fuente: Elaboración Propia).

V-D4. *Relevancia de las Características Derivadas:* Las variables generadas permitieron mejorar las correlaciones internas del conjunto de datos y facilitaron la identificación de relaciones no lineales en el consumo energético. En conjunto, estas características incrementaron la capacidad predictiva de los modelos y mejoraron el desempeño de las estimaciones de energía por sesión de carga.

V-E. *Modelos Predictivos*

Tres modelos fueron evaluados:

- 1) **Regresión lineal multivariable:** modelo base, rápido pero limitado ante relaciones no lineales.
- 2) **XGBoost:** algoritmo basado en árboles con gradiente, capaz de capturar interacciones no lineales.
- 3) **Red neuronal artificial tipo MLP,** cuya arquitectura se muestra en la Figura 4. El uso de modelos profundos para la predicción de consumo energético ha mostrado resultados competitivos en la literatura reciente [52], [53], [54].

V-F. *Arquitectura del Modelo Neuronal*

El modelo desarrollado corresponde a una red neuronal densa (*Multilayer Perceptron, MLP*) compuesta por cinco capas secuenciales: tres capas ocultas totalmente conectadas y una capa de salida. Su diseño busca capturar relaciones no




Figura 4. Arquitectura del MLP (Fuente: Elaboración Propia).

lineales entre las características del conjunto de datos y el consumo energético estimado.

V-F1. *Parámetros de Entrenamiento:* Para optimizar el desempeño del modelo, se emplearon los siguientes parámetros:

- **Optimizador (Adam):** Se utilizó el algoritmo Adam (*Adaptive Moment Estimation*), reconocido por su eficiencia computacional y su capacidad de adaptar dinámicamente la tasa de aprendizaje a cada parámetro de la red.
- **Función de pérdida (MSE):** Se empleó el Error Cuadrático Medio (*Mean Squared Error*), estándar en tareas de regresión al penalizar más fuertemente los errores grandes.

Cuadro II  
ARQUITECTURA DEL PERCEPTRÓN MULTICAPA (MLP) UTILIZADO EN EL ESTUDIO.

Capa	Neuronas	Activación	Propósito
Entrada / Oculta 1	128	ReLU	Extracción inicial de características
Dropout 1	—	0.25	Regularización y prevención de sobreajuste
Oculta 2	64	ReLU	Reducción progresiva de dimensionalidad
Dropout 2	—	0.15	Reducción de coadaptación entre neuronas
Oculta 3	32	ReLU	Abstracción final de patrones relevantes
Salida	1	Ninguna	Predicción continua (regresión)

- **Métrica (MAE):** Se utilizó el Error Absoluto Medio (*Mean Absolute Error*), métrica más interpretable que el MSE al expresarse en las mismas unidades que la variable objetivo.

V-F2. *Mecanismo de Detención Temprana:* Para evitar sobreajuste y mejorar la capacidad de generalización, se implementó un esquema de *early stopping*. El entrenamiento se interrumpía automáticamente cuando la función de pérdida en el conjunto de validación dejaba de mejorar tras un número determinado de épocas, evitando así un ajuste excesivo a los datos de entrenamiento.

V-F3. *Selección de Variables:* Las características utilizadas para entrenar el modelo fueron seleccionadas mediante análisis de correlación, priorizando aquellas con mayor relación estadística respecto a la variable objetivo. Asimismo, se incorporaron variables derivadas obtenidas durante el proceso de ingeniería de características, lo que permitió enriquecer la representación del conjunto de datos y mejorar el rendimiento predictivo.

## VI. RESULTADOS

### VI-A. Desempeño Predictivo

La Tabla III presenta las métricas de desempeño.

Cuadro III  
COMPARATIVA DE MODELOS (FUENTE: ELABORACIÓN PROPIA).

Modelo	MAE (kWh)	RMSE (kWh)	$R^2$
Regresión Lineal	18.78	21.81	-0.005
XGBoost	21.06	25.63	-0.387
<b>Red Neuronal (MLP, final)</b>	<b>1.58</b>	<b>2.12</b>	<b>0.987</b>

La curva de aprendizaje (Figura 5) evidencia una convergencia estable y sin señales de sobreajuste al emplear una arquitectura basada en redes neuronales.

Los resultados obtenidos muestran una mejora sustancial tanto en la precisión como en la capacidad explicativa del modelo, reflejada en un incremento notable del coeficiente de determinación y en una reducción del error absoluto medio superior al 90% con respecto a los modelos de referencia.

## VII. SIMULACIÓN TARIFARIA

La simulación tarifaria integra tanto esquemas por bloques de consumo como tarifas horarias residenciales, basados en las estructuras publicadas por las entidades reguladoras y distribuidoras nacionales [21], [22], [23]. En esta sección se ilustran los dos componentes principales del modelo tarifario empleado para estimar el impacto económico de la recarga de




Figura 5. Curva de aprendizaje del MLP (Fuente: Elaboración Propia).

los vehículos eléctricos en hogares costarricenses, considerando además evidencia sobre los efectos distributivos de precios variables en el tiempo [24], [37].

En primer lugar, se consideran los bloques de consumo tradicionalmente aplicados al servicio residencial, donde el costo marginal aumenta conforme se sobrepasan determinados umbrales de kWh mensuales. En segundo lugar, se incorpora un esquema de tarifa horaria que diferencia periodos de punta, valle y llano, con el objetivo de analizar el efecto de desplazar la recarga hacia horarios de menor costo.

Las tarifas del servicio eléctrico para inmuebles residenciales, comerciales e industriales que presta la Compañía Nacional de Fuerza y Luz, S.A. (CNFL) se encuentran publicadas en el consolidado vigente. Estas tarifas rigen en toda el área de servicio de la CNFL y están definidas por bloques de consumo y modalidades según el tipo de cliente [22].

### VII-A. Tarifa Residencial por Bloques (T-RE y T-RP)

La tarifa residencial tradicional (T-RE) y la tarifa residencial prepago (T-RP) aplican a casas de habitación o apartamentos servidos por medidores individuales. No aplican para hoteles, hospitales ni servicios combinados [22].

### VII-B. Tarifa Residencial Horaria (T-REH)

La tarifa residencial horaria (T-REH) es exclusiva para abonados residenciales servidos en baja tensión con un consumo mensual superior a 200 kWh. El servicio se configura con medición multitarifada para registrar el consumo según periodos horarios (punta, valle y nocturno) [22].

Cuadro IV  
RESUMEN DE LA TARIFA RESIDENCIAL T-RE/T-RP DE LA CNFL (2025)  
(FUENTE: ELABORACIÓN PROPIA).

Concepto	Medida	Precio (C)
Bloque 0–30 kWh	Cargo fijo mensual	2034,60
Bloque 31–200 kWh	por kWh	67,82
Bloque 201–300 kWh	por kWh	104,07
Más de 300 kWh	por kWh adicional	107,59

Los periodos se definen de la siguiente manera:

- **Periodo punta:** 10:01–12:30 y 17:31–20:00 (de lunes a viernes).
- **Periodo valle:** 06:01–10:00 y 12:31–17:30 (incluye las horas que serían punta durante fines de semana).
- **Periodo nocturno:** 20:01–06:00, todos los días.

La Tabla V resume los cargos por energía para la T-REH, diferenciando entre consumos mensuales de hasta 500 kWh y superiores a 500 kWh.

Cuadro V  
TARIFA HORARIA RESIDENCIAL T-REH POR PERIODO Y NIVEL DE CONSUMO (CNFL 2025) (FUENTE: ELABORACIÓN PROPIA).

Periodo	Franja horaria	C/kWh	
		0–500 kWh	> 500 kWh
Punta	10:01–12:30, 17:31–20:00	156,96	194,09
Valle	06:01–10:00, 12:31–17:30	64,35	78,33
Nocturno	20:01–06:00	26,94	36,26

## VIII. DISCUSIÓN

Los resultados demuestran que:

- La capacidad de batería y el tipo de cargador explican más del 70 % de la varianza del consumo, consistente con estudios previos sobre integración de vehículos eléctricos en redes de potencia y gestión de demanda [50], [55], [56].
- El modelo MLP supera técnicas tradicionales gracias a su capacidad para capturar relaciones no lineales, en consonancia con la literatura reciente en predicción de consumo energético mediante modelos profundos y enfoques basados en IA [52], [54], [17].
- Los patrones de recarga nocturnos coinciden con estudios internacionales de comportamiento de carga residencial [18], [57].
- El impacto económico puede variar entre un 8 % y un 25 % del total facturado en un hogar promedio, dependiendo del esquema tarifario y del horario de recarga [24], [20].

Además, se evidencia que una futura adopción masiva de VE requerirá reforzar la red de distribución y promover tarifas dinámicas que incentiven cargas en horas valle, en línea con las recomendaciones internacionales sobre flexibilidad del sistema y redes inteligentes [5], [58], [59].

## IX. CONCLUSIONES

Este trabajo tuvo como objetivo modelar y predecir el consumo energético de vehículos eléctricos ligeros en entornos residenciales costarricenses, integrando técnicas modernas de aprendizaje automático con un simulador tarifario alineado con la realidad regulatoria nacional. A partir de un conjunto de datos internacional de sesiones de carga, enriquecido mediante ingeniería de características, se logró construir un modelo capaz de estimar con alta precisión el consumo energético por sesión, así como su impacto económico bajo distintos esquemas tarifarios residenciales.

En términos de desempeño predictivo, la red neuronal tipo MLP superó ampliamente a los modelos de referencia basados en regresión lineal y XGBoost, alcanzando un MAE de 1.58 kWh, un RMSE de 2.12 kWh y un coeficiente de determinación  $R^2 = 0,987$ . Estos resultados evidencian que los enfoques basados en redes neuronales profundas son particularmente adecuados para capturar relaciones no lineales entre variables técnicas del vehículo (como capacidad de batería, tipo de cargador o estado de carga) y el consumo energético efectivo. La incorporación de características derivadas como **SoC\_diff**, **Energy\_est\_SoC** y **Power\_proxy** resultó clave para mejorar la representación del problema y aumentar la capacidad explicativa del modelo.

La simulación tarifaria desarrollada demuestra que el impacto económico de la recarga de un vehículo eléctrico en un hogar costarricense puede oscilar entre un 8 % y un 25 % del total facturado, dependiendo tanto del patrón de uso como del esquema tarifario y del horario de recarga. En particular, se evidencia que el uso de tarifas horarias residenciales (como la T-REH) y el desplazamiento de la recarga hacia horas valle o nocturnas permiten mitigar significativamente el incremento en la factura mensual, alineando los hábitos de carga con los objetivos de flexibilidad del sistema eléctrico y gestión de demanda. Esto refuerza la importancia de diseñar señales de precio adecuadas y mecanismos de incentivos que orienten el comportamiento de los usuarios en coherencia con las estrategias de descarbonización y transición energética definidas a nivel nacional [8], [9], [19].

Los resultados obtenidos aportan evidencia empírica para el diseño de políticas públicas y estrategias empresariales. Para los hogares, el modelo permite estimar de forma transparente el impacto de la compra de un vehículo eléctrico sobre su factura eléctrica, reduciendo la incertidumbre y derribando mitos frecuentes sobre el “alto costo oculto” de la recarga. Para las empresas distribuidoras y entidades reguladoras, las simulaciones muestran el potencial de las tarifas horarias y los esquemas de gestión de demanda como instrumentos para suavizar picos de carga y aprovechar de mejor forma una matriz eléctrica mayoritariamente renovable. A nivel de planificación de largo plazo, los resultados pueden servir de insumo para evaluar escenarios de penetración masiva de VE y su efecto agregado sobre la red de distribución.

Se concluye que la adopción masiva de vehículos eléctricos en Costa Rica es técnicamente viable desde la perspectiva

energética y económicamente manejable para los hogares, siempre que se acompañe de políticas de gestión de demanda, diseños tarifarios adecuados y herramientas de apoyo a la toma de decisiones. La combinación de modelos predictivos basados en IA, simuladores tarifarios contextualizados y sistemas de consulta en lenguaje natural constituye una vía prometedora para cerrar la brecha entre la investigación académica y la implementación práctica de la movilidad eléctrica en el país. El trabajo futuro propuesto, orientado a integrar datos reales de estaciones de carga, modelar la degradación de baterías, incorporar tarifas dinámicas en tiempo real y desarrollar aplicaciones web de simulación masiva, puede consolidar este enfoque como una plataforma integral de análisis y planificación de la electromovilidad a escala nacional.

## X. CONTRIBUCIONES SECUNDARIAS Y ARTEFACTOS GENERADOS

Además del desarrollo del modelo predictivo principal, la investigación produjo una serie de artefactos secundarios que fortalecen la aplicabilidad del estudio y amplían su impacto hacia la población general, contribuyendo tanto a la divulgación técnica como al soporte de herramientas de análisis energético.

### X-A. Modelo RAG para Recuperación Aumentada de Conocimiento

Durante el proceso de investigación se recopiló una gran cantidad de información técnica sobre vehículos eléctricos, su arquitectura, patrones de carga, adopción y mejores prácticas. Dado que una porción significativa de este material se encuentra en inglés y en literatura altamente especializada, se desarrolló un modelo de inteligencia artificial aumentada basado en *Retrieval-Augmented Generation* (RAG), aprovechando principios de minería de datos y ciencia de datos aplicada [48], [49].

El objetivo de este modelo es preservar el conocimiento adquirido y ponerlo a disposición de usuarios no técnicos mediante respuestas claras y contextualizadas. El sistema permite consultar documentación académica, normativa y técnica, ofreciendo una interpretación simplificada sin perder rigurosidad conceptual. Este artefacto constituye un puente entre la investigación académica y la divulgación accesible para la población costarricense.

El sistema propuesto utiliza una arquitectura de tipo *Retrieval-Augmented Generation* (RAG) para aprovechar el contenido de documentos en formato PDF. En lugar de entrenar un modelo de lenguaje desde cero, se construye un pipeline que combina:

- Extracción y preprocesamiento de texto desde PDFs,
- Generación de representaciones vectoriales (embeddings) de fragmentos de texto,
- Almacenamiento de estos vectores en una base de datos vectorial, y un modelo de lenguaje grande (LLM) que genera respuestas condicionadas por la información recuperada.

Cuando el usuario realiza una consulta, el sistema:




Figura 6. Flujo general del sistema RAG enriquecido a partir de los PDFs obtenidos durante la investigación.(Fuente: Elaboración propia)

- Convierte la pregunta en un embedding,
- Recupera los fragmentos de texto más relevantes desde la base vectorial,
- Construye un prompt enriquecido con dicho contexto, y
- Delega en el LLM la generación de una respuesta natural basada exclusivamente en los documentos originales.

### X-B. Pipeline de Orquestación con LangChain

Con el objetivo de unificar las capacidades del modelo de predicción energética basado en redes neuronales artificiales (ANN) y del modelo RAG entrenado con contenido técnico en formato PDF, se diseñó un *pipeline* conversacional utilizando la arquitectura modular provista por LangChain. Este componente actúa como un orquestador inteligente capaz de decidir, en tiempo de ejecución, cuál modelo debe atender la consulta del usuario.

El sistema implementa un mecanismo de enrutamiento semántico (*semantic router*) que clasifica automáticamente cada entrada en dos grandes categorías:

- consultas de tipo analítico orientadas a obtener estimaciones numéricas del consumo o costo energético del vehículo eléctrico o
- solicitudes de información contextual o explicativa, como dudas sobre baterías, métodos de carga, especificaciones técnicas o requisitos tarifarios

Dependiendo del resultado de esta clasificación, la solicitud es enviada al modelo correspondiente: el módulo ANN para tareas predictivas o el módulo RAG para tareas de recuperación y generación contextualizada de información.

Esta arquitectura permite una experiencia de tipo *chatbot*, donde el usuario final puede interactuar con ambos modelos de manera transparente, sin necesidad de conocimientos avanzados sobre redes neuronales, estructuras tarifarias o movilidad eléctrica. El motor de decisión interno del *pipeline* se diseñó específicamente para este proyecto, garantizando relevancia contextual y eficiencia en las respuestas [60], [61]. Como se muestra en la Figura 8, el motor de inferencia es capaz de detectar errores y transformar preguntas en lenguaje natural en las variables de entrada requeridas por el modelo ANN para realizar la predicción conforme a las características del vehículo.

La Figura 7 muestra la arquitectura completa del sistema conversacional híbrido desarrollado para esta investigación. El proceso inicia con la entrada en lenguaje natural proporcionada por el usuario, la cual es analizada por un enrutador semántico implementado en LangChain. Este componente clasifica la intención de la consulta y selecciona cuál de los dos modelos subyacentes debe ejecutarse: el modelo ANN para predicción

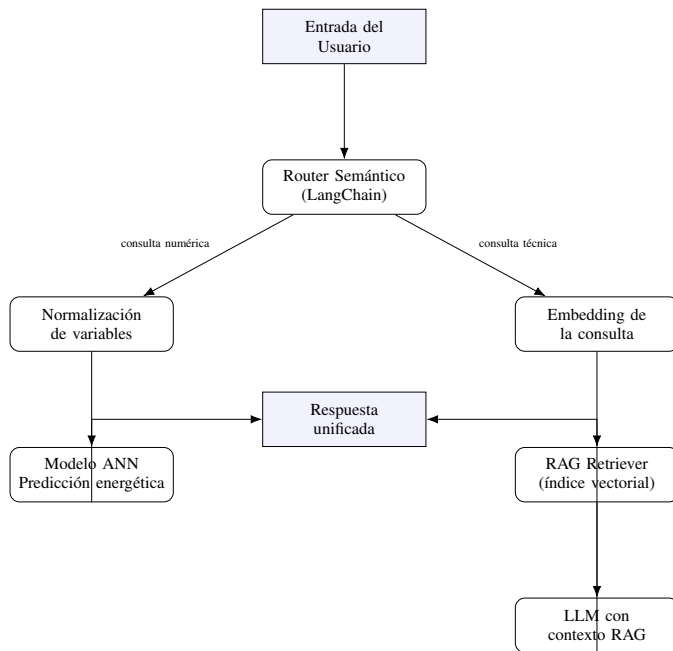


Figura 7. Arquitectura del pipeline unificado ANN + RAG orquestado mediante LangChain (Fuente: Elaboración propia).

cuantitativa del consumo energético, o el modelo RAG para obtener información técnica contextualizada a partir de los documentos en PDF previamente indexados. Cuando la consulta corresponde a un cálculo energético, el pipeline activa el módulo de normalización de variables y posteriormente envía los datos al modelo ANN. En contraste, si la consulta requiere información conceptual, el sistema genera un embedding de la pregunta, ejecuta la recuperación semántica en la base vectorial y finalmente construye una respuesta enriquecida mediante un LLM. Ambos flujos convergen en un generador de respuesta unificada, que presenta al usuario una salida coherente, completa y consistente con su intención inicial.

El artefacto de software implementado como parte de esta investigación se encuentra disponible en el repositorio oficial del proyecto: <https://github.com/shoys89/ev-llm-app>. Asimismo, el modelo ANN entrenado se ha liberado para su uso y reproducción en la plataforma Hugging Face mediante <https://huggingface.co/mchaconguenofotec/ev-test-train>.

#### X-C. Otros Artefactos Generados

Además de los modelos descritos, se generaron los siguientes activos:

- **Simulador tarifario prototipo:** herramienta que estima el costo de recarga según tipo de cargador, hábitos de uso y tarifas residenciales vigentes [21], [22].
- **Conjunto de datos procesado:** dataset depurado, normalizado y enriquecido con variables derivadas como eficiencia energética y potencia media [47].
- **Scripts de análisis y modelado:** código empleado para preprocesamiento, ingeniería de características, entrenamiento y evaluación de modelos.

## 🤖 Asistente de Carga de Vehículos Eléctricos (LLM + Modelo HF)

Este asistente usa un LLM (Groq + Qwen) para entender tu mensaje, completa la información de la sesión de carga y llama a tu modelo de predicción en Hugging Face para estimar la energía cargada.

🗨️ cuantos kw consume si cargo mi Nissan Leaf 2013 de un 0% al 100% en 6 horas?

🤖 ¡Hola! Observo que el sistema ha utilizado información de un Nissan Leaf 2018-2022 (40 kWh) para calcular los datos, pero su vehículo es un Nissan Leaf 2013, cuya capacidad de batería es menor (probablemente 24 kWh o 30 kWh, dependiendo de la configuración). Esto podría generar errores en las predicciones.

¿Podría confirmar la capacidad real de la batería de su Nissan Leaf 2013? Esto permitirá recalibrar los cálculos y ofrecerle un resultado más preciso.

Por ejemplo:

- Si su batería es de 24 kWh, la energía estimada cargada sería 24 kWh (en lugar de los 39 kWh calculados actualmente).
- La potencia media de carga sería 4 kW (24 kWh / 6 horas).
- La eficiencia calculada (92%) seguiría siendo válida, pero los valores absolutos cambiarían.

Le recomendaría revisar los datos técnicos de su vehículo para asegurar la exactitud de la predicción. ¿Desea proporcionar la capacidad de su batería real?

Describe tu sesión de carga... ➔

Figura 8. Artefacto Chat basado en LLM y modelo ANN (Fuente: Elaboración Propia).

- **Encuestas estructuradas aplicadas en Costa Rica:** instrumento para analizar percepción pública, infraestructura disponible y barreras de adopción [10], [14].
- **Material conceptual y documentación técnica:** mapa conceptual, nube de conceptos y glosario técnico que sustentan la base teórica del estudio [62], [63].

Estos artefactos complementan los resultados principales y constituyen la base para futuras extensiones del proyecto, incluyendo aplicaciones educativas, herramientas de simulación y plataformas de consulta basadas en IA.

## XI. TRABAJO FUTURO

Se propone:

- Integrar datos reales de estaciones de carga costarricenses, incluyendo su estado y capacidad de entrega de kWh.
- Evaluar el impacto de la degradación de baterías en la velocidad y capacidad de carga de los vehículos eléctricos. [31], [32], [33],
- Incorporar tarifas dinámicas en tiempo real de múltiples empresas de servicio eléctrico, con el objetivo de incrementar la precisión del cálculo de estimación de costos. [24], [5],
- Desarrollar una aplicación web para simulación energética masiva que pueda ser utilizada por proveedores eléctricos para planificar la instalación de estaciones de carga rápida o semi-rápida de acceso público.

## REFERENCIAS

- [1] IPCC, "Sixth assessment report: Mitigation of climate change," Intergovernmental Panel on Climate Change, Tech. Rep., 2022. [Online]. Available: <https://www.ipcc.ch/report/ar6/wg3>
- [2] Agencia Europea del Medio Ambiente, "Electric vehicles from life cycle and circular economy perspectives," EEA, EEA Report, 2018, accessed 2025. [Online]. Available: <https://www.eea.europa.eu/en/analysis/publications/electric-vehicles-from-life-cycle>
- [3] M. Negri and G. Bieker, "Life-cycle greenhouse gas emissions from passenger cars in the european union," ICCT, Tech. Rep., 2025. [Online]. Available: <https://theicct.org/publication/electric-cars-life-cycle-analysis-emissions-europe-jul25/>
- [4] Agencia Internacional de Energía, "Global ev outlook 2022," International Energy Agency, Tech. Rep., 2022. [Online]. Available: <https://www.iea.org/reports/global-ev-outlook-2022>
- [5] World Energy Council, "Future energy system flexibility: The key to energy transition," World Energy Council, Tech. Rep., 2022. [Online]. Available: <https://fev.vc/flexibility-the-key-to-accelerating-energy-transition/>
- [6] K. Hidalgo, "Costa rica registró en 2024 la mayor cifra de importación de vehículos: se inscribieron más de 470 automotores por día," Amelía Rueda, Jan. 2025. [Online]. Available: <https://ameliarueda.com/noticia/flota-vehicular-cifra-importacion-registro-noticias-costa-rica>
- [7] S. Ureña, "Costa rica cierra el 2024 con una cifra histórica en vehículos eléctricos," Periódico La República, Jan. 2025. [Online]. Available: <https://www.larepublica.net/noticia/costa-rica-cierra-el-2024-con-una-cifra-historica-en-vehiculos-electricos>
- [8] Ministerio de Planificación Nacional y Política Económica (MIDEPLAN), "Plan nacional de descarbonización de costa rica 2020–2050," Gobierno de Costa Rica, Tech. Rep., 2025. [Online]. Available: <https://cambioclimatico.minae.go.cr/plan-nacional-de-descarbonizacion/>
- [9] Programa Estado de la Nación, "Informe estado de la nación en desarrollo humano sostenible," Programa Estado de la Nación, Tech. Rep., 2022. [Online]. Available: [https://estadonacion.or.cr/wp-content/uploads/2022/11/PEN\\_informe\\_estado\\_nacion\\_completo\\_2022.pdf](https://estadonacion.or.cr/wp-content/uploads/2022/11/PEN_informe_estado_nacion_completo_2022.pdf)
- [10] Banco Interamericano de Desarrollo, "Electromovilidad en américa latina y el caribe: avances y perspectivas," Banco Interamericano de Desarrollo, Tech. Rep., 2023. [Online]. Available: <https://publications.iadb.org/publications/spanish/document/Hacia-una-integracion-sostenible-el-potencial-de-la-electromovilidad-en-America-Latina-y-el-Caribe>
- [11] D. Banister, *Unsustainable Transport: City Transport in the New Century*. Routledge, 2005.
- [12] H. L. Breetz, M. Miltenberger, and L. C. Stokes, "The political logics of clean energy transitions," *Business and Politics*, vol. 23, no. 1, pp. 1–28, 2021.
- [13] A. Thaller, A. Posch, A. Dugan, and K. Steininger, "How to design policy packages for sustainable transport: Balancing disruptiveness and implementability," *Transportation Research Part D: Transport and Environment*, vol. 91, p. 102714, 2021.
- [14] J. P. Díaz-Arrieta, J. R. Valverde, and J. Allen, "Análisis de perspectivas y políticas públicas enfocadas al transporte público eléctrico modalidad autobús en costa rica (2018–2022)," *Infraestructura Vial*, vol. 25, no. 44, pp. 28–45, 2023.
- [15] L. E. Barahona Carmona, "Movilidad eléctrica en costa rica: Oportunidades para una sociedad descarbonizada. avances 2020–2024," Ministerio de Planificación Nacional y Política Económica, Feb. 2025. [Online]. Available: <https://documentos.mideplan.go.cr/share/s/GW2p8OrYR7yCV6y0Cj-qTw>
- [16] International Energy Agency, "Charging infrastructure for electric vehicles: A global review," IEA, Tech. Rep., 2022. [Online]. Available: <https://www.iea.org/reports/global-ev-outlook-2022>
- [17] O. Sadeghian, A. Oshnoei, B. Mohammadi-Ivatloo, V. Vahidinasab, and A. Anvari-Moghaddam, "A comprehensive review on electric vehicles smart charging: Solutions, strategies, technologies, and challenges," *Journal of Energy Storage*, vol. 54, p. 105241, 2022.
- [18] C. Ziras, M. Thingvad, T. Fog, G. Yousefi, and T. Weckesser, "An empirical analysis of electric vehicle charging behavior based on real danish residential charging data," *Electric Power Systems Research*, vol. 234, p. 110556, 2024.
- [19] Naciones Unidas, "Movilidad sostenible: clave para la agenda 2030," <https://sdgs.un.org/es/goals>, 2022.
- [20] D. Timmons, A. Z. Dhunny, K. Elahee, B. Havumaki, M. Howells, A. Khoodaruth, and D. Surroop, "Cost minimization for fully renewable electricity systems: A mauritius case study," *Energy Policy*, vol. 133, p. 110895, 2019.
- [21] Autoridad Reguladora de los Servicios Públicos (ARESEP), "Tarifas vigentes de electricidad - aresep," <https://aresep.go.cr/electricidad/tarifas/>, Jun. 2025, accessed 2025-06-17.
- [22] Comisión Nacional de Fuerza y Luz (CNFL), "Tarifas vigentes," <https://www.cnfl.go.cr/servicios/electricos/inmuebles/tramites/tarifas>, Oct. 2025, accessed 2025-10-13.
- [23] CNFL, "Interprete su factura residual," <https://www.cnfl.go.cr/interes/servicio-electrico/interprete>, 2024, accessed 2025.
- [24] M. Reguant, N. Fabra, and J. Wang, "The distributional effects of time-varying electricity pricing," [https://nataliafabra.org/wp-content/uploads/2025/07/The\\_Distributional\\_Impacts\\_of\\_Real\\_Time\\_Pricing.pdf](https://nataliafabra.org/wp-content/uploads/2025/07/The_Distributional_Impacts_of_Real_Time_Pricing.pdf), 2025.
- [25] D. Wu, D. C. Aliprantis, and K. Gkritza, "Electric energy and power consumption by light-duty plug-in electric vehicles," *IEEE Transactions on Power Systems*, vol. 26, no. 2, pp. 738–746, 2011.
- [26] H. H. Coban, M. Bajaj, V. Blazek, F. Jurado, and S. Kamel, "Forecasting energy consumption of electric vehicles," in *2023 5th Global Power, Energy and Communication Conference (GPECOM)*, 2023, pp. 120–124.
- [27] H. Khan, M. J. Khan, and A. Qayyum, "Neural network-based load forecasting model for efficient charging of electric vehicles," in *2022 7th Asia Conference on Power and Electrical Engineering (ACPEE)*, 2022, pp. 2068–2072.
- [28] A. S. Al-Ogaili, T. J. Tengku Hashim, N. A. Rahmat, A. K. Ramasamy, M. B. Marsadek, M. Faisal, and M. A. Hannan, "Review on scheduling, clustering, and forecasting strategies for controlling electric vehicle charging: Challenges and recommendations," *IEEE Access*, vol. 7, pp. 128 353–128 371, 2019.
- [29] X. Shen, H. Zhao, Y. Xiang, P. Lan, and J. Liu, "Short-term electric vehicles charging load forecasting based on deep learning in low-quality data environments," *Electric Power Systems Research*, vol. 212, p. 108247, 2022.
- [30] D. J. Sun, Y. Zheng, and R. Duan, "Energy consumption simulation and economic benefit analysis for urban electric commercial-vehicles," *Transportation Research Part D: Transport and Environment*, vol. 101, p. 103083, 2021.
- [31] M. A. Hannan, M. S. H. Lipu, A. Hussain, and A. Mohamed, "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*, vol. 78, pp. 834–854, 2017.
- [32] X. Hu, L. Jian, Y. Zhang, and B. Egardt, "Battery health prognosis for electric vehicles using sample entropy and hilbert–huang transform," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 4, pp. 2645–2656, 2016.
- [33] Y. Zou, X. Hu, H. Ma, and S. E. Li, "Combined state of charge and state of energy estimation of lithium-ion battery with unscented kalman filter for electric vehicles," *Journal of Power Sources*, vol. 273, pp. 793–803, 2015.
- [34] International Electrotechnical Commission, "Iec 61851-1: Electric vehicle conductive charging system," 2017, international Standard.
- [35] C. Zhang, J. Jiang, W. Zhang, Y. Liu, and Y. Gao, "A review on charging power control strategies for electric vehicles," *Renewable and Sustainable Energy Reviews*, vol. 81, pp. 687–700, 2018.
- [36] S. A. K. Mojlish, D. Sutanto, and K. M. Muttaqi, "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*, vol. 107, p. 114913, 2025.
- [37] Z. Yang, P. Slowik, N. Lutsey, and S. Searle, "Principles for effective electric vehicle incentive design," International Council on Clean Transportation, Tech. Rep., 2016. [Online]. Available: [https://theicct.org/sites/default/files/publications/ICCT\\_IZEV-incentives-comp\\_201606.pdf](https://theicct.org/sites/default/files/publications/ICCT_IZEV-incentives-comp_201606.pdf)
- [38] R. Hernández Sampieri, C. Mendoza Torres, and P. Baptista Lucio, *Metodología de la investigación*, 6th ed. McGraw-Hill Education, 2014.
- [39] R. Hernández Sampieri, C. P. Mendoza Torres, and M. P. Baptista Lucio, *Metodología de la investigación*, 7th ed. McGraw-Hill, 2022.
- [40] C. A. Bernal, *Metodología de la investigación*, 3rd ed. Pearson, 2010.
- [41] F. Arias, *El proyecto de investigación: Introducción a la metodología científica*, 6th ed. Editorial Episteme, 2012.
- [42] U. Flick, *Introducción a la investigación cualitativa*. Ediciones Morata, 2012.

- [43] G. Gibbs, *El análisis de datos cualitativos en investigación cualitativa*. Ediciones Morata, 2012.
- [44] R. Sierra Bravo, *Técnicas de investigación social: Teoría y ejercicios*, 9th ed. Paraninfo, 2001.
- [45] M. Tamayo y Tamayo, *El proceso de la investigación científica*. Limusa, 2004.
- [46] C. Tamayo and M. Tamayo, *El proceso de investigación científica*, 5th ed. Limusa, 2005.
- [47] V. Khorasani, "Electric vehicle charging patterns [dataset]," Kaggle, 2024. [Online]. Available: <https://www.kaggle.com/datasets/valakhorasani/electric-vehicle-charging-patterns>
- [48] J. Han, J. Pei, and M. Kamber, *Data Mining: Concepts and Techniques*, 4th ed. Morgan Kaufmann, 2022.
- [49] F. Provost and T. Fawcett, *Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking*. O'Reilly Media, 2013.
- [50] J. A. P. Lopes, F. J. Soares, and P. M. R. Almeida, "Integration of electric vehicles in the electric power system," *Proceedings of the IEEE*, vol. 99, no. 1, pp. 168–183, 2021.
- [51] J. Galarza-Linares, D. Condezo-Hurtado, B. Saenz-Loayza, and D. Huarac-Rojas, "Evaluación de la red de distribución: conexión del vehículo eléctrico híbrido enchufable," *Revista Tecnología en Marcha*, vol. 34, no. 4, pp. 50–62, 2021. [Online]. Available: <https://dx.doi.org/10.18845/tm.v34i4.5384>
- [52] C. Ragupathi, S. Dhanasekaran, N. Vijayalakshmi, and A. O. Salau, "Prediction of electricity consumption using an innovative deep energy predictor model for enhanced accuracy and efficiency," *Energy Reports*, vol. 12, pp. 5320–5337, 2024.
- [53] G. Bayomi, A. Hamdy, M. Hasheem, and A. Ali, "Prediction of smart grid stability utilizing machine learning algorithms," in *2023 International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)*, Cairo, Egypt, 2023, pp. 1–6.
- [54] I. Rojek, A. Mroziński, P. Kotlarz, M. Macko, and D. Mikołajewski, "Ai-based computational model in sustainable transformation of energy markets," *Energies*, vol. 16, pp. 1–26, 2023.
- [55] X. Fang, S. Misra, G. Xue, and D. Yang, "Smart grid—the new and improved power grid: A survey," *IEEE Communications Surveys & Tutorials*, vol. 24, no. 1, pp. 1–30, 2011.
- [56] Instituto de Investigación Tecnológica, "Gestión inteligente de la demanda y patrones de consumo residencial," Universidad Pontificia Comillas, Tech. Rep., 2021. [Online]. Available: [https://www.iit.comillas.edu/documentacion/revista/IIT-13-131A/Gesti%C3%B3n\\_de\\_la\\_demanda\\_el%C3%A9ctrica.pdf](https://www.iit.comillas.edu/documentacion/revista/IIT-13-131A/Gesti%C3%B3n_de_la_demanda_el%C3%A9ctrica.pdf)
- [57] T. H. Christensen, F. Friis, and T. M. Skjølvold, "Changing practices of energy consumption: The influence of smart grid solutions in households," NTNU, Tech. Rep., 2017. [Online]. Available: <https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/2466857>
- [58] Comisión Europea, "Smart grids and the energy transition," IEF, 2023. [Online]. Available: <https://www.ief.org/news/smart-grids-support-the-energy-transition-heres-how>
- [59] IEEE, "Smart grid overview," <https://smartgrid.ieee.org/>, 2022, institute of Electrical and Electronics Engineers.
- [60] J. Baggio, "Complex adaptive systems, simulations and agent-based modeling," 2017, unpublished/working material.
- [61] C. M. Macal and M. J. North, "Agent-based modeling and simulation: An overview," *Complex Adaptive Systems Modeling*, vol. 9, no. 1, pp. 1–14, 2021.
- [62] F. Martínez-Plumed, L. Contreras-Ochando, C. Ferri, J. Hernández-Orallo, and M. Kull, *Fairness and Discrimination in Machine Learning*. Springer, 2019.
- [63] UNESCO, "Science, technology and innovation policy review: Tools for sustainable development," United Nations Educational, Scientific and Cultural Organization, Tech. Rep., 2024. [Online]. Available: <https://www.unesco.org/en/articles/science-technology-and-innovation-policy-instruments-sustainable-development-goals-global-outlook>