

**UNIVERSIDAD INTERNACIONAL DE LAS AMÉRICAS**

**CARRERA DE ADMINISTRACIÓN DE EMPRESAS**

**ESTIMACIÓN DE LA CANTIDAD DE VEHÍCULOS ELÉCTRICOS  
REGISTRADOS EN COSTA RICA PARA EL AÑO 2026, MEDIANTE  
EL DISEÑO, CALIBRACIÓN Y VALIDACIÓN DE UN MODELO  
PREDICTIVO DE REDES NEURONALES AUTORREGRESIVAS  
APLICADO A UNA SERIE DE TIEMPO ANUAL DEL PERÍODO  
2010–2025**

**INVESTIGADOR:  
ROBERTO DELGADO CASTRO**

**ABRIL, 2026**

# Contenido

Índice de tablas .....	5
Índice de figuras .....	6
Glosario de términos .....	7
Capítulo I. Planteamiento del problema .....	8
1.1. Problema .....	8
1.2. Objetivos .....	13
1.2.1. <i>Objetivo General De La Investigación</i> .....	13
1.2.2. <i>Objetivos Específicos De La Investigación</i> .....	13
1.3. Justificación .....	14
1.4. Antecedentes .....	17
1.4.1 Antecedentes internacionales .....	17
1.4.2 Antecedentes nacionales .....	20
1.4.3 Marco político: Plan Nacional de Descarbonización.....	24
1.4.4 <i>Implicaciones Para La Presente Investigación</i> .....	25
Capítulo II. Marco Teórico .....	26
2.5. Marco Teórico .....	26
2.5.1 <i>Redes Neuronales Artificiales: Fundamentos Conceptuales</i> .....	26
2.5.2 <i>Red Neuronal Autorregresiva (NNAR) Para Series De Tiempo</i> .....	27
2.5.3 <i>Modelos Predictivos Y Validación Fuera De Muestra</i> .....	28
2.5.4 <i>Movilidad Eléctrica</i> .....	28
2.5.5 <i>Energías Renovables</i> .....	29
2.5.6 <i>Descarbonización Y Eficiencia Energética</i> .....	30
2.5.7 <i>Integración Conceptual Del Marco Teórico</i> .....	30
Capítulo III. Metodología .....	31

3.1	Tipo De Investigación.....	31
3.2	Tipo De Alcance.....	31
3.3	Diseño Metodológico .....	32
3.4	Variables de la investigación .....	33
3.5	Técnicas de la investigación.....	34
3.6	Instrumentos de la investigación.....	35
3.7	Fuentes De Información.....	35
3.8	Recopilación de la información .....	36
3.8	Análisis de la información .....	36
3.9	Consideraciones éticas .....	39
Capítulo IV. Datos recolectados.....		40
Capítulo V. Resultados .....		42
5.1	Construcción De La Base De Datos De La Cantidad De Vehículos Eléctricos Registrados En Costa Rica Del 2010 Al 2025.....	43
5.2	Desarrollo del modelo de Redes Neuronales Autorregresivas (NNAR) .....	43
5.2.1	<i>Parámetros estructurales de la Red Neuronal Autorregresiva</i> .....	44
5.2.2	<i>Especificación Del Modelo</i> .....	51
5.2.3	<i>Resultados De La Proyección Del Modelo</i> .....	58
Capítulo VI. Análisis De Los Resultados.....		60
6.1	Objetivo Específico #1.....	60
6.2	Objetivo Específico # 2.....	62
6.3	Objetivo Específico #3.....	64
6.4	Análisis general de los resultados .....	66
Capítulo VII. Hallazgos y recomendaciones .....		69
7.1	Hallazgos De La Investigación .....	70
7.1.1	<i>Hallazgo 1: Crecimiento sostenido y acelerado del parque de vehículos eléctricos</i> .....	70

7.1.2 Hallazgo 2: <i>Presencia de patrones no lineales en la dinámica del fenómeno.</i>	70
7.1.3 Hallazgo 3: <i>Dependencia significativa de la historia reciente (memoria temporal).</i>	70
7.1.4 Hallazgo 4: <i>Ausencia de estacionalidad en la serie temporal.</i>	70
7.1.5 Hallazgo 5: <i>Adecuación del modelo NNAR para capturar la complejidad del fenómeno.</i>	71
7.1.6 Hallazgo 6: <i>Capacidad predictiva robusta validada fuera de muestra.</i>	71
7.1.7 Hallazgo 7: <i>Proyección de crecimiento continuo para el año 2026.</i>	71
7.1.8 Hallazgo 8: <i>Importancia del enfoque ensemble en la estabilidad del modelo.</i>	71
7.2 Recomendaciones de la Investigación	71
7.2.1 <i>Incorporar modelos de redes neuronales en la planificación pública</i>	72
7.2.2 <i>Fortalecer la infraestructura de movilidad eléctrica.</i>	72
7.2.3 <i>Diseñar políticas públicas basadas en evidencia predictiva.</i>	72
7.2.4 <i>Ampliar la base de datos y frecuencia de los registros.</i>	72
7.2.5 <i>Comparar con modelos alternativos en futuras investigaciones.</i>	72
7.2.6 <i>Realizar actualizaciones periódicas del modelo.</i>	73
Referencias Bibliográficas	73

## Índice de tablas

<b>Tabla 1. Variables de la investigación .....</b>	<b>33</b>
<b>Tabla 2. Información por recolectar .....</b>	<b>36</b>
<b>Tabla 3. Procesamiento de la información recolectada .....</b>	<b>37</b>
<b>Tabla 4. Vehículos eléctricos registrados en Costa Rica, 2010-2025 .....</b>	<b>40</b>
<b>Tabla 5. Red Neuronal NNAR. Parámetros de arquitectura .....</b>	<b>50</b>
<b>Tabla 6. Red Neuronal NNAR. Cuadro metodológico.....</b>	<b>50</b>

## Índice de ilustraciones

<b>Ilustración 1. Tratamiento de la información recolectada .....</b>	<b>32</b>
<b>Ilustración 2. Visualización de la red neuronal NNAR(4,8) .....</b>	<b>58</b>
<b>Ilustración 3. Pronóstico de vehículos eléctricos. Horizonte de un año (2026). .....</b>	<b>59</b>

## Glosario de términos

<b>Sigla</b>	<b>Detalle</b>
ARIMA	Modelos autorregresivo Integrado de Medias Móviles
RMSE	Root Mean Squared Error
NNAR	Neural Network Auto Regressive
IEA	Agencia Internacional de Energía
MIDEPLAN	Ministerio de Planificación Nacional y Política Económica
MINAE	Ministerio de Ambiente y Energía
ARESEP	Autoridad Reguladora de los Servicios Públicos
PND	Plan Nacional de Desarrollo
RNA	Redes Neuronales Artificiales
ASOMOVE	Asociación Costarricense de Movilidad Eléctrica

## **Capítulo I. Planteamiento del problema**

### **1.1. Problema**

El siguiente apartado detalla el problema de la investigación.

Durante la última década, la movilidad eléctrica ha adquirido un papel cada vez más relevante en las agendas de política pública, desarrollo sostenible y transformación energética a nivel mundial. El incremento en la preocupación por el cambio climático, la reducción de emisiones de gases de efecto invernadero y la dependencia de combustibles fósiles ha impulsado la adopción de tecnologías de transporte más limpias, entre ellas, los vehículos eléctricos. En este contexto, los países han comenzado a promover estrategias para acelerar la transición hacia flotas vehiculares más eficientes y menos contaminantes, mediante incentivos fiscales, mejoras en la infraestructura de carga y regulaciones ambientales más estrictas.

Costa Rica ha sido uno de los países latinoamericanos con mayor compromiso en materia de sostenibilidad ambiental y transición energética. El país ha construido una imagen internacional asociada a la protección del medio ambiente, el uso intensivo de energías renovables y la promoción de políticas de descarbonización. En el sector eléctrico, Costa Rica ha logrado una matriz de generación compuesta, en su gran mayoría, por fuentes renovables, lo cual convierte al país en un escenario particularmente favorable para la adopción de vehículos eléctricos, ya que estos pueden operar con energía de bajo impacto ambiental.

En este marco, el transporte eléctrico se ha posicionado como un componente clave dentro de las estrategias nacionales de descarbonización. El sector transporte ha sido, históricamente, uno de los principales emisores de gases de efecto invernadero en el país, debido a su alta dependencia de combustibles fósiles. Por ello, la promoción de vehículos

eléctricos ha sido considerada una medida estratégica para reducir las emisiones, mejorar la calidad del aire y disminuir la dependencia de hidrocarburos importados.

A partir de la aprobación de la Ley N° 9518 de Incentivos y Promoción para el Transporte Eléctrico en 2018, se estableció un conjunto de beneficios fiscales y regulatorios para fomentar la adquisición de vehículos eléctricos. Entre estos incentivos se encuentran exoneraciones de impuestos de importación, beneficios en el pago del marchamo, facilidades para la instalación de infraestructura de carga y estímulos para el desarrollo del transporte público eléctrico. Estas medidas han contribuido a un crecimiento progresivo del parque de vehículos eléctricos en el país, especialmente en los últimos años.

Sin embargo, a pesar del crecimiento observado, la adopción de vehículos eléctricos en Costa Rica sigue enfrentando múltiples desafíos. Entre los principales obstáculos se encuentran el alto costo inicial de los vehículos, la limitada infraestructura de carga en algunas regiones, la incertidumbre tecnológica, la disponibilidad de modelos en el mercado y las condiciones macroeconómicas que afectan la capacidad adquisitiva de los consumidores. Además, el ritmo de adopción puede verse influenciado por cambios en los incentivos fiscales, las políticas públicas, los precios de la energía y el comportamiento del mercado automotor.

En este contexto, surge la necesidad de contar con herramientas de análisis y predicción que permitan estimar el crecimiento futuro del parque de vehículos eléctricos. Las proyecciones de corto y mediano plazo son fundamentales para la toma de decisiones tanto en el sector público como en el privado. Las instituciones gubernamentales requieren estimaciones confiables para planificar la infraestructura de carga, diseñar políticas de incentivos, evaluar impactos fiscales y proyectar la demanda energética. Por su parte, las empresas del sector automotor, energético y financiero necesitan anticipar la evolución del mercado para orientar sus estrategias de inversión y comercialización.

Tradicionalmente, las proyecciones de variables económicas y tecnológicas se han realizado mediante modelos estadísticos clásicos, como los modelos de regresión lineal o los modelos autorregresivos integrados de medias móviles (ARIMA). No obstante, estos enfoques suelen basarse en supuestos de linealidad y estructuras de dependencia

relativamente simples. En el caso de la adopción de vehículos eléctricos, la dinámica del crecimiento puede presentar comportamientos no lineales, cambios estructurales, aceleraciones repentinas y efectos de difusión tecnológica que no son capturados adecuadamente por modelos lineales tradicionales.

En los procesos de adopción tecnológica, es común observar patrones de crecimiento exponencial en etapas tempranas, seguidos por fases de desaceleración a medida que el mercado se acerca a niveles de saturación. Además, la introducción de nuevas políticas, cambios en los precios internacionales de los combustibles, avances tecnológicos en baterías o la entrada de nuevos competidores al mercado pueden generar alteraciones abruptas en la tendencia histórica. Estas características hacen que la serie temporal de vehículos eléctricos posea una estructura compleja, donde las relaciones entre los valores pasados y futuros no necesariamente siguen patrones lineales.

En este sentido, los modelos de redes neuronales para series de tiempo han surgido como una alternativa flexible para el análisis predictivo. Estos modelos tienen la capacidad de aproximar relaciones no lineales complejas entre las observaciones pasadas y los valores futuros, sin requerir supuestos estrictos sobre la forma funcional de la serie. En particular, los modelos de redes neuronales autorregresivas (NNAR) combinan la estructura de los modelos autorregresivos con la flexibilidad de las redes neuronales, permitiendo capturar patrones no lineales en series temporales univariadas.

La falta de estimaciones precisas limita la capacidad de las instituciones públicas y privadas para planificar inversiones en infraestructura de recarga, gestionar la demanda energética, diseñar políticas públicas basadas en evidencia y evaluar los impactos económicos, ambientales y sociales de la transición hacia la movilidad eléctrica. Por tanto, se identifica la necesidad de explorar enfoques metodológicos alternativos, particularmente aquellos basados en inteligencia artificial, que permitan modelar de manera más adecuada la dinámica observada en la serie temporal de vehículos eléctricos registrados en el país.

El uso de modelos NNAR resulta especialmente pertinente en el contexto de la movilidad eléctrica, donde el comportamiento de la serie puede estar influenciado por múltiples factores tecnológicos, económicos y regulatorios. La calibración adecuada de estos

modelos, mediante la selección óptima de retardos y neuronas ocultas, permite mejorar la precisión de las predicciones y reducir los errores de estimación.

A pesar de la importancia estratégica de la movilidad eléctrica en Costa Rica, existe una limitada disponibilidad de estudios académicos que empleen técnicas avanzadas de modelado predictivo para estimar el crecimiento del parque de vehículos eléctricos. La mayoría de las proyecciones existentes se basan en escenarios de política pública, análisis de tendencias simples o supuestos exógenos sobre el crecimiento del mercado. Estas aproximaciones, aunque útiles para la planificación general, no siempre incorporan herramientas de análisis estadístico o de aprendizaje automático que permitan explotar de manera rigurosa la información contenida en la serie histórica.

En este contexto, surge la necesidad de desarrollar modelos predictivos que utilicen técnicas de ciencia de datos y aprendizaje automático para estimar el comportamiento futuro del parque de vehículos eléctricos en el país. La aplicación de modelos de redes neuronales a series temporales permite explorar patrones complejos en los datos y generar estimaciones más precisas, contribuyendo así a mejorar la base técnica para la toma de decisiones.

Desde una perspectiva práctica, la investigación busca generar información predictiva que sirva como insumo para la toma de decisiones estratégicas en materia de política pública, planificación energética, diseño de infraestructura y gestión del transporte. Una estimación confiable del crecimiento del parque vehicular eléctrico permite reducir la incertidumbre asociada a procesos de transformación tecnológica acelerada, optimizar la asignación de recursos y mejorar la coordinación entre actores públicos y privados.

El problema central de esta investigación radica en la incertidumbre sobre la cantidad de vehículos eléctricos que estarán registrados en Costa Rica para el año 2026, y en la necesidad de contar con un modelo predictivo que permita realizar esta estimación con un nivel adecuado de precisión. Dado que la serie histórica disponible abarca el período 2010–2025, se plantea la interrogante sobre qué tan efectiva puede ser una red neuronal autorregresiva, debidamente calibrada, para anticipar el valor de la serie en el siguiente período.

Esta problemática se traduce en la siguiente pregunta de investigación: ¿en qué medida un modelo de redes neuronales autorregresivo para series de tiempo, calibrado con datos históricos del período 2010–2025, permite estimar con precisión la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 y generar proyecciones confiables que contribuyan a la planificación estratégica del desarrollo?

Por tanto, la investigación responde al problema metodológico y aplicado de cómo modelar adecuadamente una serie de tiempo con posibles patrones no lineales y dinámicas de crecimiento acelerado, utilizando un enfoque de redes neuronales autorregresivas (NNAR), que permita mejorar la precisión predictiva frente a enfoques tradicionales. En términos concretos, el estudio busca determinar en qué medida un modelo de redes neuronales calibrado y validado rigurosamente puede generar una estimación precisa y técnicamente defendible del número de vehículos eléctricos registrados en 2026.

Responder a esta pregunta implica analizar la estructura temporal de la serie, diseñar y calibrar diferentes configuraciones del modelo NNAR, y evaluar su desempeño predictivo mediante validación fuera de muestra. De esta manera, la investigación no solo busca generar una estimación puntual para el año 2026, sino también demostrar la utilidad de los modelos de redes neuronales como herramientas de predicción en el ámbito del transporte eléctrico.

De esta forma, la investigación contribuye a lo siguiente:

1. Reducir la incertidumbre en la toma de decisiones públicas.
2. Proveer evidencia empírica para la planificación estratégica del sector transporte–energía.
3. Incorporar técnicas avanzadas de ciencia de datos en el análisis de políticas públicas.
4. Evaluar la pertinencia del modelado no lineal en series temporales de adopción tecnológica.

En síntesis, el planteamiento del problema se fundamenta en tres elementos principales: primero, la creciente importancia de la movilidad eléctrica en la estrategia de descarbonización de Costa Rica; segundo, la necesidad de contar con estimaciones confiables para la planificación de políticas públicas y decisiones empresariales; y tercero,

la oportunidad de aplicar modelos de redes neuronales para mejorar la precisión de las proyecciones basadas en series temporales. Estos elementos convergen en la necesidad de desarrollar y validar un modelo predictivo que permita estimar la cantidad de vehículos eléctricos registrados en el país para el año 2026, utilizando técnicas modernas de ciencia de datos aplicadas a la información histórica disponible.

## **1.2. Objetivos**

Los siguientes apartados detallan los objetivos de la investigación.

### ***1.2.1. Objetivo General De La Investigación***

Estimar con precisión la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026, mediante el diseño, calibración y validación de un modelo predictivo de redes neuronales autorregresivas aplicado a una serie de tiempo anual del período 2010–2025, y generar proyecciones confiables que contribuyan a la planificación estratégica del desarrollo.

### ***1.2.2. Objetivos Específicos De La Investigación***

1. Analizar la serie temporal de vehículos eléctricos registrados en Costa Rica para el período 2010–2025, identificando su tendencia, comportamiento temporal, posibles patrones no lineales y condiciones de estacionalidad relevantes para el modelado predictivo.
2. Diseñar un modelo de redes neuronales autorregresivas para series de tiempo (NNAR), evaluando diferentes configuraciones de retardos y neuronas ocultas, con el fin de seleccionar la arquitectura óptima mediante criterios de desempeño predictivo (Raíz del Error Cuadrático Medio).
3. Evaluar la capacidad predictiva del modelo seleccionado mediante validación fuera de muestra, por medio de la estimación de la cantidad de vehículos eléctricos

registrados para el año 2026, para así generar proyecciones confiables que contribuyan a la planificación estratégica del desarrollo.

### **1.3. Justificación**

La transición hacia la movilidad eléctrica constituye uno de los cambios tecnológicos y energéticos más relevantes del siglo XXI, debido a sus implicaciones económicas, ambientales y sociales. En este contexto, la estimación de la cantidad de vehículos eléctricos registrados en un país no solo representa un ejercicio técnico de proyección estadística, sino también una herramienta estratégica para la planificación pública, la toma de decisiones en infraestructura y la formulación de políticas energéticas. La presente investigación, orientada a estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 mediante un modelo de redes neuronales aplicado a una serie temporal del período 2010–2025, se justifica tanto por su relevancia académica como por su pertinencia para el desarrollo nacional.

En primer lugar, la movilidad eléctrica ha adquirido una importancia creciente a nivel global, especialmente en los países en desarrollo, donde se presenta como una alternativa viable para reducir la dependencia de combustibles fósiles, mejorar la calidad del aire y disminuir los costos operativos del transporte. Precisamente, una de las principales razones por las cuales los vehículos eléctricos son considerados como objetivo de compra a nivel mundial sobre los tradicionales que utilizan combustibles comunes, es que los eléctricos son mucho más eficientes (Hnatova, 2019).

Desde una perspectiva ambiental, los vehículos eléctricos representan una alternativa clave para la mitigación del cambio climático y la reducción de emisiones contaminantes. Investigaciones recientes destacan que la adopción masiva de estos vehículos puede reducir las emisiones de dióxido de carbono por kilómetro recorrido, disminuir la contaminación del aire urbano y generar beneficios directos para la salud pública y el bienestar social (Al Noman & Siam, 2025). Estos efectos adquieren especial relevancia en países con matrices energéticas basadas en fuentes renovables, donde el impacto ambiental del transporte eléctrico es aún más favorable.

En el caso específico de Costa Rica, la movilidad eléctrica se ha convertido en un componente fundamental de la estrategia nacional de descarbonización. El país ha logrado posicionarse como líder regional en adopción de vehículos eléctricos, alcanzando niveles de penetración superiores a los de otras naciones del continente.

Este crecimiento sostenido plantea nuevos desafíos para la planificación energética, la infraestructura de recarga, la gestión de redes eléctricas y el diseño de incentivos fiscales. Para enfrentar estos desafíos, resulta indispensable contar con estimaciones confiables sobre la evolución futura del parque vehicular eléctrico. Sin embargo, en muchos casos, las decisiones de política pública y planificación se basan en proyecciones simples o en supuestos lineales, que no capturan adecuadamente la naturaleza no lineal y acelerada de los procesos de adopción tecnológica.

En este contexto, la presente investigación adquiere relevancia, ya que propone la aplicación de un modelo de redes neuronales autorregresivas para series de tiempo (NNAR), el cual permite capturar patrones complejos y no lineales presentes en los datos históricos. Las redes neuronales han demostrado ser herramientas eficaces para el análisis predictivo en contextos donde los modelos tradicionales presentan limitaciones, especialmente en series temporales con crecimiento acelerado, cambios estructurales o comportamientos irregulares. En este sentido, el uso de técnicas de aprendizaje automático representa un aporte metodológico importante para el análisis de la movilidad eléctrica en Costa Rica.

Desde el punto de vista académico, esta investigación contribuye al campo de la ciencia de datos aplicada al análisis de políticas públicas y transporte sostenible. En particular, aporta evidencia empírica sobre el desempeño de modelos de redes neuronales en series temporales cortas y con crecimiento no lineal, como es el caso del parque vehicular eléctrico. Además, el estudio integra las etapas de análisis exploratorio, diseño del modelo, calibración y validación fuera de muestra, lo que fortalece su rigor metodológico.

Desde el punto de vista práctico, los resultados de esta investigación pueden ser útiles para diversas instituciones públicas y privadas. Por ejemplo, las entidades encargadas de la planificación energética pueden utilizar las proyecciones para estimar la demanda futura de electricidad asociada al transporte. Del mismo modo, las autoridades de transporte pueden

emplear estas estimaciones para planificar la expansión de la infraestructura de recarga y ajustar los incentivos fiscales de manera eficiente. También el sector privado, como importadores, distribuidores de vehículos y empresas de infraestructura de carga, puede beneficiarse de proyecciones más precisas para orientar sus decisiones de inversión.

Otra justificación importante radica en la necesidad de fortalecer la toma de decisiones basada en datos. La planificación del transporte sostenible requiere herramientas analíticas que permitan anticipar tendencias y evaluar el impacto de políticas públicas. En este sentido, el uso de modelos predictivos avanzados contribuye a mejorar la calidad de la información disponible para los tomadores de decisiones y a reducir el riesgo de errores de planificación.

En síntesis, esta investigación se justifica por tres razones principales. En primer lugar, por la importancia estratégica de la movilidad eléctrica en el contexto de la transición energética y la descarbonización del transporte. En segundo lugar, por el crecimiento acelerado del parque vehicular eléctrico en Costa Rica, lo cual exige herramientas predictivas más precisas para la planificación pública y privada. Y, en tercer lugar, por el aporte metodológico que representa la aplicación de modelos de redes neuronales a la estimación de series temporales con comportamientos no lineales.

Por lo tanto, la estimación de la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026, mediante un modelo de redes neuronales debidamente calibrado y validado, no solo constituye un ejercicio académico relevante, sino también una herramienta práctica para la planificación del transporte sostenible, la formulación de políticas públicas y la toma de decisiones estratégicas en el país.

## **1.4. Antecedentes**

El siguiente apartado detalla los elementos más importantes de los antecedentes de la investigación.

Durante la última década, la movilidad eléctrica ha adquirido una relevancia creciente en el ámbito internacional como una de las principales estrategias para reducir emisiones de gases de efecto invernadero en el sector transporte. Este sector representa una proporción significativa del consumo energético mundial y de las emisiones asociadas al uso de combustibles fósiles, por lo que la transición hacia tecnologías de propulsión eléctrica se ha convertido en una prioridad en políticas públicas de numerosos países. Este escenario global ha impulsado el desarrollo de investigaciones en ciencia de datos y modelización predictiva que permiten estimar tendencias futuras de adopción de tecnologías limpias, como los vehículos eléctricos, utilizando herramientas avanzadas de análisis de series de tiempo.

### **1.4.1 Antecedentes internacionales**

En el contexto descrito, donde la movilidad eléctrica se consolida como una respuesta estratégica frente a los desafíos ambientales y energéticos a nivel global, resulta fundamental comprender no solo el comportamiento histórico de su adopción, sino también anticipar su evolución futura mediante herramientas analíticas robustas. En este sentido, la aplicación de modelos predictivos basados en redes neuronales para el análisis de series de tiempo ha emergido como una alternativa metodológica capaz de capturar patrones no lineales y dinámicas complejas que caracterizan la difusión de tecnologías emergentes.

Por tanto, el estudio de antecedentes internacionales permite contextualizar la presente investigación dentro de un marco comparativo más amplio, identificando enfoques, metodologías y resultados obtenidos en distintos países, lo cual contribuye a fortalecer el sustento teórico y empírico del modelo propuesto para estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026.

En primer lugar, según la Agencia Internacional de Energía (IEA), en el informe World Energy Outlook para el año (2020), indica que el sector transporte es responsable de aproximadamente 23%–24% de las emisiones globales de CO<sub>2</sub> relacionadas con la energía. Además, cerca del 95% de la energía consumida por el transporte proviene de combustibles fósiles, lo que confirma su alta dependencia del petróleo y su contribución estructural al cambio climático. Este dato sustenta la idea de que cualquier estrategia de descarbonización global necesariamente debe intervenir este sector. En este sentido, la necesidad imperiosa de generar energías alternativas menos contaminantes ha sido una prioridad de los Gobiernos durante los últimos años, más aun tomando en cuenta el auge de los proyectos de movilidad eléctrica.

En segundo lugar, el crecimiento de los vehículos eléctricos ha sido exponencial durante la última década. De acuerdo con el informe Global EV Outlook para el año (2024) de la Agencia Internacional de Energía, el parque mundial de vehículos eléctricos pasó de menos de 200 mil unidades en 2012 a más de 40 millones de unidades en 2023, lo que implica una tasa de crecimiento acumulada extraordinaria en poco más de diez años.

De acuerdo con el citado informe, solo en 2023 se vendieron aproximadamente 14 millones de vehículos eléctricos a nivel mundial, representando cerca del 18% de las ventas totales de automóviles nuevos. Esta evolución estadística evidencia que la movilidad eléctrica dejó de ser una tecnología incipiente para convertirse en un componente estructural del mercado automotor. En relación con lo anterior, este antecedente es evidencia inequívoca de la importancia de la puesta en marcha de proyectos de movilidad eléctrica.

De acuerdo con Yengil-Bülbül y Baydar, (2025), en su artículo denominado como *Decarbonizing Transportation: Cross-Country Evidence on Electric Vehicle Sales and Carbon Dioxide Emissions*, el crecimiento de las ventas de vehículos eléctricos (EV) a nivel mundial ha sido exponencial, superando los 17 millones de unidades en 2024 y representando más del 20 % de las ventas totales de automóviles. Este aumento ha contribuido a reducir la demanda de petróleo y es un indicador central en los procesos globales de descarbonización del transporte. Así las cosas, este antecedente marca un hito en términos de la relevancia de las iniciativas de movilidad eléctrica en el mundo.

Un artículo científico reciente desarrollado por Zaino, Ahmed, Alhammadi y Alghoush, (2024), denominado como *Electric vehicle adoption: A comprehensive systematic review of technological, environmental, organizational and policy impacts*, identifica los diversos efectos tecnológicos, ambientales y de políticas públicas asociados con la adopción de vehículos eléctricos, destacando cómo estos factores influyen en la transición hacia un transporte más sostenible y bajo en emisiones. En dicho artículo se pone de manifiesto el marcado interés de los países en desarrollar políticas tendientes a darle especial focalización al desarrollo de proyectos sostenibles, sobre todo de movilidad eléctrica, elemento que sustenta los contenidos de la presente investigación.

Un artículo científico escrito por Ramadoss, Lee, Davis y Hardman (2025), denominado como *Classifying electric vehicle adopters and forecasting progress to full adoption* clasifica los diferentes grupos de adoptantes de vehículos eléctricos y proyecta las trayectorias de adopción, lo cual es fundamental para planear políticas de infraestructura, incentivos y equidad en la transición hacia sistemas de transporte más limpios. En relación con lo anterior, este antecedente es relevante para la investigación porque pone de manifiesto la tendencia de las economías hacia la movilidad eléctrica.

Estudios recientes, como el desarrollado por Adamashvili y Thrassou (2024), denominado como *Towards sustainable decarbonization: Addressing challenges in electric vehicle adoption and infrastructure development* subrayan que el despliegue de vehículos eléctricos es clave para lograr una descarbonización sostenible del transporte, aunque también señalan desafíos como la infraestructura de recarga, aceptación social y políticas integradas para fortalecer la transición energética. Este antecedente es especialmente importante porque fortalece el criterio de que la movilidad eléctrica es un elemento fundamental de las políticas y planes de descarbonización.

De acuerdo con Lukuyo y Taneja (2024), la adopción de vehículos eléctricos también plantea nuevos desafíos para los sistemas eléctricos, especialmente en ciudades africanas. Investigaciones recientes muestran cómo una mayor penetración de los EV afecta las redes de distribución y requieren estrategias de gestión para asegurar que dicha integración apoye

la descarbonización y estabilidad energética. En este sentido, este antecedente pone de manifiesto el desafío de los países de darle sostenibilidad operativa a las iniciativas de movilidad eléctrica, con el fin de garantizar su operatividad en el tiempo.

En particular, el uso de modelos de redes neuronales para series de tiempo se ha consolidado como una alternativa potente frente a los métodos tradicionales, especialmente cuando los patrones de crecimiento son no lineales y presentan tendencias aceleradas que no pueden ser capturadas adecuadamente por modelos lineales clásicos. Este enfoque ha ganado importancia en escenarios donde los datos históricos muestran comportamientos complejos y donde se busca generar proyecciones precisas para la toma de decisiones estratégicas (Zhang et al., 1998; Elman, 1990). Así las cosas, el uso de modelos predictivos basados en redes neuronales, han ido ganando terreno dentro de la industria dada su capacidad de modelar estimaciones basados en series de tiempo no lineales, típicas del sector de movilidad eléctrica.

#### **1.4.2 Antecedentes nacionales**

En el ámbito nacional, el análisis del comportamiento de la movilidad eléctrica adquiere una relevancia particular, dado que Costa Rica ha impulsado activamente políticas orientadas a la descarbonización del sector transporte y a la adopción de tecnologías limpias. En este contexto, resulta fundamental examinar los estudios y reportes desarrollados a nivel país que abordan la evolución del parque vehicular eléctrico, sus determinantes y proyecciones, ya que estos aportan evidencia empírica clave sobre la dinámica local del fenómeno.

La revisión de antecedentes nacionales permite, por tanto, comprender las características específicas del crecimiento de los vehículos eléctricos en Costa Rica, identificar posibles patrones y limitaciones en su análisis, y establecer una base sólida que justifique la aplicación de modelos predictivos avanzados, como las redes neuronales autorregresivas, en la estimación de su comportamiento futuro hacia el año 2026.

Costa Rica constituye un caso de estudio particularmente relevante en la región de América Latina en términos de adopción de movilidad eléctrica. A diferencia de muchos

países latinoamericanos, Costa Rica ha integrado la movilidad eléctrica dentro de su agenda nacional de sostenibilidad, lo cual se refleja tanto en políticas públicas como en el crecimiento exponencial del parque automotor eléctrico en los últimos años. Según un estudio encabezado por el Ministerio de Planificación Nacional y Política Económica (Mideplan) en 2025, denominado “*Movilidad eléctrica en Costa Rica: Oportunidades para una sociedad descarbonizada. Avances 2020-2024*”, el parque automotor eléctrico en Costa Rica creció en un 507 % entre diciembre de 2020 y septiembre de 2024, consolidando al país como un referente regional en movilidad limpia y sostenible. Este antecedente cimienta el desarrollo de la presente investigación en términos del fuerte crecimiento del mercado de movilidad eléctrica en el país durante los últimos años, elemento que se tomó en cuenta al momento de la calibración de los hiper parámetros de la red neuronal desarrollada.

Este crecimiento no solo representa un cambio cuantitativo en el número de unidades vehiculares, sino que también evidencia la adopción de tecnologías que funcionan con electricidad generada principalmente por fuentes renovables dentro del país, reforzando la independencia energética y la reducción de emisiones de Dióxido de Carbono (Mideplan, 2025).

Este estudio resalta varias ventajas asociadas a la movilidad eléctrica en Costa Rica. Primero, el uso de electricidad 100 % renovable permite maximizar los beneficios ambientales de los vehículos eléctricos al reducir las emisiones locales y globales. Segundo, estos vehículos presentan costos de operación y mantenimiento significativamente más bajos que los de combustión interna, lo cual representa un incentivo económico importante para los consumidores y las empresas (Mideplan, 2025). Sin embargo, el estudio también identifica retos como la infraestructura de recarga aún insuficiente y la necesidad de una mejor comunicación hacia los potenciales usuarios sobre los beneficios y oportunidades de los vehículos eléctricos.

Diversos estudios han señalado que la movilidad eléctrica constituye uno de los pilares centrales de la estrategia de descarbonización de Costa Rica. El país adoptó el Plan Nacional de Descarbonización (el cual se cataloga como uno de los antecedentes de la presente investigación) con metas explícitas de electrificación del transporte público y privado, estableciendo objetivos de penetración de vehículos eléctricos en la flota nacional

para las próximas décadas. Informes de organismos internacionales como la OCDE, en su estudio denominado *Environmental Performance Reviews: Costa Rica 2023*, destacan que dicho plan otorga una importancia prioritaria a la electrificación del transporte, con metas de alcanzar una participación significativa de vehículos eléctricos en la flota hacia 2035 y una penetración casi total para 2050.

En este sentido, tanto el Plan Nacional de Descarbonización como los informes citados de la OCDE, incluyen acciones claras tendientes a fortalecer el sector de la movilidad eléctrica, elemento que, sin lugar a dudas, moldea un escenario de marcado crecimiento en las proyecciones futuras.

Ahora bien, históricamente, un hito fundamental fue la promulgación de la Ley N° 9518, Ley de Incentivos y Promoción para el Transporte Eléctrico, en 2018, la cual estableció exoneraciones fiscales, beneficios arancelarios e incentivos no tributarios para la importación y uso de vehículos eléctricos. Esta normativa marcó el inicio formal de la transición hacia la electromovilidad en el país. Posteriormente, el Gobierno de Costa Rica presentó el Plan Nacional de Descarbonización 2018–2050, que posiciona al transporte eléctrico como eje estratégico para alcanzar emisiones netas cero en el largo plazo, particularmente mediante la electrificación del transporte público y privado.

Estas acciones, sin duda, se enmarcan en una tendencia al alza en la cantidad de vehículos eléctricos utilizados en el país, factor que genera una visualización de crecimiento futuro, tal y como se plantea en el modelo de redes neuronales propuesto. Este antecedente fue crucial como parte de los esfuerzos por promulgar política pública de calidad en el ámbito de la institucionalidad de la descarbonización.

Segundo, en el ámbito del diagnóstico estructural del sector transporte, el Programa Estado de la Nación ha documentado que el transporte es uno de los principales emisores de gases de efecto invernadero en el país, representando cerca del 40% de las emisiones energéticas nacionales. Sus informes han señalado la alta dependencia del parque vehicular respecto a combustibles fósiles y la necesidad de modernizar la flota vehicular. Este diagnóstico macroestructural proporciona el sustento empírico para justificar políticas de

electrificación progresiva del transporte. Estos informes incluyen al Informe del Programa Estado de la Nación en desarrollo humano sostenible del 2018.

En este sentido, este antecedente marca claramente el hecho de que el país ha ido buscando alternativas energéticas fuera de los combustibles fósiles, elemento que ha caracterizado el marcado crecimiento del sector en términos de demanda de vehículos de movilidad eléctrica.

En tercera instancia, en relación con la evolución del parque vehicular eléctrico, el Ministerio de Ambiente y Energía (MINAE), a través de la Dirección de Energía, ha publicado balances energéticos nacionales y reportes técnicos donde se evidencia el crecimiento sostenido del número de vehículos eléctricos inscritos, especialmente a partir de 2018. Estos informes incluyen al reporte denominado como Balance Energético Nacional 2022, emitido por el Ministerio de Ambiente y Energía (MINAE).

Los registros administrativos muestran una tendencia exponencial en la matrícula anual, lo cual constituye una serie temporal idónea para modelado predictivo mediante redes neuronales. Este tipo de informes, en términos de antecedentes, complementan adecuadamente los objetivos de la investigación, en términos de poner de manifiesto la importancia y el crecimiento de la movilidad eléctrica en el país.

Cuarto, como parte de un análisis académico de la transición energética costarricense, en el artículo escrito por Okot, Solís-Barquero y Valverde, 2021, denominado como Potential of renewable energy production: an assessment of Costa Rica's decarbonization plan se evalúa el potencial de producción de energía renovable y los planes de descarbonización en Costa Rica, analizando cómo la matriz energética verde puede contribuir tanto al desarrollo sostenible como a la reducción de emisiones. Este antecedente proporciona una base importante a los esfuerzos del país por descarbonizar la economía, en clara concordancia con el auge del mercado de movilidad eléctrica en mundo y en el país.

La Autoridad Reguladora de los Servicios Públicos (ARESEP), como parte de los esfuerzos por desarrollar y poner en práctica una estrategia de electrificación del transporte

público, ha impulsado estudios técnicos para la incorporación de autobuses eléctricos en rutas urbanas, particularmente en el Gran Área Metropolitana.

Estos estudios, como por ejemplo el Estudio técnico sobre autobuses eléctricos en Costa Rica del 2020, han evaluado costos operativos, reducción de emisiones y factibilidad financiera. Este estudio, sin duda, se enmarca, tal y como se ha mencionado en este apartado, dentro de los esfuerzos del país por dar especial importancia a la movilidad eléctrica como estrategia para reducir la contaminación ambiental.

### **1.4.3 Marco político: Plan Nacional de Descarbonización**

El crecimiento de la movilidad eléctrica en Costa Rica no es producto del azar, sino parte de una política pública deliberada enmarcada dentro del Plan Nacional de Descarbonización 2018–2050 (PND), el cual constituye el principal instrumento estratégico que guía la política climática y ambiental del país en las próximas décadas.

El PND establece metas claras de reducción de emisiones de Gases de Efecto Invernadero, con énfasis en la transformación del sector transporte, considerado uno de los principales contribuyentes a las emisiones nacionales. Dentro del eje de “Movilidad sostenible y transporte público”, el PND incluye metas como la electrificación de una proporción significativa de la flota pública y privada en el corto y mediano plazo, así como la expansión de infraestructura de apoyo como estaciones de carga y la transformación de rutas urbanas hacia sistemas de transporte cero emisiones (Minae, 2025).

Estas metas buscan no solo reducir las emisiones de carbono, sino también fomentar una cultura de movilidad más sostenible en las áreas urbanas y periurbanas del país. El PND contempla, por ejemplo, que para 2035 una parte importante de los vehículos nuevos en circulación sean cero emisiones y que la infraestructura de carga se expanda de forma articulada con la demanda proyectada.

Este enfoque estratégico refuerza la importancia de contar con proyecciones confiables sobre el crecimiento de los vehículos eléctricos, ya que dichas proyecciones se convierten en insumos fundamentales para diseñar políticas, **programas de incentivos y planes**

**de infraestructura acordes con los compromisos nacionales e internacionales de descarbonización.**

En síntesis, el Plan Nacional de Descarbonización 2018–2050 no solo establece el marco estratégico que orienta la transición hacia una movilidad sostenible en Costa Rica, sino que también evidencia la necesidad de incorporar herramientas analíticas que permitan anticipar con mayor precisión la evolución del parque vehicular eléctrico. En este sentido, la presente investigación se alinea directamente con los objetivos del PND, al proponer un modelo predictivo basado en redes neuronales que contribuya a generar estimaciones confiables sobre la cantidad de vehículos eléctricos para el año 2026.

Dichas estimaciones representan un insumo clave para la toma de decisiones en materia de planificación energética, diseño de infraestructura de carga y formulación de políticas públicas, fortaleciendo así la capacidad del país para avanzar de manera efectiva hacia sus metas de descarbonización.

#### ***1.4.4 Implicaciones Para La Presente Investigación***

Los antecedentes revisados muestran que Costa Rica ha experimentado un crecimiento acelerado en la adopción de vehículos eléctricos que está estrechamente vinculado a políticas públicas de descarbonización y a la promoción de tecnologías limpias. Sin embargo, aunque existen informes descriptivos y análisis de tendencias de adopción, aún se carece de estudios que utilicen metodologías cuantitativas avanzadas para proyectar de manera precisa la evolución futura del parque vehicular eléctrico, especialmente mediante modelos predictivos robustos como las redes neuronales autorregresivas para series de tiempo.

La presente investigación busca contribuir a este vacío metodológico mediante el diseño, calibración y validación de un modelo de redes neuronales para series de tiempo capaz de estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026, usando datos anuales entre 2010 y 2025. La elección de este enfoque se basa en su capacidad para capturar patrones no lineales, tendencias complejas y comportamientos

dinámicos que podrían escapar a modelos más tradicionales, lo cual es particularmente relevante en un contexto de rápida evolución tecnológica y de mercado.

## **Capítulo II. Marco Teórico**

### **2.5. Marco Teórico**

El siguiente apartado detalla los conceptos más relevantes acerca del marco teórico de la investigación.

#### ***2.5.1 Redes Neuronales Artificiales: Fundamentos Conceptuales***

Las redes neuronales artificiales (RNA) constituyen modelos computacionales inspirados en el funcionamiento del sistema nervioso biológico del ser humano, diseñados para identificar patrones complejos en datos y aproximar funciones no lineales mediante procesos de aprendizaje automático. Desde una perspectiva formal, una red neuronal se compone de neuronas artificiales organizadas en capas (entrada, ocultas y salida), conectadas por pesos sinápticos que se ajustan durante el proceso de entrenamiento para minimizar una función de error (Goodfellow, Bengio, & Courville, 2016).

De acuerdo con Goodfellow et al. (2016), el aprendizaje en redes neuronales profundas se basa en la optimización de parámetros mediante algoritmos como el descenso por gradiente y la retropropagación del error, permitiendo que el modelo capture relaciones altamente no lineales entre variables. Esta capacidad resulta especialmente relevante en contextos donde los procesos subyacentes no siguen patrones lineales simples, como ocurre en fenómenos tecnológicos, económicos o sociales.

Asimismo, Chollet (2018) señala que las redes neuronales modernas han demostrado una elevada capacidad predictiva cuando se dispone de datos históricos suficientes, ya que pueden modelar interacciones complejas sin necesidad de especificar explícitamente la forma funcional del modelo. Esta característica la diferencia de los modelos econométricos tradicionales, los cuales requieren supuestos estructurales previos.

En el ámbito de la ciencia de datos aplicada a series temporales, las redes neuronales permiten capturar dinámicas no lineales, cambios estructurales y comportamientos emergentes que podrían no ser detectados por modelos clásicos como ARIMA. En consecuencia, su aplicación en la estimación del crecimiento del parque vehicular eléctrico en Costa Rica resulta teóricamente pertinente, dado el carácter dinámico y potencialmente acelerado del proceso de adopción tecnológica.

### ***2.5.2 Red Neuronal Autorregresiva (NNAR) Para Series De Tiempo***

Las redes neuronales autorregresivas para series de tiempo constituyen una adaptación de las RNA al análisis de datos secuenciales. En este enfoque, los valores pasados de la serie se utilizan como entradas del modelo para predecir valores futuros, siguiendo una estructura análoga a los modelos autorregresivos clásicos, pero incorporando una capa oculta que introduce no linealidad (Hyndman & Athanasopoulos, 2021).

Según Hyndman y Athanasopoulos (2021), el modelo NNAR ( $p, k$ ) se puede interpretar como una red neuronal feedforward con  $p$  retardos como entradas y  $k$  neuronas en la capa oculta. La diferencia fundamental respecto a un modelo AR( $p$ ) radica en que la relación entre los retardos y la variable dependiente no se restringe a una combinación lineal, sino que se transforma mediante funciones de activación no lineales.

James, Witten, Hastie y Tibshirani (2021) explican que los métodos no lineales como las redes neuronales resultan particularmente útiles cuando la estructura de dependencia temporal no puede representarse adecuadamente mediante parámetros lineales. En el caso de la adopción de vehículos eléctricos, es plausible la existencia de efectos de aceleración, saturación o influencia de políticas públicas que generen trayectorias no lineales en el tiempo.

El uso del modelo NNAR permite, por tanto, capturar posibles patrones de crecimiento exponencial inicial, cambios abruptos asociados a incentivos fiscales o variaciones en precios internacionales de combustibles. Su calibración implica la selección óptima del número de retardos ( $p$ ) y del número de neuronas ocultas ( $k$ ), generalmente

mediante criterios de desempeño predictivo como la Raíz del Error Cuadrático Medio (RMSE).

En consecuencia, la fundamentación teórica del modelo NNAR respalda su aplicación para estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026, partiendo de la serie anual 2010–2025.

### ***2.5.3 Modelos Predictivos Y Validación Fuera De Muestra***

Un modelo predictivo se define como una representación matemática o computacional orientada a estimar valores futuros o desconocidos a partir de información histórica. En el marco del aprendizaje estadístico, la calidad de un modelo predictivo se evalúa por su capacidad de generalización, es decir, su desempeño sobre datos no utilizados durante el entrenamiento (James et al., 2021).

Hastie, Tibshirani y Friedman (2017) sostienen que la validación fuera de muestra constituye un componente esencial para evitar el sobreajuste (overfitting), fenómeno que ocurre cuando el modelo aprende excesivamente los patrones específicos del conjunto de entrenamiento y pierde capacidad de predicción en nuevos datos. En series temporales, esta validación suele implementarse mediante esquemas de división temporal, donde los datos más recientes se reservan para prueba.

La utilización del RMSE como métrica de evaluación responde a su capacidad para penalizar de manera más severa los errores grandes, lo cual resulta adecuado en contextos donde desviaciones significativas podrían afectar la toma de decisiones de política pública.

En esta investigación, la estimación para el año 2026 constituye un ejercicio de validación prospectiva, que permite evaluar la robustez del modelo NNAR calibrado con la información histórica 2010–2025.

### ***2.5.4 Movilidad Eléctrica***

La movilidad eléctrica se refiere al uso de vehículos impulsados total o parcialmente por energía eléctrica almacenada en baterías recargables o mediante sistemas híbridos que

integran movilidad con fuentes energéticas limpias. Este concepto implica no solo una sustitución tecnológica de los motores de combustión interna, sino también una transformación hacia sistemas de transporte sostenibles, con menores emisiones de gases de efecto invernadero y una reducción de la dependencia de combustibles fósiles, especialmente cuando se integra con fuentes de energía renovable (Electric Vehicle and Renewable Energy Sources, 2021).

Desde una perspectiva sistémica, la movilidad eléctrica no solamente trae consigo un cambio tecnológico, sino también transformaciones en los sistemas energéticos, redes eléctricas y marcos regulatorios. En Costa Rica, país caracterizado por una matriz eléctrica mayoritariamente renovable, la electrificación del transporte adquiere relevancia estratégica al permitir que la reducción de emisiones sea aún más significativa en términos relativos.

### ***2.5.5 Energías Renovables***

Las energías renovables verdes comprenden fuentes como la hidráulica, eólica, solar, geotérmica y biomasa, cuya principal característica es su capacidad de regeneración natural y baja emisión de carbono. Boyle (2017) sostiene que la expansión de energías renovables constituye un elemento esencial para mitigar el cambio climático y garantizar seguridad energética a largo plazo.

Twidell y Weir (2015) argumentan que la integración de energías renovables en los sistemas eléctricos nacionales reduce la intensidad de carbono de la generación eléctrica, potenciando los beneficios ambientales de tecnologías como los vehículos eléctricos. Cuando la electricidad proviene de fuentes renovables, la huella de carbono total del ciclo de vida del vehículo disminuye considerablemente. Es importante indicar, por lo tanto, que la idea de los autores cuando citan a entornos nacionales se refiere a los ecosistemas de generación eléctrica de los países en general.

En el caso costarricense, la alta participación de fuentes renovables fortalece la coherencia entre movilidad eléctrica y sostenibilidad ambiental, generando un entorno propicio para el crecimiento del parque vehicular eléctrico.

### ***2.5.6 Descarbonización Y Eficiencia Energética***

La descarbonización se refiere al proceso de reducción progresiva de emisiones de carbono en los sistemas productivos y energéticos. Grubb, Hourcade y Neuhoff (2014) explican que la transición hacia economías bajas en carbono requiere innovación tecnológica, instrumentos regulatorios e incentivos económicos que orienten las decisiones de inversión hacia alternativas limpias.

La adopción de vehículos eléctricos contribuye a la eficiencia energética debido a que los motores eléctricos presentan mayores rendimientos que los motores de combustión interna. Esta ventaja técnica, combinada con una matriz eléctrica renovable, fortalece el argumento estructural para proyectar un crecimiento sostenido del número de vehículos eléctricos en Costa Rica.

### ***2.5.7 Integración Conceptual Del Marco Teórico***

La presente investigación articula dos dimensiones teóricas complementarias. Por un lado, la dimensión metodológica, sustentada en el aprendizaje profundo, modelos predictivos y redes neuronales autorregresivas. Por otro, la dimensión sustantiva, relacionada con la transición energética, movilidad eléctrica y descarbonización.

Desde el punto de vista metodológico, las redes neuronales ofrecen herramientas robustas para modelar dinámicas no lineales y realizar proyecciones basadas en patrones históricos complejos. Desde el punto de vista estructural, el crecimiento del parque vehicular eléctrico responde a tendencias globales asociadas a la transición hacia energías limpias y políticas de reducción de emisiones.

En consecuencia, el uso de un modelo NNAR calibrado y validado empíricamente constituye una estrategia metodológica coherente para estimar la cantidad de vehículos eléctricos registrados en Costa Rica en 2026, integrando fundamentos de ciencia de datos con el contexto energético y ambiental contemporáneo.

## **Capítulo III. Metodología**

### **3.1 Tipo De Investigación**

La presente investigación se tipifica como exploratorio-predictivo y de carácter cuantitativa, dado que explora la aplicabilidad del modelo de Redes Neuronales Autorregresivas y, al mismo tiempo, genera pronósticos a partir de una serie de tiempo. Adicionalmente, no hay trabajos académicos previos en la temática específica que se aborda, e incluye variables de índole numéricas que serán examinadas.

### **3.2 Tipo De Alcance**

La presente investigación se ubica en un nivel descriptivo-predictivo con un componente explicativo leve. Se denota un elemento descriptivo porque se analiza la serie de tiempo de 2010 al 2025, y se identifican tendencias, patrones y comportamiento no lineal.

Se define un alcance predictivo, porque se diseña un modelo NNAR, se calibran diferentes configuraciones y se realiza una estimación futura para el año 2026. En términos generales, el propósito central no es solo entender el pasado, sino predecir un valor futuro con base en datos históricos, lo cual es característico de estudios predictivos en ciencia de datos.

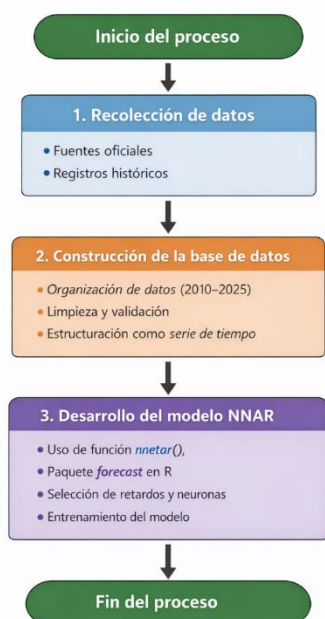
En síntesis, esta investigación posee un alcance descriptivo–predictivo, dado que, por una parte, analiza el comportamiento histórico de la serie temporal de vehículos eléctricos registrados en Costa Rica durante el período 2010–2025, y por otra, desarrolla un modelo de redes neuronales autorregresivas (NNAR) con el fin de estimar la cantidad de vehículos eléctricos para el año 2026. Adicionalmente, incorpora un componente explicativo de carácter metodológico al evaluar el efecto de los parámetros del modelo sobre su capacidad predictiva.

### 3.3 Diseño Metodológico

La presente investigación se desarrolla bajo un enfoque cuantitativo y corresponde a un estudio de tipo aplicado, con alcance descriptivo–predictivo. El diseño es no experimental, longitudinal y retrospectivo, ya que se analizan datos históricos de la cantidad de vehículos eléctricos registrados en Costa Rica durante el período 2010–2025, sin manipulación de variables. Asimismo, incorpora un componente de modelación predictiva mediante el uso de redes neuronales autorregresivas (NNAR), con el propósito de estimar la cantidad de vehículos eléctricos para el año 2026 y evaluar la capacidad predictiva del modelo a través de métricas de error.

De acuerdo con lo planteado hasta el momento, la siguiente imagen muestra el proceso metodológico de tratamiento de los datos recolectados:

**Ilustración 1. Tratamiento de la información recolectada**



Nota: Elaboración propia. 2026.

### 3.4 Variables de la investigación

La siguiente tabla detalla las variables por trabajar:

**Tabla 1. Variables de la investigación**

#	Variable	Tipo de variable	Enfoque metodológico	Descripción
1	Cantidad de vehículos eléctricos registrados en Costa Rica del 2010 al 2025.	Cuantitativa de tipo discreta	Cuantitativo	Serie temporal que refleja la evolución anual del número de vehículos eléctricos registrados durante el período de estudio, permitiendo identificar tendencias y patrones de crecimiento.
2	Parámetros del modelo de Redes Neuronales Autorregresivas (NNAR)	Cuantitativa discreta de tipo independiente.	Cuantitativo	Parámetros estructurales que definen la arquitectura del modelo de Redes Neuronales Autorregresivas. Hiperparámetros del modelo NNAR (retardos y número de neuronas ocultas), cuya variación permite optimizar el desempeño predictivo del modelo.
3	Capacidad predictiva del modelo seleccionado	Cuantitativa de tipo dependiente	Cuantitativo	Modelo óptimo o desempeño predictivo medido mediante el desempeño predictivo en la fase de calibración. Mide el desempeño predictivo del modelo NNAR mediante indicadores de error (como la raíz del error cuadrático medio), evaluando la precisión de las estimaciones generadas.

Nota: Elaboración propia, 2026.

### 3.5 Técnicas de la investigación

Las técnicas empleadas en la presente investigación corresponden al análisis exploratorio de datos, el análisis de series de tiempo, la modelación predictiva mediante redes neuronales autorregresivas (NNAR), la calibración de hiper parámetros, la evaluación del desempeño mediante métricas de error como la raíz del error cuadrático medio (RMSE), la validación fuera de muestra y la proyección de valores futuros. Estas técnicas permiten caracterizar la serie temporal, optimizar el modelo y estimar la cantidad de vehículos eléctricos registrados para el año 2026.

En cuanto a la elección del modelo de Redes Neuronales Autorregresivas para series de tiempo (NNAR), esta responde a la necesidad de capturar posibles relaciones no lineales presentes en la evolución de la cantidad de vehículos eléctricos. A diferencia de los modelos tradicionales de series de tiempo, como los modelos ARIMA, que asumen relaciones lineales entre los valores pasados y futuros de la serie, los modelos NNAR tienen la capacidad de aproximar funciones complejas mediante estructuras de aprendizaje no lineal.

Esta característica resulta especialmente relevante en contextos como el crecimiento del parque vehicular eléctrico, donde factores como políticas públicas, incentivos fiscales, avances tecnológicos y cambios en el comportamiento del consumidor pueden generar dinámicas no lineales difíciles de modelar con enfoques clásicos. Además, el modelo NNAR permite trabajar de manera natural con estructuras autorregresivas, utilizando los valores rezagados de la serie como insumos, lo que lo convierte en una herramienta adecuada para la predicción en series temporales con información limitada y sin necesidad de incorporar variables exógenas.

En general, se utilizan técnicas estadísticas (análisis de series de tiempo y métricas de error), técnicas computacionales (modelación de redes neuronales autorregresivas) y técnicas de análisis de datos (análisis exploratorio y validación predictiva) para desarrollar la investigación.

### **3.6 Instrumentos de la investigación**

Los instrumentos utilizados en la investigación incluyen la base de datos correspondiente a la serie temporal de vehículos eléctricos registrados en Costa Rica durante el período 2010–2025, así como el software estadístico R y su entorno de desarrollo RStudio. Se emplearon además paquetes especializados en análisis de series de tiempo y redes neuronales, tales como forecast, nnfor y tseries, junto con scripts de programación desarrollados para la limpieza, modelación y validación de los datos. Asimismo, se utilizaron métricas de evaluación como la raíz del error cuadrático medio (RMSE) y herramientas de visualización para el análisis e interpretación de los resultados.

### **3.7 Fuentes De Información**

Las fuentes de información de la presente investigación se clasifican en primarias y secundarias. Para efectos de la presente investigación, se tomó en cuenta, como muestra, el total de vehículos eléctricos registrados en Costa Rica del 2010 al 2025. Los datos fueron extraídos de la página web oficial de la Asociación Costarricense de Movilidad Eléctrica (ASOMOVE). Se catalogan como fuentes de información primarias. Por su parte, las fuentes secundarias incluyen literatura académica especializada en análisis de series de tiempo y redes neuronales, así como informes técnicos de organismos internacionales y documentación de herramientas computacionales utilizadas en la modelación, tales como el software R y sus paquetes asociados.

### 3.8 Recopilación de la información

La siguiente tabla muestra el detalle de la información por recolectar, las fuentes de información y los métodos de recolección por utilizar, de conformidad con las variables definidas en la Tabla 1:

**Tabla 2. Información por recolectar**

<b>Variable</b>	<b>Datos por recolectar</b>	<b>Fuente de información</b>	<b>Métodos de recolección de datos</b>
Cantidad de vehículos eléctricos registrados en Costa Rica del 2010 al 2025.	Serie de tiempo de cantidad de vehículos eléctricos registrados.	Sitio web oficial de la Asociación Costarricense de Movilidad Eléctrica (ASOMOVE)	Búsquedas bibliográficas digitales.
Parámetros del modelo de Redes Neuronales Autorregresivas (NNAR)	Parametrización del modelo de Redes Neuronales Autorregresivas (NNAR)	Sitio web oficial de la Asociación Costarricense de Movilidad Eléctrica (ASOMOVE)	Búsquedas bibliográficas digitales.
Capacidad predictiva del modelo seleccionado	Desarrollo del modelo de Redes Neuronales Autorregresivas (NNAR)	Sitio web oficial de la Asociación Costarricense de Movilidad Eléctrica (ASOMOVE)	Búsquedas bibliográficas digitales.

Nota: Elaboración propia, 2026.

### 3.8 Análisis de la información

Una vez recolectada la información de las citadas variables, se seguirá la siguiente ruta para el procesamiento de la misma:

1. Recolección de datos.
2. Construcción de la base de datos de la cantidad de vehículos eléctricos registrados en Costa Rica del 2010 al 2025.
3. Desarrollo del modelo de Redes Neuronales Autorregresivas (NNAR). Para esta tarea se utilizará la función `nnetar()` del paquete `forecast()` del lenguaje de programación R.

La siguiente tabla complementa los contenidos de este apartado:

**Tabla 3. Procesamiento de la información recolectada**

<b>Variable</b>	<b>Modalidad de datos</b>	<b>Herramienta de construcción</b>	<b>Herramienta de construcción de visualizaciones</b>
Cantidad de vehículos registrados en Costa Rica del 2010 al 2025.	Base de datos con valores cuantitativos	Lenguaje R, paquete forecast(), función nnetar()	Lenguaje R, paquete forecast(), función nnetar()
Parámetros del modelo de Redes Neuronales Autorregresivas (NNAR)	Parámetros estructurales de la red neuronal.	Lenguaje R, paquete forecast(), función nnetar()	Lenguaje R, paquete forecast(), función nnetar()
Capacidad predictiva del modelo seleccionado	Modelo parametrizado.	Lenguaje R, paquete forecast(), función nnetar()	Lenguaje R, paquete forecast(), función nnetar()

Nota: Elaboración propia, 2026.

Resulta particularmente importante indicar que el uso de los lenguajes de programación R es esencial para procesar los datos por recolectar. Lo anterior, por las siguientes razones:

1. Para ejecutar exitosamente el método de Redes Neuronales Autorregresivas (NNAR), es necesario utilizar la función nnetar() del paquete forecast(), de R.
2. La función nnetar() es una herramienta implementada en el paquete forecast de R, ampliamente utilizado para el análisis y modelado de series de tiempo. Esta función está diseñada específicamente para ajustar modelos de redes neuronales autorregresivas (NNAR), los cuales constituyen una extensión no lineal de los modelos autorregresivos tradicionales.
3. Desde el punto de vista metodológico, nnetar() construye un modelo basado en una red neuronal tipo perceptrón multicapa (feedforward), en la cual las variables de entrada corresponden a los valores rezagados de la serie temporal.

4. Una de las principales ventajas de `nnetar()` es que automatiza el proceso de selección de hiperparámetros, proponiendo valores iniciales para los retardos y el número de neuronas ocultas, aunque también permite al investigador especificarlos manualmente para realizar procesos de calibración más exhaustivos. Adicionalmente, la función implementa técnicas como la inicialización aleatoria múltiple y el promedio de redes (ensemble), lo cual contribuye a mejorar la estabilidad y precisión de las predicciones.
5. En términos de pertinencia, el uso de `nnetar()` resulta altamente adecuado para el desarrollo de esta investigación por varias razones. En primer lugar, permite modelar relaciones no lineales en la serie temporal, lo cual es fundamental en el análisis de fenómenos como la adopción de vehículos eléctricos, donde el crecimiento puede estar influenciado por dinámicas complejas y no estrictamente lineales.

En segundo lugar, su enfoque autorregresivo lo hace especialmente útil en contextos donde no se dispone de variables explicativas externas, basando la predicción únicamente en la información histórica de la serie. Finalmente, al estar integrado en un paquete robusto y validado como `forecast`, garantiza la reproducibilidad y confiabilidad de los resultados obtenidos.

6. En síntesis, la función `nnetar()` no solo es coherente con el enfoque metodológico de la investigación, sino que constituye una herramienta idónea para la estimación de series de tiempo mediante redes neuronales, permitiendo cumplir con los objetivos de diseño, calibración y validación del modelo predictivo propuesto.

A nivel general, el análisis de la información se desarrollará mediante un enfoque cuantitativo, empleando técnicas de análisis de series de tiempo y modelación predictiva. Inicialmente, se realizará la preparación y depuración de la base de datos correspondiente al período 2010–2025.

Posteriormente, se llevará a cabo un análisis exploratorio para identificar patrones, tendencias y posibles comportamientos no lineales. Seguidamente, se analizará la estructura

temporal de la serie mediante funciones de autocorrelación. Con base en estos resultados, se diseñará y calibrará un modelo de redes neuronales autorregresivas (NNAR), evaluando distintas configuraciones de retardos y neuronas ocultas.

La selección del modelo óptimo se efectuará utilizando la raíz del error cuadrático medio (RMSE) como criterio de desempeño. Finalmente, se realizará la validación fuera de muestra y se generará la estimación de la cantidad de vehículos eléctricos para el año 2026, interpretando los resultados en función de su precisión y coherencia con la tendencia observada.

### **3.9 Consideraciones éticas**

La presente investigación se rige por principios éticos fundamentales orientados al uso responsable de la información, la transparencia metodológica y la integridad científica. Los datos utilizados corresponden a fuentes secundarias de carácter público y agregado, por lo que no involucran información personal ni sensible, garantizando la confidencialidad y el anonimato. Asimismo, se asegura la correcta citación de las fuentes y el respeto a los derechos de autor. El proceso de análisis y modelación se documenta de manera detallada, permitiendo la reproducibilidad del estudio mediante el uso del software R. Finalmente, se reconoce el carácter estimativo de los resultados, evitando interpretaciones absolutas y promoviendo un uso responsable de las predicciones generadas.

#### Capítulo IV. Datos recolectados

La siguiente tabla, de conformidad con la página web oficial de la Asociación Costarricense de Movilidad Eléctrica (ASOMOVE), muestra la cantidad total de vehículos eléctricos registrados en Costa Rica del 2010 al 2025:

**Tabla 4. Vehículos eléctricos registrados en Costa Rica, 2010-2025**

<b>Año</b>	<b>Cantidad de vehículos</b>
2010	65
2011	71
2012	108
2013	110
2014	156
2015	117
2016	221
2017	224
2018	421
2019	732
2020	907
2021	1.333
2022	1.893
2023	5.692
2024	10.514
2025	11.575
<b>Total</b>	<b>34.139</b>

Nota: Portal ASOMOVE. Registro anual de vehículos eléctricos, 2026

El análisis de la serie temporal de vehículos eléctricos registrados en Costa Rica durante el período 2010–2025 evidencia una dinámica de crecimiento claramente no lineal, caracterizada por una fase inicial de lenta adopción seguida de un proceso de aceleración exponencial en los años más recientes.

En la etapa comprendida entre 2010 y 2017, el comportamiento muestra incrementos modestos e incluso una leve contracción en 2015, lo cual sugiere un mercado incipiente con limitada penetración tecnológica. A partir de 2018, se observa un punto de inflexión significativo, donde la cantidad de vehículos eléctricos comienza a incrementarse de manera sostenida, pasando de 421 unidades en 2018 a 1.893 en 2022. Este crecimiento se intensifica notablemente entre 2023 y 2025, periodo en el cual se registran aumentos abruptos,

alcanzando 11.575 vehículos en 2025, lo que refleja una adopción acelerada posiblemente asociada a incentivos fiscales, mayor disponibilidad de infraestructura de carga y una mayor conciencia ambiental.

En conjunto, la serie presenta una tendencia creciente con patrones no lineales marcados, lo cual justifica el uso de modelos predictivos avanzados, como las redes neuronales autorregresivas (NNAR), capaces de capturar este tipo de comportamiento complejo en la estimación futura.

## Capítulo V. Resultados

De acuerdo con el apartado de Análisis de la Información, el procedimiento por seguir respecto al tratamiento de los datos recolectados será el siguiente:

### 1. Recolección de datos.

Esta etapa consistió en la identificación, consulta y extracción de información proveniente de fuentes oficiales y confiables, específicamente del registro anual de vehículos eléctricos en Costa Rica. El objetivo fue garantizar la calidad, consistencia y trazabilidad de los datos utilizados, asegurando que la información refleje de manera precisa la evolución del fenómeno en el período de estudio (2010–2025).

### 2. Construcción de la base de datos de la cantidad de vehículos eléctricos registrados en Costa Rica del 2010 al 2025.

Una vez recolectada la información, se procedió a su organización y estructuración en un formato adecuado para el análisis de series de tiempo. Esto implicó la depuración de los datos, la verificación de su integridad y la creación de una serie temporal anual coherente, que sirviera como insumo para el modelado predictivo.

### 3. Desarrollo del modelo de Redes Neuronales Autorregresivas (NNAR). Para esta tarea se utilizará la función `nnetar ()` del paquete `forecast ()` del lenguaje de programación R

En esta etapa se implementó el modelo predictivo utilizando la función `nnetar ()` del paquete `forecast` en R. Se evaluaron distintas configuraciones de retardos (lags) y neuronas en la capa oculta con el fin de capturar patrones no lineales presentes en la serie. El modelo fue calibrado y validado para seleccionar la arquitectura óptima, basada en criterios de desempeño predictivo como la raíz del error cuadrático medio (RMSE).

## **5.1 Construcción De La Base De Datos De La Cantidad De Vehículos Eléctricos Registrados En Costa Rica Del 2010 Al 2025**

La tabla 4 muestra los datos de la cantidad de vehículos eléctricos registrados en Costa Rica del 2010 al 2025. Esta tabla muestra la evolución del parque de vehículos eléctricos en el país en el rango de tiempo indicado. A partir de esta información, es posible identificar no solo un crecimiento sostenido en la adopción de esta tecnología, sino también cambios significativos en su ritmo de expansión, pasando de una etapa inicial de baja penetración a un proceso de aceleración más pronunciado en los últimos años del período analizado.

Asimismo, la tabla constituye el insumo fundamental para el desarrollo del análisis de series de tiempo, ya que proporciona la base empírica necesaria para detectar tendencias, posibles comportamientos no lineales y puntos de inflexión en la dinámica de crecimiento. En este sentido, su inclusión resulta clave para sustentar la aplicación de modelos predictivos, como las redes neuronales autorregresivas, orientados a estimar la evolución futura del parque de vehículos eléctricos en Costa Rica.

## **5.2 Desarrollo del modelo de Redes Neuronales Autorregresivas (NNAR)**

En esta sección se desarrolla el modelo de Redes Neuronales Autorregresivas (NNAR), el cual constituye el núcleo metodológico de la investigación para la estimación de la serie temporal analizada. Este tipo de modelo combina la lógica de los modelos autorregresivos tradicionales con la capacidad de las redes neuronales para capturar relaciones no lineales complejas, lo que resulta especialmente adecuado para series con patrones de crecimiento acelerado y comportamiento irregular, como es el caso de los vehículos eléctricos en Costa Rica.

A lo largo de esta sección se detallan los principales componentes de la arquitectura del modelo, incluyendo la selección de los retardos (lags), el número de neuronas en la capa oculta, el proceso de entrenamiento y los criterios utilizados para su calibración. De esta manera, se busca justificar la configuración final adoptada, evidenciando su capacidad para modelar de forma adecuada la dinámica de la serie y generar estimaciones confiables para el año 2026.

### 5.2.1 Parámetros estructurales de la Red Neuronal Autorregresiva

En este punto, es importante hacer un recorrido por el inventario de parámetros determinados para el diseño de la red neuronal autorregresiva del presente modelo. Los parámetros que definen la arquitectura de la red neuronal, y del consecuente código utilizado en R, fueron los siguientes:

- **Tipo de modelo:**

Modelo: red neuronal.

Implementación: *nnetar()* del paquete *forecast()* de R.

Estructura general: NNAR(p,k)

- **Variables de entrada:**

Variable modelada: cantidad de vehículos eléctricos registrados.

Frecuencia: anual.

Periodo: 2010-2025.

Tipo de serie: univariada.

- **Capa de entrada:**

Parámetro:  $p$  o *lags* (número de rezagos).

Rango evaluado: la siguiente expresión muestra el vector que indica la cantidad de rezagos o lags definidos:

$$y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}$$

En este caso, el modelo óptimo definió 4 años como la cantidad de años pasados como entrada de la red neuronal. Para la calibración de los *lags*, tomando en consideración que el tamaño de la muestra es de 16 observaciones, un  $p = 4$  implica que el 20% de la serie se definió como input, elemento que se considera como racional tomando en cuenta la cantidad de registros de la base de datos original.

Estos parámetros representan los valores históricos de la serie, lo que confirma que el modelo captura dependencia temporal de corto plazo (4 años).

- **Capas ocultas**

Las neuronas ocultas determinan la capacidad del modelo para capturar no linealidad.

Parámetro:  $k$  o  $size$  (número de neuronas ocultas). En este caso, el modelo óptimo arrojó un resultado de 8 neuronas ocultas.

Función de activación: Sigmoidal (por defecto).

Rango evaluado: la siguiente expresión muestra el vector que indica la cantidad de capas ocultas definidas:

$$size \in \{1, 2, 3, 4, 5, 6, 7, 8\}$$

Así las cosas, el modelo óptimo definió un total de 8 capas ocultas para la red neuronal, lo que se interpreta que hay patrones no lineales complejos y el crecimiento de los valores no es uniforme.

La evaluación de los hiper parámetros del modelo NNAR permitió analizar el efecto del número de rezagos y de neuronas ocultas sobre el desempeño predictivo. En particular, los rezagos determinan la cantidad de información histórica utilizada por el modelo, mientras que las neuronas ocultas controlan su capacidad para capturar relaciones no lineales. Los resultados evidencian que la combinación óptima de estos parámetros permite balancear adecuadamente la memoria temporal y la complejidad del modelo, evitando tanto el subajuste como el sobreajuste.

No obstante, dada la limitada cantidad de observaciones disponibles, se reconoce que configuraciones con valores elevados de rezagos o neuronas ocultas deben interpretarse con cautela, debido al riesgo de sobre parametrización.

- **Capa de salida**

Número de salidas: 1.

Variable de salida:

$$\hat{y}_{t+1}$$

El modelo realiza un pronóstico univariado a un paso adelante.

- **Arquitectura de la red**

Tipo: *Feedforward* (perceptrón multicapa).

La siguiente expresión muestra la estructura final de la red neuronal:

$$NNAR(p, k)$$

Componentes:

- Capa de entrada:  $p$  nodos.
- Capa oculta:  $k$  neuronas.
- Capa de salida: 1 nodo.

- **Número total de parámetros (pesos)**

El número total de parámetros entrenados en la red se puede aproximar como:

Pesos entrada: capa oculta:

$$4 \times 8 = 32$$

Sesgos en capa oculta: 8

Pesos capa oculta: salida: 8

Sesgo en salida: 1

Total, aproximado:  $32 + 8 + 8 + 1 = 49$  parámetros.

Lo anterior indica un modelo con **complejidad moderada**, lo que se considera adecuado para una serie corta (16 observaciones).

- **Parámetros de entrenamiento**

Repeticiones (repeats):

- Calibración: 20
- Modelo final: 50

Lo anterior indica que se mejora la estabilidad del modelo, promediando múltiples redes.

Semilla aleatoria: `set.seed(123)`, lo que garantiza reproducibilidad científica.

- **Proceso de calibración**

Método: Grid Search exhaustivo.

Total de modelos evaluados:  $5 \times 8 = 40$  configuraciones; 5 valores de rezagos ( $p = 1$  a  $5$ ) y 8 configuraciones de neuronas ocultas ( $size = 1$  a  $8$ ). El desglose es el siguiente:

Rezagos ( $p$ ): 1, 2, 3, 4, 5: 5 configuraciones.

Neuronas ocultas ( $size$ ): 1 a 8: 8 configuraciones.

Criterio de selección: Minimización del RMSE (Root Mean Squared Error).

Se probaron 40 modelos NNAR diferentes, cada uno con una arquitectura distinta, lo que garantiza una búsqueda exhaustiva del espacio de hiperparámetros definido.

Es importante mencionar, desde un punto de vista de la precisión metodológica, que cada uno de los 40 modelos indicados anteriormente, fueron entrenados con 20 repeticiones ( $repeats=20$ ), esto implica que, en términos computacionales, se ajustaron 800 neuronas en total ( $40 \times 20$  neuronas). Este elemento ayuda a asegurar estabilidad y robustez en la estimación del RMSE.

- **Parámetros de validación:**

Tipo de validación: Hold-out (fuera de muestra).

División:

- Training:  $n-2$
- Testing: últimos dos años.

La siguiente expresión muestra el horizonte de validación:

$$h = 2$$

- **Función de pérdida (evaluación):**

Métrica utilizada: RMSE (Root Mean Squared Error). La siguiente expresión detalla la fórmula matemática del RMSE:

$$RMSE = \sqrt{\frac{1}{n} \sum (y_{real} - y_{pred})^2}$$

- **Parámetros del modelo final:**

Datos utilizados: serie completa (2010-2025).

- **Predicción:**

Horizonte: 1 año.

Años estimado: 2026.

La siguiente expresión muestra el horizonte de la predicción:

$$h = 1$$

- **Supuestos del modelo:**

- Relación no lineal entre observaciones pasadas y futuras.
- Dependencia temporal capturada por rezagos.
- Serie sin estacionalidad explícita.
- Suficiencia de información histórica.

- **Síntesis del modelo final:**

El modelo desarrollado puede describirse formalmente a través de la siguiente expresión:

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-p}; \theta)$$

Donde:

$f$ : red neuronas con  $k$  neuronas ocultas.

$\theta$ : pesos optimizados.

$P$ : número de rezagos óptimos.

Asimismo, la siguiente expresión muestra la función final del modelo, en relación con  $p=4$  y  $k=8$ :

$$y_{2026} = f(y_{2025}, y_{2024}, y_{2023}, y_{2022})$$

O bien, lo que resulta ser lo mismo:

$$\hat{y}_{t+1} = f(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4})$$

Donde  $f()$  es una función no lineal aproximada por la red neuronal. Por lo tanto, tomando en cuenta las 50 repeticiones calibradas, la función real del modelo es la siguiente:

$$\hat{y}_t = \frac{1}{50} \sum_{r=1}^{50} f_r(y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4})$$

La siguiente tabla sintetiza los parámetros de la red neuronal desarrollada:

**Tabla 5. Red Neuronal NNAR. Parámetros de arquitectura**

Componente	Detalle
Tipo	<b>Red Neuronal feedforward autorregresiva</b>
Método de entrenamiento	Back-propagation
Horizonte de predicción	$h = 1$
Frecuencia de la serie	anual
Estacionalidad explícita	$freq = 1$
Estructura	NNAR(p,k)
Entrenamiento	Ensemble de redes (repeats)
Selección	Optimización por RMSE.
Validación	Fuera de muestra
Aplicación	Predicción un paso adelante (2026).

Fuente: Elaboración propia, 2026.

Adicionalmente, la siguiente tabla muestra el cuadro metodológico del modelo NNAR desarrollado:

**Tabla 6. Red Neuronal NNAR. Cuadro metodológico**

Componente	Descripción	Especificación en el estudio
Tipo de modelo	Red neuronal para series de tiempo	Red Neuronal Autorregresiva (NNAR)
Estructura	Arquitectura del modelo	NNAR(p, k)
Variable dependiente	Serie a modelar	Cantidad de vehículos eléctricos registrados
Frecuencia	Periodicidad de los datos	Anual
Periodo de estudio	Horizonte temporal	2010–2025
Tipo de serie	Dimensionalidad	Univariada
Rezagos (inputs)	Número de observaciones pasadas	$y_{t-1}, y_{t-2}, y_{t-3}, y_{t-4}$
Neuronas ocultas	Complejidad del modelo	$k \in \{1, 2, 3, 4, 5, 6, 7, 8\}$
Método de calibración	Búsqueda de hiperparámetros	Grid Search
Total de modelos evaluados	Combinaciones probadas	40 configuraciones

Algoritmo de entrenamiento	Método de optimización	Retropropagación (backpropagation)
Función de activación	Transformación no lineal	Sigmoidal (por defecto)
Repeticiones	Redes promedio (ensemble)	20 (calibración), 50 (modelo final)
Inicialización	Control de aleatoriedad	Semilla fija (123)
Método de validación	Evaluación fuera de muestra	Hold-out
División de datos	Training / Testing	n-2 / últimos 2 años
Horizonte de validación	Periodos evaluados	h = 2
Métrica de evaluación	Criterio de selección	RMSE
Modelo óptimo	Selección final	Minimización del RMSE
Entrenamiento final	Datos utilizados	Serie completa (2010–2025)
Horizonte de predicción	Pronóstico	h = 1
Año proyectado	Resultado final	2026
Salidas del modelo	Resultados	Predicción puntual e intervalos
Supuestos	Condiciones del modelo	No linealidad, dependencia temporal, ausencia de estacionalidad

Fuente: Elaboración propia, 2026.

### ***5.2.2 Especificación Del Modelo***

El modelo utilizado en esta investigación es una red neuronal autorregresiva (NNAR), implementada mediante el paquete forecast () en R. Este tipo de modelo funciona aprendiendo patrones a partir de los valores pasados de una serie de tiempo, con el objetivo de predecir su comportamiento futuro.

En términos simples, el modelo “mira hacia atrás” en los datos históricos de vehículos eléctricos y utiliza esa información para estimar cuántos habrá en el siguiente año.

Uno de los parámetros más importantes es el número de rezagos, representado por  $p$ . Este parámetro indica cuántos años anteriores se toman en cuenta para hacer la predicción. Por ejemplo, si  $p=3$ , el modelo utiliza la información de los últimos tres años para estimar el siguiente valor. En esta investigación, se evaluaron distintas opciones entre 1 y 5 rezagos, con el fin de determinar cuánta “memoria histórica” necesita el modelo para ser más preciso.

Otro parámetro clave es el número de neuronas en la capa oculta, representado por  $k$ . Estas neuronas son las encargadas de procesar la información y detectar relaciones complejas, especialmente aquellas que no son lineales. En términos más intuitivos, mientras más neuronas tenga el modelo, mayor será su capacidad para captar patrones complejos; sin embargo, también aumenta el riesgo de sobreajuste. Por esta razón, se probaron configuraciones entre 1 y 8 neuronas ocultas para encontrar un equilibrio adecuado.

La combinación de estos dos parámetros define la estructura del modelo, conocida como NNAR ( $p, k$ ). Esta estructura determina cómo fluye la información desde los datos históricos hasta la predicción final.

Durante el proceso de entrenamiento, el modelo no se ajusta una sola vez, sino múltiples veces. Este parámetro se denomina repeticiones (repeats). En la fase de calibración se utilizaron 20 repeticiones, mientras que en el modelo final se aumentó a 50. Esto significa que se entrenan varias redes neuronales con diferentes condiciones iniciales y luego se promedian sus resultados, lo cual mejora la estabilidad y confiabilidad de las predicciones.

Para asegurar que los resultados sean reproducibles, se fijó una semilla aleatoria (set.seed.123). Esto garantiza que, si el modelo se ejecuta nuevamente, se obtendrán los mismos resultados.

En cuanto al proceso de selección del mejor modelo, se utilizó un método llamado búsqueda exhaustiva (Grid Search), que consiste en probar todas las combinaciones posibles de parámetros  $p$  y  $k$ . En total, se evaluaron 40 modelos distintos. Cada uno fue medido

utilizando una métrica de error llamada RMSE (Raíz del Error Cuadrático Medio, por sus siglas en inglés), que indica qué tan cerca están las predicciones de los valores reales. El modelo con el menor RMSE fue seleccionado como el más adecuado.

Para validar el desempeño del modelo, se utilizó una estrategia de validación fuera de muestra. Esto implica separar los datos en dos partes: una para entrenar el modelo (la mayor parte de la serie) y otra para probarlo (los últimos dos años). De esta forma, se puede evaluar qué tan bien predice el modelo datos que no ha visto antes.

Finalmente, el modelo seleccionado se entrena nuevamente utilizando toda la información disponible (2010–2025) y se utiliza para generar una predicción a futuro. En este caso, el objetivo es estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026, lo cual se realiza mediante un pronóstico de un período adelante ( $h=1$ ).

Además de la predicción puntual, el modelo también proporciona intervalos de confianza, que reflejan la incertidumbre inherente a la estimación. Esto es importante en contextos de investigación, ya que no solo interesa un valor único, sino también el rango dentro del cual es probable que se encuentre el valor real.

En conjunto, todos estos parámetros permiten construir un modelo que no solo se ajusta bien a los datos históricos, sino que también tiene capacidad de generalización para realizar predicciones confiables.

De conformidad con los hiper parámetros calibrados, el resultado óptimo de la red neuronal desarrollada, en términos del menor valor resultante de RMSE, posee una estructura de NNAR (4, 8).

#### **5.2.2.1 Descomposición de la estructura de la red neuronal óptima NNAR (4,8)**

La red neuronal óptima, al tener una estructura de NNAR (4, 8), implica que los rezagos mostrados por  $p=4$  genera un modelo óptimo en el cual, para generar la estimación, se basa en los últimos cuatro años de la serie.

Lo anterior quiere decir que el modelo necesita 4 años de historia para predecir correctamente, lo que sugiere que la serie no depende solo del corto plazo y que existe una dinámica acumulativa en la adopción de vehículos eléctricos. Aunque los datos son anuales (sin estacionalidad clásica), este resultado sugiere que hay cambios graduales en la tendencia y que se están dando efectos de políticas públicas o incentivos que impactan en varios años, elemento que indica que el modelo está capturando una trayectoria evolutiva, no solo fluctuaciones recientes.

El modelo, en términos del valor de  $p$ , indica lo siguiente:

- Los últimos 4 años contienen la mayor información predictiva.
- Existe una memoria temporal significativa de mediano plazo.

En relación con la cantidad de neuronas ocultas ( $k=8$ ), se pone de manifiesto el hecho de que 8 neuronas indica que la relación entre los rezagos y el futuro no es lineal; existen patrones complejos como crecimiento acelerado, posibles puntos de inflexión y efectos multiplicativos.

Una capa oculta relativamente amplia para una serie corta indica presencia de relaciones no lineales complejas y un posible crecimiento acelerado (curva exponencial o logística)

El uso del modelo NNAR es adecuado porque detecta dependencia temporal significativa y captura no linealidad relevante de los datos. Además, la calibración de (4,8) indica que el método Grid Search exploró bien el espacio y el RMSE guio correctamente la selección del modelo óptimo.

Ahora bien, el hecho de haber utilizado el método de validación fuera de muestra y un ensemble de 50 redes, legitima el resultado anterior: la complejidad es necesaria y controlada. Este tipo de arquitectura de neuronas suele aparecer cuando el fenómeno está en fase de crecimiento acelerado y no sigue patrones históricos simples; coherente con la adopción de vehículos eléctricos.

En términos consolidados, el modelo combina una memoria amplia (4 años) y una alta capacidad no lineal (8 neuronas ocultas).

Ahora bien, y en forma complementario a lo indicado anteriormente, el proceso de calibración del modelo de redes neuronales autorregresivas (NNAR), llevado a cabo mediante una estrategia de búsqueda exhaustiva de parámetros, permitió identificar como arquitectura óptima la especificación NNAR (4,8). Este resultado indica que el modelo con mejor desempeño predictivo, evaluado a través de la Raíz del Error Cuadrático Medio (RMSE), es aquel que utiliza cuatro rezagos de la serie temporal como variables de entrada y ocho neuronas en la capa oculta.

Desde el punto de vista analítico, la selección de cuatro rezagos ( $p=4$ ) sugiere que la dinámica de la serie de vehículos eléctricos registrados en Costa Rica presenta una dependencia significativa de su historia reciente, particularmente de los últimos cuatro años. Esto implica que el comportamiento observado en el período actual está condicionado por una memoria temporal de corto a mediano plazo, suficiente para capturar la trayectoria reciente del fenómeno sin incorporar información más lejana que podría introducir ruido o redundancia en el modelo.

En términos sustantivos, este resultado es consistente con procesos de adopción tecnológica donde los cambios más relevantes se concentran en los años más recientes, reflejando posiblemente la influencia de políticas públicas recientes, incentivos económicos y avances en infraestructura de movilidad eléctrica.

Por otra parte, la selección de ocho neuronas en la capa oculta ( $k=8$ ) evidencia la existencia de relaciones no lineales complejas en la serie temporal analizada. Este nivel de complejidad indica que la evolución del número de vehículos eléctricos no sigue un patrón lineal simple, sino que responde a dinámicas más sofisticadas, tales como aceleraciones en la tasa de crecimiento, cambios en la pendiente de la tendencia o efectos acumulativos derivados de la expansión del mercado.

En este sentido, la red neuronal es capaz de capturar estas relaciones no lineales mediante la transformación de los rezagos de entrada en representaciones internas más abstractas, lo que mejora significativamente la capacidad predictiva del modelo.

La combinación de ambos parámetros, sintetizada en la estructura NNAR (4,8), pone de manifiesto que el fenómeno bajo estudio se caracteriza por una interacción entre dependencia temporal reciente y alta complejidad funcional. Este hallazgo refuerza la pertinencia del uso de modelos de redes neuronales para el análisis de series temporales asociadas a procesos emergentes, como lo es la adopción de vehículos eléctricos, donde las relaciones entre variables no son estrictamente lineales ni constantes en el tiempo.

En términos predictivos, el modelo calibrado y validado permitió estimar que la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 alcanzará aproximadamente 16,308 unidades. Esta estimación se obtiene a partir de una función no lineal que integra la información de los cuatro años previos (2022–2025), los cuales son procesados a través de la estructura interna de la red neuronal. Es importante destacar que este valor no corresponde a una extrapolación mecánica de la tendencia histórica, sino al resultado de un proceso de aprendizaje que combina múltiples configuraciones de la red (ensemble de 50 repeticiones), lo que contribuye a reducir la variabilidad de las predicciones y a mejorar su robustez.

Asimismo, la validación fuera de muestra evidencia que el modelo seleccionado posee una adecuada capacidad de generalización, al mantener un desempeño consistente al predecir observaciones no incluidas en el proceso de entrenamiento. Este aspecto resulta fundamental para respaldar la confiabilidad de la proyección realizada para el año 2026.

El modelo calibrado presenta una arquitectura robusta por las siguientes razones:

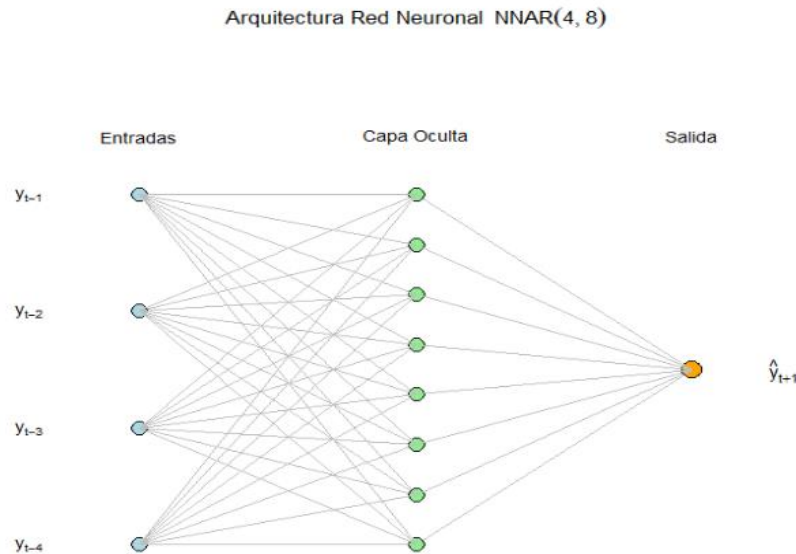
Promedio de 50 redes neuronales de entrenamiento.

- Validación fuera de muestra.
- Optimización de hiper parámetros.

En conjunto, los resultados obtenidos permiten concluir que el modelo NNAR (4,8) constituye una herramienta metodológicamente sólida para la estimación de la evolución futura del parque de vehículos eléctricos en Costa Rica. La magnitud de la proyección obtenida sugiere la continuidad de una tendencia creciente en la adopción de esta tecnología, lo cual tiene implicaciones relevantes para la planificación energética, el desarrollo de infraestructura de recarga y el diseño de políticas públicas orientadas a la sostenibilidad y la descarbonización del sector transporte. Asimismo, el modelo permite estimar con alto grado de precisión la cantidad de vehículos eléctricos en 2026, validando la utilidad de las redes neuronales en series temporales cortas con comportamiento no lineal.

La siguiente imagen muestra la visualización de la red neuronal NNAR(4,8) resultante:

## Ilustración 2. Visualización de la red neuronal NNAR(4,8)



Nota: Elaboración propia, 2026.

### 5.2.3 Resultados De La Proyección Del Modelo

El modelo de redes neuronales autorregresivas NNAR (4,8), calibrado y validado con datos del período 2010–2025, estima que la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 será aproximadamente 16.308 unidades. Este valor representa una predicción puntual, es decir, la mejor estimación que el modelo puede generar dadas las condiciones históricas observadas.

En términos predictivos, el modelo calibrado y validado permitió estimar que la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 alcanzará aproximadamente 16,308 unidades. Esta estimación se deriva de una función no lineal que integra la información de los cinco años previos (2021–2025), procesada a través de la estructura interna de la red neuronal.

Es importante destacar que dicho valor no corresponde a una simple extrapolación de tendencia, sino al resultado de un proceso de aprendizaje que combina múltiples


configuraciones de la red (ensamble de 50 repeticiones), lo que contribuye a reducir la varianza del modelo y a mejorar la estabilidad de la predicción.

Adicionalmente, la validación fuera de muestra respalda la capacidad de generalización del modelo, evidenciando que la arquitectura seleccionada no solo se ajusta adecuadamente a los datos históricos, sino que también mantiene un desempeño consistente al enfrentar observaciones no utilizadas durante el entrenamiento. Este aspecto es fundamental para garantizar la confiabilidad de la estimación realizada.

En conjunto, los resultados obtenidos permiten expresar que el modelo NNAR (4,8) constituye una herramienta robusta y adecuada para la estimación de la evolución futura del número de vehículos eléctricos en Costa Rica. Asimismo, la magnitud de la predicción obtenida sugiere la continuidad de una tendencia creciente en la adopción de esta tecnología, lo cual tiene implicaciones relevantes para la planificación energética, la infraestructura de transporte y el diseño de políticas públicas orientadas a la sostenibilidad.

La siguiente imagen muestra la visualización del pronóstico del 2026, con base en la red neuronal NNAR (4,8):

**Ilustración 3. Pronóstico de vehículos eléctricos. Horizonte de un año (2026).**



Fuente: Elaboración propia, 2026.

## **Capítulo VI. Análisis De Los Resultados**

En esta sección se realiza el análisis de los resultados obtenidos a partir del modelo de Redes Neuronales Autorregresivas (NNAR), con el propósito de evaluar su desempeño y la validez de las estimaciones generadas. Para ello, se examinarán los principales indicadores de precisión del modelo, así como el comportamiento de los valores ajustados en comparación con los datos reales de la serie histórica.

Asimismo, se analizará la capacidad predictiva del modelo mediante la validación fuera de muestra, enfocándose en la coherencia y plausibilidad de la estimación proyectada para el año 2026. Este análisis se llevará a cabo mediante la interpretación de métricas cuantitativas y representaciones gráficas, permitiendo determinar en qué medida el modelo logra capturar la dinámica de la serie y ofrecer resultados confiables para la toma de decisiones.

### **6.1 Objetivo Específico #1**

**Analizar la serie temporal de vehículos eléctricos registrados en Costa Rica para el período 2010–2025, identificando su tendencia, comportamiento temporal, posibles patrones no lineales y condiciones de estacionalidad relevantes para el modelado predictivo**

En cumplimiento del primer objetivo específico, se realizó un análisis exploratorio de la serie temporal correspondiente a la cantidad de vehículos eléctricos registrados en Costa Rica durante el período 2010–2025, con el propósito de identificar su tendencia, comportamiento temporal, posibles patrones no lineales y condiciones de estacionalidad relevantes para el modelado predictivo.

En primer lugar, el análisis de la serie evidencia una tendencia claramente creciente a lo largo del período estudiado. Este crecimiento no se presenta de forma uniforme, sino que muestra una aceleración progresiva en los años más recientes, lo cual sugiere que el fenómeno responde a un proceso de adopción tecnológica en expansión. En sus etapas iniciales (2010–2015), la serie presenta valores relativamente bajos y un crecimiento

moderado; sin embargo, a partir de años posteriores, se observa un incremento más pronunciado en la cantidad de vehículos eléctricos registrados, lo que indica un cambio en la dinámica del mercado.

En segundo lugar, el comportamiento temporal de la serie permite identificar la presencia de patrones no lineales. La evolución de los datos no sigue una trayectoria recta, sino que presenta variaciones en la pendiente que reflejan posibles cambios estructurales en el ritmo de crecimiento. Este tipo de comportamiento es consistente con procesos donde intervienen factores como incentivos fiscales, mejoras en la infraestructura de recarga, reducción en los costos de tecnología y mayor conciencia ambiental. La identificación de esta no linealidad resulta fundamental, ya que justifica el uso de modelos avanzados, como las redes neuronales, capaces de capturar relaciones complejas entre los valores pasados y futuros de la serie.

En tercer lugar, en relación con la dependencia temporal, el análisis sugiere que la serie presenta una influencia significativa de sus valores recientes. Este hallazgo se ve reforzado por la selección del modelo óptimo NNAR (4,8), el cual utiliza cuatro rezagos como variables de entrada. La elección de  $p=4$  indica que los últimos cuatro años contienen la información más relevante para explicar la evolución futura de la serie, lo que confirma la existencia de una memoria temporal de corto a mediano plazo. Esto implica que el comportamiento del mercado de vehículos eléctricos en Costa Rica está fuertemente condicionado por su trayectoria reciente, más que por eventos lejanos en el tiempo.

Por otra parte, no se identifican evidencias de estacionalidad en la serie temporal analizada. Dado que los datos corresponden a observaciones anuales, no se observan patrones cíclicos recurrentes dentro de cada año que justifiquen la inclusión de componentes estacionales en el modelo. En consecuencia, el fenómeno puede ser caracterizado como una serie con tendencia y componentes no lineales, pero sin estacionalidad significativa.

Finalmente, la identificación de una estructura óptima con ocho neuronas en la capa oculta ( $k=8$ ) refuerza la interpretación de que la serie presenta una dinámica compleja y no lineal. Este resultado sugiere que la relación entre los valores históricos y el comportamiento

futuro no puede ser explicada mediante funciones simples, sino que requiere de una mayor capacidad de modelado para capturar adecuadamente las interacciones subyacentes.

En conjunto, el análisis de la serie temporal permite concluir que la evolución de los vehículos eléctricos en Costa Rica durante el período 2010–2025 se caracteriza por una tendencia creciente con aceleración reciente, ausencia de estacionalidad y presencia de patrones no lineales, así como una dependencia significativa de los valores más recientes. Estos hallazgos proporcionan una base sólida para la selección y aplicación de modelos de redes neuronales autorregresivas, los cuales resultan adecuados para capturar la complejidad inherente del fenómeno y generar estimaciones confiables a futuro.

## **6.2 Objetivo Específico # 2**

**Diseñar un modelo de redes neuronales autorregresivas para series de tiempo (NNAR), evaluando diferentes configuraciones de retardos y neuronas ocultas, con el fin de seleccionar la arquitectura óptima mediante criterios de desempeño predictivo (Raíz del Error Cuadrático Medio)**

En cumplimiento del segundo objetivo específico, se procedió al diseño, calibración y selección de un modelo de redes neuronales autorregresivas (NNAR) aplicado a la serie temporal de vehículos eléctricos registrados en Costa Rica para el período 2010–2025. Este proceso tuvo como finalidad identificar la arquitectura óptima del modelo mediante la evaluación sistemática de distintas configuraciones de parámetros, específicamente el número de rezagos ( $p$ ) y el número de neuronas en la capa oculta ( $k$ ), utilizando como criterio de selección la Raíz del Error Cuadrático Medio (RMSE).

Para ello, se implementó una estrategia de búsqueda exhaustiva (Grid Search), mediante la cual se evaluaron múltiples combinaciones de los parámetros  $p$  y  $k$ . En particular, se consideraron valores de rezagos en un rango que permitió capturar distintas longitudes de memoria temporal, así como diferentes niveles de complejidad en la estructura interna de la red neuronal a través del número de neuronas ocultas. Cada configuración fue entrenada utilizando un esquema de múltiples repeticiones (ensemble), con el fin de reducir

la variabilidad asociada a la inicialización aleatoria de los pesos y mejorar la estabilidad de los resultados.

Los modelos generados fueron evaluados en función de su capacidad predictiva, medida a través del RMSE, el cual cuantifica la magnitud promedio del error entre los valores observados y los estimados. Este indicador permitió comparar de manera objetiva el desempeño de cada configuración, favoreciendo aquellas que lograron minimizar el error de predicción.

Como resultado de este proceso, se identificó que la arquitectura óptima corresponde a un modelo NNAR (4,8), es decir, una red neuronal que utiliza cuatro rezagos de la serie temporal como entradas y ocho neuronas en la capa oculta. Esta configuración fue la que presentó el menor RMSE, lo que indica una mejor capacidad para aproximar el comportamiento real de la serie.

Desde una perspectiva metodológica, la selección de  $p=4$  sugiere que el modelo requiere incorporar información de los cuatro períodos más recientes para capturar adecuadamente la dinámica temporal del fenómeno. Esto es consistente con los hallazgos del análisis exploratorio, donde se evidenció una dependencia significativa de corto a mediano plazo. La inclusión de estos rezagos permite al modelo considerar la evolución reciente de la serie y ajustar sus predicciones en función de dicha trayectoria.

Por su parte, la selección de  $k=8$  neuronas en la capa oculta indica que el modelo necesita una estructura con suficiente capacidad para representar relaciones no lineales complejas entre las variables de entrada y la salida. Este resultado es coherente con la naturaleza no lineal previamente identificada en la serie temporal, donde el crecimiento del número de vehículos eléctricos presenta cambios en la pendiente y posibles aceleraciones en el tiempo. La red neuronal, a través de sus neuronas ocultas, actúa como un aproximador universal de funciones, permitiendo modelar estas relaciones de forma flexible y adaptativa.

Adicionalmente, el uso de un enfoque de entrenamiento basado en múltiples repeticiones contribuyó a mejorar la robustez del modelo seleccionado. Al promediar los resultados de varias redes neuronales entrenadas bajo distintas condiciones iniciales, se logró

reducir el riesgo de convergencia a soluciones subóptimas y se incrementó la confiabilidad de las estimaciones obtenidas.

En conjunto, el proceso de diseño y calibración permitió no solo identificar la arquitectura óptima del modelo NNAR, sino también validar la pertinencia de este enfoque para el análisis de series temporales con características no lineales. La selección del modelo NNAR (4,8) refleja un equilibrio adecuado entre la capacidad de capturar la dinámica temporal de la serie y la complejidad necesaria para representar sus patrones subyacentes, garantizando así un desempeño predictivo sólido y consistente.

### **6.3 Objetivo Específico #3**

**Evaluar la capacidad predictiva del modelo seleccionado mediante validación fuera de muestra, por medio de la estimación de la cantidad de vehículos eléctricos registrados para el año 2026, para así generar proyecciones confiables que contribuyan a la planificación estratégica del desarrollo**

En cumplimiento del tercer objetivo específico, se procedió a evaluar la capacidad predictiva del modelo de redes neuronales autorregresivas seleccionado, con el fin de validar su desempeño y estimar la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026. Este proceso se llevó a cabo mediante una estrategia de validación fuera de muestra, lo que permitió analizar la capacidad del modelo para generalizar su aprendizaje a datos no utilizados durante la fase de entrenamiento.

Para tal propósito, la serie temporal fue dividida en dos subconjuntos: un conjunto de entrenamiento, utilizado para ajustar los parámetros del modelo, y un conjunto de prueba, correspondiente a los últimos años de la serie, reservado para evaluar el desempeño predictivo. Esta metodología permite simular un escenario real de predicción, en el cual el modelo debe estimar valores futuros sin haber tenido acceso a ellos previamente.

El modelo seleccionado, con arquitectura NNAR (4,8), fue evaluado utilizando la métrica de Raíz del Error Cuadrático Medio (RMSE), la cual permitió cuantificar la precisión de las predicciones en comparación con los valores observados. Los resultados obtenidos

evidencian que el modelo presenta un desempeño adecuado en términos de error, lo que confirma su capacidad para capturar la dinámica subyacente de la serie temporal y generar estimaciones confiables.

Una vez validado el modelo, se procedió a su reentrenamiento utilizando la totalidad de los datos disponibles para el período 2010–2025, con el objetivo de maximizar la información incorporada en el proceso de aprendizaje. Posteriormente, se realizó una predicción a un paso adelante ( $h=1$ ), obteniéndose como resultado una estimación de 16,308 vehículos eléctricos registrados en Costa Rica para el año 2026.

Desde una perspectiva analítica, esta estimación se deriva de una función no lineal que integra la información de los cuatro años más recientes (2022–2025), procesada a través de las ocho neuronas en la capa oculta del modelo. Este proceso permite capturar patrones complejos de crecimiento, incluyendo posibles aceleraciones en la adopción de vehículos eléctricos, lo que otorga mayor realismo a la proyección en comparación con modelos lineales tradicionales.

Asimismo, es importante destacar que el modelo fue entrenado bajo un enfoque de múltiples repeticiones (ensemble), lo que implica que la predicción final corresponde al promedio de varias redes neuronales entrenadas con diferentes condiciones iniciales. Este procedimiento contribuye a reducir la varianza de las estimaciones y a mejorar la estabilidad del pronóstico, fortaleciendo la confiabilidad del resultado obtenido.

En conjunto, los resultados de la validación fuera de muestra y la proyección realizada permiten concluir que el modelo NNAR (4,8) posee una adecuada capacidad predictiva y constituye una herramienta confiable para la estimación del comportamiento futuro del número de vehículos eléctricos en Costa Rica. La proyección obtenida sugiere la continuidad de una tendencia creciente en la adopción de esta tecnología, lo cual tiene implicaciones relevantes para la planificación estratégica en sectores como energía, transporte e infraestructura sostenible.

## 6.4 Análisis general de los resultados

Los resultados obtenidos en la presente investigación evidencian una coherencia metodológica y empírica entre el análisis exploratorio de la serie temporal, el proceso de diseño y calibración del modelo, y la evaluación de su capacidad predictiva. En conjunto, estos hallazgos permiten dar respuesta a la pregunta de investigación y validar el uso de modelos de redes neuronales autorregresivas (NNAR) para la estimación del número de vehículos eléctricos en Costa Rica.

En relación con el Objetivo Específico N.º 1, el análisis de la serie temporal correspondiente al período 2010–2025 permitió identificar una tendencia creciente sostenida, acompañada de una aceleración en los años más recientes. Este comportamiento sugiere que el fenómeno estudiado responde a un proceso de adopción tecnológica en expansión, caracterizado por cambios progresivos en la dinámica del mercado. Asimismo, se evidenció la presencia de patrones no lineales, reflejados en variaciones en la pendiente de la serie, lo que indica que el crecimiento no sigue una trayectoria constante.

Por otra parte, no se encontraron indicios de estacionalidad, lo cual es consistente con la naturaleza anual de los datos. Estos resultados establecieron una base sólida para la selección de un modelo capaz de capturar tanto la dependencia temporal como la complejidad estructural del fenómeno.

En cuanto al Objetivo Específico N.º 2, el proceso de diseño y calibración del modelo permitió identificar como arquitectura óptima una red neuronal NNAR (4,8). Este resultado refleja un equilibrio adecuado entre la incorporación de memoria temporal, mediante el uso de cuatro rezagos, y la capacidad de modelar relaciones no lineales complejas, a través de ocho neuronas en la capa oculta. La selección de esta configuración, basada en la minimización del RMSE, confirma que la serie presenta una dependencia significativa de su historia reciente y una estructura funcional que no puede ser representada adecuadamente mediante modelos lineales.

Además, el uso de un enfoque de entrenamiento basado en múltiples repeticiones (ensemble) contribuyó a mejorar la estabilidad y robustez del modelo, reduciendo la variabilidad asociada a la inicialización aleatoria de los parámetros.

Por su parte, el Objetivo Específico N.º 3 permitió validar empíricamente la capacidad predictiva del modelo seleccionado mediante una estrategia de validación fuera de muestra.

Los resultados obtenidos evidencian que el modelo NNAR(4,8) presenta un desempeño satisfactorio en términos de precisión, lo que respalda su capacidad de generalización. A partir de este modelo, se estimó que la cantidad de vehículos eléctricos registrados en Costa Rica para el año 2026 alcanzará aproximadamente 16,308 unidades.

Esta proyección se fundamenta en una función no lineal que integra la información de los cuatro años más recientes, lo que permite capturar de manera adecuada la dinámica reciente del fenómeno. Asimismo, la utilización de un ensemble de redes neuronales y la generación de intervalos de predicción fortalecen la confiabilidad de la estimación, al considerar tanto la estabilidad del modelo como la incertidumbre inherente al proceso predictivo.

En términos integrales, los resultados muestran una clara correspondencia entre la naturaleza de la serie temporal y la estructura del modelo seleccionado. La presencia de tendencia creciente, no linealidad y dependencia temporal reciente es coherente con la elección de un modelo NNAR con múltiples rezagos y una capa oculta relativamente compleja. Esta alineación entre los hallazgos exploratorios y el desempeño del modelo refuerza la validez interna de la investigación.

En síntesis, se denota que el enfoque metodológico adoptado permitió no solo comprender la dinámica histórica del fenómeno, sino también generar una estimación confiable de su evolución futura. La proyección obtenida sugiere la continuidad del crecimiento en la adopción de vehículos eléctricos en Costa Rica, lo cual tiene implicaciones relevantes para la planificación estratégica en materia de transporte sostenible, política energética e infraestructura. De esta manera, los resultados alcanzados cumplen de manera

satisfactoria con los objetivos específicos planteados y aportan evidencia empírica sobre la utilidad de los modelos de redes neuronales en el análisis de series temporales complejas.

## **Capítulo VII. Hallazgos y recomendaciones**

Previo a la presentación de los resultados finales de la investigación, esta sección expone de manera estructurada los principales hallazgos derivados del proceso de análisis, modelado y validación del modelo predictivo desarrollado. Su propósito es sintetizar los aportes más relevantes obtenidos a lo largo del estudio, en concordancia con los objetivos específicos planteados y la pregunta de investigación.

La presentación se organiza mediante la identificación puntual de cada hallazgo, el cual será expuesto de forma clara y concisa, seguido de un análisis explicativo que profundiza en su significado, implicaciones y relación con el comportamiento de la serie temporal de vehículos eléctricos en Costa Rica. Este enfoque permite no solo destacar los resultados más importantes, sino también contextualizarlos dentro del proceso metodológico aplicado, particularmente en lo referente al análisis exploratorio de la serie, la selección de la arquitectura óptima del modelo NNAR y la evaluación de su capacidad predictiva.

De esta manera, la sección busca ofrecer una interpretación integral de los resultados, facilitando la comprensión de cómo el modelo de redes neuronales contribuye a estimar la cantidad de vehículos eléctricos para el año 2026, así como sentar las bases para la formulación de recomendaciones fundamentadas en evidencia empírica.

## **7.1 Hallazgos De La Investigación**

A continuación, se presentan los principales hallazgos obtenidos a partir del análisis de la serie temporal y del proceso de modelado predictivo mediante redes neuronales. Cada hallazgo se expone de forma puntual, seguido de una breve explicación que permite interpretar su significado y su aporte al cumplimiento de los objetivos de la investigación.

### ***7.1.1 Hallazgo 1: Crecimiento sostenido y acelerado del parque de vehículos eléctricos***

El análisis de la serie temporal 2010–2025 evidenció una tendencia claramente creciente, con una aceleración en los últimos años. Este comportamiento sugiere que la adopción de vehículos eléctricos en Costa Rica se encuentra en una fase de expansión, caracterizada por un incremento progresivo en la tasa de crecimiento.

### ***7.1.2 Hallazgo 2: Presencia de patrones no lineales en la dinámica del fenómeno***

La evolución de la serie no responde a una estructura lineal, sino que presenta cambios en la pendiente y posibles puntos de inflexión. Esto confirma que el comportamiento del mercado de vehículos eléctricos está influenciado por factores complejos, como políticas públicas, incentivos económicos y avances tecnológicos.

### ***7.1.3 Hallazgo 3: Dependencia significativa de la historia reciente (memoria temporal)***

La selección de cuatro rezagos en el modelo óptimo NNAR (4,8) indica que los valores de los últimos cuatro años contienen la información más relevante para explicar la evolución futura de la serie. Esto evidencia una dependencia temporal de corto a mediano plazo en la dinámica del fenómeno.

### ***7.1.4 Hallazgo 4: Ausencia de estacionalidad en la serie temporal***

Dado que los datos analizados son de frecuencia anual, no se identificaron patrones estacionales recurrentes. En consecuencia, el comportamiento de la serie está determinado principalmente por su tendencia y sus componentes no lineales.

#### ***7.1.5 Hallazgo 5: Adecuación del modelo NNAR para capturar la complejidad del fenómeno***

El modelo de redes neuronales autorregresivas demostró ser una herramienta eficaz para modelar la serie, al capturar tanto la dependencia temporal como las relaciones no lineales presentes en los datos. La arquitectura óptima NNAR (4,8) refleja un equilibrio entre capacidad de aprendizaje y generalización.

#### ***7.1.6 Hallazgo 6: Capacidad predictiva robusta validada fuera de muestra***

La validación fuera de muestra evidenció que el modelo posee una adecuada capacidad de generalización, manteniendo un desempeño consistente al predecir datos no utilizados en el entrenamiento. Esto respalda la confiabilidad de las estimaciones generadas.

#### ***7.1.7 Hallazgo 7: Proyección de crecimiento continuo para el año 2026***

El modelo estimó que la cantidad de vehículos eléctricos registrados en Costa Rica alcanzará aproximadamente 16,308 unidades en 2026, lo que confirma la continuidad de la tendencia creciente y sugiere una consolidación del proceso de adopción tecnológica.

#### ***7.1.8 Hallazgo 8: Importancia del enfoque ensemble en la estabilidad del modelo***

El uso de múltiples repeticiones en el entrenamiento permitió reducir la variabilidad de las predicciones y mejorar la robustez del modelo, lo cual es especialmente relevante en contextos de datos limitados como series anuales.

## **7.2 Recomendaciones de la Investigación**

A continuación, se presentan las recomendaciones derivadas de los hallazgos obtenidos en la investigación. Estas se formulan con base en la evidencia empírica generada y en el desempeño del modelo predictivo desarrollado, con el propósito de orientar la toma de decisiones y futuras líneas de análisis en torno al crecimiento de los vehículos eléctricos en Costa Rica. Se detallará cada recomendación de forma puntual, seguida de un breve texto que profundiza los contenidos de las mismas.

#### ***7.2.1 Incorporar modelos de redes neuronales en la planificación pública***

Se recomienda a las instituciones públicas utilizar modelos predictivos basados en redes neuronales como herramientas de apoyo para la toma de decisiones, particularmente en áreas como transporte, energía y sostenibilidad.

#### ***7.2.2 Fortalecer la infraestructura de movilidad eléctrica***

Dado el crecimiento proyectado del parque de vehículos eléctricos, es necesario anticipar la demanda futura mediante la expansión de infraestructura de recarga, redes eléctricas y servicios asociados.

#### ***7.2.3 Diseñar políticas públicas basadas en evidencia predictiva***

Los resultados del modelo pueden servir como insumo para la formulación de políticas orientadas a incentivar la adopción de vehículos eléctricos, tales como beneficios fiscales, financiamiento y regulaciones ambientales.

#### ***7.2.4 Ampliar la base de datos y frecuencia de los registros***

Se recomienda mejorar la disponibilidad y granularidad de los datos, incorporando información mensual o trimestral, así como variables adicionales (por ejemplo, precios, incentivos, infraestructura), lo cual permitiría desarrollar modelos más precisos y robustos.

#### ***7.2.5 Comparar con modelos alternativos en futuras investigaciones***

Para fortalecer la validez externa del estudio, se sugiere realizar comparaciones con otros enfoques de modelado, como ARIMA o modelos basados en aprendizaje automático más avanzados.

#### ***7.2.6 Realizar actualizaciones periódicas del modelo***

Dado que el fenómeno analizado es dinámico, se recomienda recalibrar el modelo de forma periódica conforme se disponga de nuevos datos, con el fin de mantener la precisión de las estimaciones.

## **Referencias Bibliográficas**

- Adamashvili, N., & Thrassou, A. (2024). *Towards sustainable decarbonization: Addressing challenges in electric vehicle adoption and infrastructure development*. *Energies*, 17(21), 5443
- Agencia Internacional de Energía. (2023). *CO<sub>2</sub> emissions in 2022: Transport sector analysis*. International Energy Agency.
- Agencia Internacional de Energía. (2024). *Global EV outlook 2024: Catching up with climate ambitions*. International Energy Agency.
- Al Noman, A., & Siam, H. H. (2025). The economic, social & environmental impact of electric vehicle (EV) adaptation on Bangladeshi society. arXiv.
- Asamblea Legislativa de la República de Costa Rica. (2018). *Ley N.º 9518: Ley de incentivos y promoción para el transporte eléctrico*. La Gaceta.
- Asociación Costarricense de Movilidad Eléctrica (ASOMOVE),, <https://asomove.org/indicadores>
- Autoridad Reguladora de los Servicios Públicos. (2020). *Estudio técnico sobre autobuses eléctricos en Costa Rica*. ARESEP.
- Blanco, H., Nijs, W., Ruf, J., & Faaij, A. (2018). Potential of hydrogen and Power-to-Liquid in a low-carbon EU energy system using cost optimization. *Applied Energy*, 232, 617–639.
- Boyle, G. (2017). *Renewable energy: Power for a sustainable future* (4th ed.). Oxford University Press.
- Chollet, F. (2018). *Deep learning with Python*. Manning Publications.
- Colmenar-Santos, A., Borge Diez, D., & Rosales-Asensio, E. (Eds.). (2020). *Locally Available Energy Sources and Sustainability*. MDPI Books.
- Consejo Nacional de Rectores (Costa Rica). Programa Estado de la Nación. (2018). *Informe Estado de la Nación en desarrollo humano sostenible 2018* (Informe Estado de la Nación; 24). San José, C.R.: Programa Estado de la Nación.
- Costa Rica. Asamblea Legislativa. (2018). *Ley N.º 9518: Incentivos y promoción para el transporte eléctrico*. Imprenta Nacional.
- Elman, J. L. (1990). Finding structure in time. *Cognitive Science*, 14(2), 179–211.

- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Grubb, M., Hourcade, J.-C., & Neuhoff, K. (2018). *Planetary economics: Energy, climate change and the three domains of sustainable development*. Routledge.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). Springer.
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts.
- International Energy Agency (IEA). (2020). *World Energy Outlook 2020*. Paris: IEA.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An introduction to statistical learning* (2nd ed.). Springer.
- Lukuyu, J., Shirley, R., & Taneja, J. (2024). *Managing grid impacts from increased electric vehicle adoption in African cities*. *Scientific Reports*, 14, 24320.
- Ministerio de Ambiente y Energía (Minae). (2025). *Transporte y electricidad: Plan Nacional de Descarbonización 2018–2050*. Gobierno de Costa Rica.
- Ministerio de Ambiente y Energía. (2022). *Balance energético nacional 2022*. MINAE.
- Ministerio de Planificación Nacional y Política Económica (Mideplan). (2025). *Movilidad eléctrica en Costa Rica: Oportunidades para una sociedad descarbonizada. Avances 2020-2024*. Gobierno de Costa Rica.
- Okot, T., Solís Barquero, C. F., & Valverde, F. A. (2021). Potential of renewable energy production: An assessment of Costa Rica's decarbonization plan. *Rhombus*, 1(2), 26–49.
- Organisation for Economic Co-operation and Development. (2023). *OECD Environmental Performance Reviews: Costa Rica 2023*. OECD Publishing.
- Panel Intergubernamental sobre Cambio Climático. (2022). *Climate change 2022: Mitigation of climate change (Working Group III contribution to the Sixth Assessment Report)*. Cambridge University Press.
- Twidell, J., & Weir, T. (2015). *Renewable energy resources* (3rd ed.). Routledge.
- Yengil Bülbül, B., & Baydar, M. B. (2025). Decarbonizing Transportation: Cross-Country Evidence on Electric Vehicle Sales and Carbon Dioxide Emissions. *World Electric Vehicle Journal*, 16(12), 660.

- Zaino, R., Ahmed, V., Alhammadi, A. M., & Alghoush, M. (2024). *Electric vehicle adoption: A comprehensive systematic review of technological, environmental, organizational and policy impacts*. *World Electric Vehicle Journal*, 15(8), 375.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. *International J.*