



Maestría en

SISTEMAS DE INFORMACIÓN



Mención **Inteligencia de Negocios y Analítica de Datos Masivos.**

AUTORES:

López Quilligana Francisco Isaac

Chiliquinga Jiménez Gabriela Estefanía

Guamba Suntaxi Jajaira Michelle

Campaña Ayala Luis Omar

TUTOR:

Vizcaíno Imacaña Fernanda Paulina

DESARROLLAR UN MODELO DE MACHINE LEARNING PARA ESTIMAR LA
CANTIDAD DE ENERGÍA REQUERIDA POR UN SISTEMA DE TRANSPORTE
ELÉCTRICO EN EL CANAL DE ITABACA, ISLAS GALÁPAGOS.

APROBACIÓN DEL TUTOR

Yo, Paulina Vizcaíno Imacaña, certifico que conozco los autores del presente trabajo siendo la responsable exclusiva tanto de su originalidad y autenticidad, como de su contenido.

A handwritten signature in blue ink, reading "Paulina Vizcaíno Imacaña", positioned above a horizontal line.

Paulina Vizcaíno Imacaña
DIRECTOR DE TESIS

Certificación de Autoría

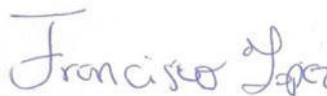
Nosotros **López Quilligana Francisco Isaac, Chilibuina Jiménez Gabriela Estefanía, Guamba Suntuji Jajaira Michelle, Campaña Ayala Luis Omar** declaramos bajo juramento que el trabajo aquí descrito es de nuestra autoría; que no ha sido presentado anteriormente para ningún grado o calificación profesional y que se ha consultado la bibliografía detallada.

Cedemos nuestros derechos de propiedad intelectual a la Universidad Internacional del Ecuador (UIDE), para que sea publicado y divulgado en internet, según lo establecido en la Ley de Propiedad Intelectual, su reglamento y demás disposiciones legales.



1729 134815

Chilibuina Jiménez Gabriela Estefanía



López Quilligana Francisco Isaac



Guamba Suntuji Jajaira Michelle



180455196-6

Campaña Ayala Luis Omar

Autorización de Derechos de Propiedad Intelectual

Nosotros **López Quilligana Francisco Isaac, Chilibuina Jiménez Gabriela Estefanía, Guamba Suntaxi Jajaira Michelle, Campaña Ayala Luis Omar** en calidad de autores del trabajo de investigación titulado *Desarrollar un modelo de machine learning para estimar la cantidad de energía requerida por un sistema de transporte eléctrico en el canal de Itabaca, Islas Galápagos*, autorizamos a la Universidad Internacional del Ecuador (UIDE) para hacer uso de todos los contenidos que nos pertenecen o de parte de los que contiene esta obra, con fines estrictamente académicos o de investigación. Los derechos que como autores nos corresponden, lo establecido en los artículos 5, 6, 8, 19 y demás pertinentes de la Ley de Propiedad Intelectual y su Reglamento en Ecuador.

D. M. Quito, septiembre 2024

Chilibuina Jiménez Gabriela Estefanía

López Quilligana Francisco Isaac

Guamba Suntaxi Jajaira Michelle

Campaña Ayala Luis Omar

Dedicatoria

Dedicamos este trabajo a nuestras familias, quienes han sido nuestro mayor apoyo durante la finalización de este objetivo.

Dedico este trabajo a Dios, a mis padres y a mis amigos, quienes me han apoyado incondicionalmente a lo largo de este camino. Sus consejos, experiencias y conocimientos han sido fuente de grandes enseñanzas que me han acompañado en todo momento.

Gabriela Chiliquinga Jiménez

Agradecimiento

Queremos expresar nuestro más sincero agradecimiento a todas las personas e instituciones que nos acompañaron a lo largo de este proceso. En especial, agradecemos al Ing. Marcelo Moya, PhD (c), por su invaluable apoyo, orientación y compromiso incondicional durante el desarrollo de esta tesis. Asimismo, extendemos nuestro agradecimiento al Instituto de Investigación Geológico y Energético, así como a la empresa pública CELEC EP, encargada de la generación eléctrica, y a ELECGALAPAGOS S.A., por la valiosa información y colaboración que brindaron para la realización de este trabajo.

Agradezco profundamente a Dios por darme la fortaleza y sabiduría necesarias para superar los desafíos de este proyecto. A mis padres, por su amor, paciencia y apoyo incondicional a lo largo de mi formación. A mis amigos, por su compañía, motivación y valiosos consejos, es fundamental reconocer el significativo apoyo del Ing. Michael Guerra durante todo el proceso clave para el éxito de este proyecto. También extendo mi gratitud a mis mentores, quienes con su guía y conocimientos me han inspirado a alcanzar mis metas. A todos, gracias por ser parte esencial de este logro.

Gabriela Chilibingua Jiménez

Resumen Ejecutivo

Este proyecto propone el desarrollo de un modelo predictivo basado en machine learning para optimizar el consumo energético del catamarán solar "INER 1", utilizado en el Canal de Itabaca, Islas Galápagos. Dada la necesidad de reducir el uso de combustibles fósiles y minimizar la huella de carbono, el modelo contribuirá a mejorar la sostenibilidad ambiental en la región.

El objetivo principal es diseñar un modelo predictivo que permita prever con precisión el consumo energético del catamarán, integrando variables clave como la radiación solar, temperatura, velocidad del viento, nivel de radiación global, capacidad de almacenamiento de batería, y número de pasajeros a bordo. Con ello, se optimizará la eficiencia operativa del catamarán y se reducirá su impacto ambiental, contribuyendo a la sostenibilidad en las Islas Galápagos.

La metodología empleada se basa en modelos de redes neuronales híbridas, combinando Autoencoder y LSTM (Long Short-Term Memory). Los datos sobre radiación solar, temperatura, turistas, velocidad del viento y carga de pasajeros se procesan utilizando herramientas avanzadas de análisis estadístico y machine learning. El Autoencoder permite reducir la dimensionalidad de los datos, mientras que LSTM identifica patrones en las series temporales, lo que mejora la precisión en las predicciones.

El análisis PCA revela que factores climáticos y la demanda turística son determinantes en el consumo energético. El modelo Autoencoder-LSTM obtuvo un coeficiente de determinación con un porcentaje muy aceptable, lo que indica que captura el 96.8% de la variabilidad en los datos. En escenarios de alta demanda turística, el sistema depende más de la

red eléctrica, mientras que, en baja demanda, la generación solar es suficiente, aunque con menor ingreso.

Este modelo es escalable y puede aplicarse en otros sistemas de transporte marítimo sostenible, aportando soluciones energéticas limpias y eficientes.

Palabras clave: Islas Galápagos; machine learning; consumo energético; catamarán solar; sostenibilidad ambiental.

Abstract

This project proposes the development of a predictive model based on machine learning to optimize the energy consumption of the solar catamaran "INER 1," which operates in the Itabaca Channel, Galápagos Islands. Given the need to reduce fossil fuel usage and minimize carbon footprints, the model will contribute to enhancing environmental sustainability in the región.

The primary objective is to design a predictive model that accurately forecasts the catamaran's energy consumption by integrating key variables such as solar radiation, temperature, wind speed, global radiation level, battery storage capacity, and the number of passengers onboard. This will optimize the catamaran's operational efficiency and reduce its environmental impact, thus contributing to the sustainability of the Galápagos Islands.

The methodology is based on hybrid neural network models, combining Autoencoder and Long Short-Term Memory (LSTM). Temporal data on solar radiation, temperature, wind speed, battery capacity, and passenger load are processed using advanced statistical analysis and machine learning tools. The Autoencoder reduces data dimensionality, while LSTM identifies patterns in the time series, enhancing prediction accuracy.

The PCA analysis reveals that climatic factors and tourism demand are determinants of energy consumption. The Autoencoder-LSTM model obtained a coefficient of determination with a very acceptable percentage, indicating that it captures 96.8% of the variability in the data. In scenarios of high tourist demand, the system depends more on the electrical grid, while, in low demand, solar generation is sufficient, although with lower income.

This model is scalable and can be applied to other sustainable maritime transport systems, providing clean and efficient energy solutions.

Keywords: Galápagos Islands; machine learning; energy consumption; solar catamaran; environmental sustainability.

Tabla de contenido

Resumen Ejecutivo	7
Abstract	9
Glosario de Términos	18
Capítulo 1	20
1.1 Introducción	20
1.2 Problema de Investigación	21
1.3 Objetivos	21
1.3.1 Objetivo General	21
1.3.2 Objetivos Específicos	22
1.4 Alcance del Proyecto	22
1.5 Análisis Pestel	22
1.5.1 Factor Político	22
1.5.2 Factor Económico	24
1.5.3 Factor Social	26
1.5.4 Factor Tecnológico	28
1.5.12 Factor Ecológico	31
1.5.13 Factor Legal	33
1.6 Stakeholders y Áreas del Negocio Involucradas	34
1.7 Fuentes de Información	35
1.8 Estructura de Datos	36
1.9 Fuentes de Datos Primarias	36
1.10 Fuentes de Datos Secundarias	37

	12
1.11 Tratamiento de Datos	38
Capítulo 2	39
2.1 Marco Teórico	39
2.1.1 Aprendizaje Supervisado	39
2.1.2 Definición de Machine Learning	39
2.1.3 Modelos de Machine Learning	40
2.1.4 Red Neuronal Artificial	43
2.1.5 Tipos de Redes Neuronales	44
2.1.6 Funciones de Activación	46
2.1.7 Número de Capas	47
2.1.8 Gradiente Desciende	48
2.1.9 Red Neuronal Híbrida Autoencoder-LSTM	49
2.1.10 Programación Python	51
2.2 Arquitectura del Modelo	51
2.2.1 Ecosistema de Datos	52
2.3 Métricas de Valor	53
2.3.1 Margen Operativo	54
2.3.2 Margen Neto	54
2.3.3 VAN	55
2.3.4 TIR	55
2.3.5 Payback	55
2.4 Metodología	56
2.4.1 CRISP-DM (Cross-Industry Standard Process for Data Mining)	56

	13
2.5 Análisis EDA	58
2.5.1 Valores Faltantes	59
2.5.2 Medidas Descriptivas	62
2.5.3 Matrices de Correlación	64
2.6 Validación de variables influyente	65
2.7 Modelación con series temporales	67
2.7.1 Modelo ARIMA	67
2.7.2. Modelo SARIMAX	73
2.8 Construcción de la Red- Autoencoder-LSTM	76
2.8.1 Preparación de datos	76
2.8.2 Ingreso de Datos	76
2.8.3 Creación de la Red neuronal	78
2.8.4 Hiperparámetros de la red neuronal	79
2.8.5 Simulaciones de escenarios factor Turistas	80
2.8.6 Simulaciones de escenarios factor Clima	81
2.9 Desarrollo Business Case: Operación de Catamaranes Solares con Energía Solar	83
2.9.1. Introducción	83
2.9.2 Análisis de la Demanda de Energía y Operación de Catamaranes Energía Solar y Red Eléctrica	83
2.9.3 Simulaciones de Escenarios de Demanda de Energía para 2024	84
2.9.4. Capacidad de Operación de Catamaranes Eléctricos	88
2.9.5. Impacto Financiero	89
2.9.6. Almacenamiento	90

	14
2.9.7. Control operativo - Oportunidades de Carga	91
2.9.8. Análisis Comparativo del Consumo Energético de Catamaranes Eléctricos en Relación con la Capacidad de Generación de la Isla Santa Cruz	92
2.9.9. Comparación de rentabilidad entre Catamarán y Lancha	94
2.9.10. Impacto ambiental	96
2.9.11. Escalabilidad y Aplicación del Modelo de Catamarán Solar a Gran Escala	97
Capítulo 3	100
3.1 Resultados Análisis PCA	100
3.1.1 Componente 1	101
3.1.2 Componente 2	101
3.2 Resultados Red neuronal Autoencoder-LSTM	103
3.3 Resultados Simulaciones de Escenarios	109
3.4 Análisis del Impacto de Factores Externos: Clima	110
Capítulo 4	113
Conclusiones	113
Recomendaciones	117
Anexos	121
Bibliografía	125

Lista de Tablas

Tabla 1 <i>Métricas de energía, ambiente y turismo</i>	54
Tabla 2 <i>Métricas de energía, ambiente y turismo</i>	56
Tabla 3 <i>Estructura de datos</i>	59
Tabla 4 <i>Prueba de estacionalidad</i>	68
Tabla 5 <i>Descripción variables</i>	77
Tabla 6 <i>Resultados de predicción de la energía Red Neuronal</i>	81
Tabla 7 <i>Resultados energía solar, red eléctrica y energía total</i>	84
Tabla 8 <i>Factor Planta</i>	85
Tabla 9 <i>Resultados de simulaciones escenarios</i>	86
Tabla 10 <i>Resultados energía solar, red eléctrica, energía total de 7 catamaranes</i>	88
Tabla 11 <i>Costo de energía</i>	89
Tabla 12 <i>Resultados costo, ahorro y proyección</i>	90
Tabla 13 <i>Resultados costo energía vespertina y nocturna</i>	91
Tabla 14 <i>Capacidad total de generación de la isla</i>	92
Tabla 15 <i>Demanda máxima</i>	93
Tabla 16 <i>Consumo energético con relación a las islas</i>	94
Tabla 17 <i>Comparación de rentabilidad entre Catamarán y Lancha</i>	94
Tabla 18 <i>Análisis de valor unidad</i>	96
Tabla 19 <i>Componentes principales</i>	100
Tabla 20 <i>Métricas de evaluación</i>	106
Tabla 21 <i>Otras métricas de evaluación</i>	107

Tabla 22 *Simulaciones de varios escenarios*

109

Tabla 23 *Simulaciones de varios escenarios Clima*

111

Lista de Figuras

Ilustración 1 <i>Arquitectura básica de una red neuronal (Haykin 1998)</i>	44
Ilustración 2 <i>Red neuronal profunda con tres capas ocultas</i>	48
Ilustración 3 <i>Arquitectura del autoencoder</i>	50
Ilustración 4 <i>Arquitectura del modelo</i>	52
Ilustración 5 <i>Fases de la metodología CRISP-DM</i>	58
Ilustración 6 <i>Histogramas de las variables representativas</i>	61
Ilustración 7 <i>Medidas descriptivas</i>	63
Ilustración 8 <i>Matrices de correlación</i>	64
Ilustración 9 <i>Serie temporal</i>	67
Ilustración 10 <i>Autocorrelación de residuos</i>	69
Ilustración 11 <i>Autocorrelación parcial</i>	69
Ilustración 12 <i>Resultados ARIMA</i>	71
Ilustración 13 <i>Resultados SARIMAX</i>	74
Ilustración 14 <i>Proyección de los datos</i>	103
Ilustración 15 <i>Serie temporal Perdida del modelo Autoencoder-LSTM</i>	104
Ilustración 16 <i>Predicciones del Autoencoder-LSTM</i>	105
Ilustración 17 <i>Gráfica de predicciones con lineal ideal</i>	107
Ilustración 18 <i>Predicción de energía un año futuro</i>	108

Glosario de Términos

- **Banco de baterías:** Conjunto de baterías interconectadas utilizadas para almacenar energía generada, por ejemplo, por un sistema fotovoltaico en el catamarán solar.
- **Catamarán:** Es una embarcación o buque multicasco con dos cascos paralelos de igual tamaño.
- **CSV:** Es un formato de archivo de texto utilizado para almacenar y transmitir datos tabulares en forma de filas y columnas.
- **Eólica:** Energía que se obtiene a partir del viento.
- **Fotovoltaica:** Es una fuente de energía que produce electricidad de origen renovable, obtenida directamente de la radiación solar.
- **Impacto ambiental:** Consecuencia que una acción o proyecto tiene sobre el medio ambiente.
- **KDD (knowledge discovery in databases):** Proceso de descubrimiento de conocimiento útil a partir de grandes volúmenes de datos.
- **Machine learning:** Campo de la inteligencia artificial que se enfoca en el desarrollo de algoritmos que permiten a las computadoras aprender de datos y hacer predicciones o tomar decisiones.
- **Panel solar:** Dispositivo que convierte la energía solar en energía eléctrica, compuesto de celdas fotovoltaicas.
- **Prototipo:** Modelo inicial de un producto que se utiliza para pruebas y mejoras antes de la producción en serie.

- **Radiación global:** Medida de la energía solar que incide sobre una superficie específica, generalmente utilizada en la evaluación del potencial de generación de energía fotovoltaica.
- **Sostenibilidad ambiental:** Principio de desarrollo que busca satisfacer las necesidades del presente sin comprometer la capacidad de las futuras generaciones de satisfacer sus propias necesidades, especialmente en términos de conservación del medio ambiente.

Capítulo 1

1.1 Introducción

En el presente proyecto se desarrolla un modelo predictivo de machine learning para la optimización del consumo energético del catamarán solar "INER 1", con el fin de mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental en las Islas Galápagos, operando desde el lugar. Además, se integrará y analizará información de diversas fuentes, incluyendo datos meteorológicos, y de operación del catamarán para mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental.

Un medio importante dentro las conexiones entre las islas Galápagos es el transporte marítimo que influye directamente en el ambiente, provocando resultados negativos dentro de la misma, según Moya (2019) “el transporte marítimo de pasajeros en las Islas Galápagos, especialmente en el Canal de Itabaca, ha dependido tradicionalmente de embarcaciones con motores de combustión interna” el promedio de consumo anual es de aproximadamente 4,200 galones de combustible, generando alrededor de 38 toneladas de CO₂ por año.

En su esfuerzo por proteger el medio ambiente, el Instituto de Investigación Geológico y Energético (IIGE) diseñó un prototipo de embarcación catamarán llamado INER1, de manera que se afirma que el navío con el objetivo de reducir la huella de carbono utiliza energía solar, el modelo se encuentra vigente desde octubre de 2015 en el que no solo beneficia a los pasajeros durante su viaje sino que la dependencia al combustible fósil es mínimo y ambientalmente es más sostenible por la disminución de la emisión de CO₂, Moya (2019).

El propósito es desarrollar un sistema de predicción del consumo energético del catamarán solar "INER 1", con el fin de mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental en las Islas Galápagos en la planificación futura de la cantidad de

energía que requiere para opera el catamarán y la escalabilidad de cuantas más embarcaciones de este tipo se podrían implementar. Este contexto subraya la importancia de encontrar una solución sostenible y eficiente en términos energéticos para preservar el frágil ecosistema de las Islas Galápagos.

1.2 Problema de Investigación

La idea surge como una continuación de un proyecto anterior y busca demostrar las ventajas de la optimización y eficiencia de las energías limpias y renovables en el transporte de turistas a través del Canal de Itabaca en el Parque Nacional Galápagos. El impacto negativo de la quema de combustibles fósiles, su alto costo y la deficiente red pública de energía hacen que la autogeneración eléctrica sea una opción viable. Sin embargo, la comprensión y el aprovechamiento eficiente de esta opción pueden mejorar aún más los beneficios ambientales, económicos y los incentivos que ofrecen las entidades gubernamentales.

Este proyecto ofrece beneficios ecológicos directos y también posiciona al Instituto de Investigación Geológico y Energético quien diseño el prototipo de embarcación INER1 como líder en sostenibilidad, lo cual puede traducirse en ventajas competitivas significativas en el mercado turístico de las Islas Galápagos.

1.3 Objetivos

1.3.1 Objetivo General

Diseño de un modelo predictivo de machine learning para la optimización del consumo energético del catamarán solar "INER 1", con el fin de mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental en las Islas Galápagos.

1.3.2 Objetivos Específicos

- Validar las variables más influyentes en el consumo energético utilizando técnicas de big data.
- Realizar el modelo predictivo en base a la técnica optima seleccionada.
- Evaluar el resultado del modelo predictivo obtenido en función de los parámetros de entrada, simulando distintos escenarios de comportamiento de la embarcación en un caso de negocio.

1.4 Alcance del Proyecto

Este proyecto tiene como objetivo desarrollar un modelo predictivo de machine learning para la optimización del consumo energético del catamarán solar "INER 1", con el fin de mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental en las Islas Galápagos", operando en las Islas Galápagos. Se integrará y analizará información de diversas fuentes, incluyendo datos meteorológicos, y de operación del catamarán, para mejorar la eficiencia operativa y contribuir a la sostenibilidad ambiental específicamente en lo correspondiente a transportación turística por el Canal de Itabaca.

1.5 Análisis Pestel

1.5.1 Factor Político

El Gobierno Nacional a través del Ministerio de Energía Renovable y no Renovable promueve desde el año 2007 la iniciativa “Cero Combustibles Fósiles en las Islas Galápagos”, que tiene como objetivo principal la disminución del uso de derivados del petróleo o combustibles fósiles en el archipiélago de Galápagos, por medio del aprovechamiento de recursos renovables. Con el fin de apoyar a la iniciativa “Cero Combustibles Fósiles en las Islas

Galápagos”, la entidad gubernamental ha destinado inversión a proyectos generadores de energía alternativa con el apoyo de organismos internacionales, tales como:

- Banco de Desarrollo de América Latina (CAF).
- Agencia Japonesa de Cooperación Internacional (JICA).
- El Fondo Mundial para la Naturaleza (WWF).
- Organización de las Naciones Unidas para la Alimentación y Agricultura (FAO).
- Ministerio de Agricultura (MAG).
- Ministerio de Energía y Recursos Naturales no Renovables (MERNNR).
- Consejo de Régimen Especial del Gobierno de las Galápagos; y el apoyo de los tres alcaldes del Archipiélago (San Cristóbal, Santa Cruz e Isabela); y del Parque Nacional Galápagos.

En el año 2023 el Gobierno Ecuatoriano y el Banco Internacional del Ecuador propuso el cambio de la matriz energética a través del “Plan de Transición Energética de las Islas Galápagos” se propuso disminuir el impacto fiscal de los subsidios a los combustibles líquidos y energía eléctrica a través de la reducción significativa del uso de los combustibles fósiles y la promoción de la introducción de las energías renovables en el Archipiélago. Asimismo, el plan “contempla aprovechar los mercados de carbono para financiar programas basados en comunidades, ecosistemas y naturaleza”, Ministerio de Energía y Minas (2023).

Según el boletín de prensa del Ministerio de Energía y Minas (2023) acerca de la transición energética el lanzamiento del Plan de Transición Energética contempla la implementación de políticas que promuevan una reducción significativa del consumo energético fósil en un corto 2025 y mediano plazo 2030; y, un consumo mínimo en el largo plazo 2050 mediante las siguientes líneas de acción:

- Incorporar fuentes de energía renovable no convencional, un programa de eficiencia energética y de gestión de la demanda, sistemas de almacenamiento de energía e inversores en la red que aseguren la atención de la demanda en un 85% a partir de fuentes limpias en el 2030.
- Implementar un plan integral del transporte público que permita una movilidad urbana sostenible.
- Ejecutar un plan integral de transporte marítimo que genere incentivos que permitan hacer más eficiente el uso de diésel y a futuro sustituir embarcaciones utilizando nuevos vectores energéticos.

El representante de JICA expresó su apoyo a las políticas públicas que mantiene el Gobierno del Ecuador en beneficio de los habitantes del Archipiélago de Galápagos a favor de preservar el medio ambiente y fauna de las Islas Galápagos suscribiéndose en el registro de la “Hoja de Ruta” del proyecto planteado del Ministerio de Energía y Minas.

El diseño de un modelo predictivo para optimizar el consumo energético del catamarán solar "INER 1" se alinea con la estrategia de sostenibilidad y transición energética del Gobierno Ecuatoriano en las Islas Galápagos. Además de mejorar la eficiencia operativa y reducir el impacto ambiental, contribuye a las políticas que buscan disminuir el uso de combustibles fósiles. Este enfoque no solo favorece la sostenibilidad, sino que también reduce la dependencia de subsidios y promueve la inversión en energías renovables, mejorando la competitividad económica de la región.

1.5.2 Factor Económico

En 2024, la economía de Galápagos se caracteriza por una fuerte dependencia del turismo, que sigue siendo su principal fuente de ingresos. Este sector, sin embargo, se encuentra

bajo un marco de regulaciones más estrictas orientadas a la sostenibilidad y la conservación del medio ambiente, la promoción del ecoturismo ha diversificado la oferta turística con actividades responsables, mientras que la pesca y la agricultura local permanecen relevantes pero limitadas para proteger los ecosistemas únicos del archipiélago. Además, la región está experimentando un aumento en la inversión en energías renovables y tecnologías verdes, buscando reducir su huella ambiental y asegurar un desarrollo económico equilibrado.

De acuerdo Review (2023) la economía depende en gran medida del turismo que representa aproximadamente el 80% de la economía local, esta cifra demuestra la gran importancia que tiene el turismo exterior en las islas, sin embargo, no todo es bueno debido que depender únicamente de un sector causa que en momentos críticos como por ejemplo la pandemia las Galápagos se conviertan en unas de las provincias más afectadas. En el año 2023 recibieron a un total de 329,475 turistas de esta cifra el 54% fueron extranjeros sumando 179,000 visitantes, mientras que el 46% restante correspondió a turistas nacionales con 151,000 llegadas. De manera comparable, el número de turistas nacionales creció un 23%, equivalente a un incremento de 29,000 personas.

Otro indicador importante que se evalúa mensualmente es la tasa de desempleo que según el INEC (2023) Galápagos cerró el año 2023 en 4.2% en comparación al año 2022 el 5,6%, esto se da a la recuperación del flujo de turista que visitaron las islas Galápagos. Es así como se puede observar que esta provincia depende en gran medida del turismo, que constituye aproximadamente el 80% de los ingresos locales, mejorar la eficiencia energética y reducir la huella ambiental refuerza el atractivo del archipiélago como destino de ecoturismo, al alinear el proyecto con las tendencias actuales de inversión en energías renovables y tecnologías verdes, se contribuye a un desarrollo económico más sostenible.

1.5.3 Factor Social

Turismo Sostenible. El turismo sostenible globalmente ha experimentado un crecimiento significativo en los últimos años "el 66% de los viajeros globales estarían dispuestos a pagar más por opciones de viaje sostenibles", Organización Mundial del Turismo (2019). Es así como en el área de proyectos ecoturísticos influye de manera directa ya que el catamarán solar de Galápagos aportando de forma directa un aumento de las energías renovables y disminución de la contaminación.

Las Islas Galápagos además de ser identificadas como Patrimonio Mundial de la UNESCO aportan con un gran impacto ambiental, económico y social, "el ecoturismo en Galápagos ha crecido significativamente en las últimas décadas, convirtiéndose en un pilar fundamental de la economía local" Granda León (2019). Así como el catamarán solar INER 1 beneficia a la creación de proyectos sostenibles que mejoren los sistemas ecológicos.

Por otra parte, el perfil de los turistas que visitan las Islas Galápagos posee un mayor grado de conciencia ambiental del medio ambiente. Un estudio encontró que "los turistas en Galápagos están dispuestos a pagar una prima por experiencias que preserven el ecosistema único de las islas" Rivera & Croes (2010, p. 95). Adicional el catamarán incluiría oportunidades para posicionarse como una atracción propia, no solo originar viajes turísticos (tours educativos) que manejen la información de energía renovable, sino también la conservación marina de las islas, potenciando el crecimiento de un mayor gasto por experiencias sostenibles.

Aceptación de Nuevas Energías Renovables. La aceptación de las energías renovables es un factor muy influyente dentro de la conciencia ambiental local de las islas, ya que los residentes normalmente tienen un alto grado de ética en la conservación motivo por la cual "la comunidad local está preocupada por los impactos ambientales y apoya iniciativas sostenibles"

Benítez-Capistros (2014) teniendo un alto grado de inclinación por precautelar el entorno donde habitan mejorando los problemas actuales.

En las islas Galápagos actualmente ya se encuentran implementados proyectos que utilizan energía renovable, "la Isla Baltra y Santa Cruz tiene un parque eólico, y San Cristóbal y Santa Cruz cuenta con sistemas fotovoltaicos" Irena (2021), la experiencia previa a este tipo de proyectos puede anticipar que la comunidad ha tenido una acogida positiva a este tipo de implementaciones sostenibles.

La comunidad local percibe los beneficios que aportan los proyectos sostenibles ya que se proporciona los beneficios comprensibles a las personas. Benítez-Capistros et al. (2014) sugieren que "los proyectos que demuestran beneficios claros para la comunidad y el medio ambiente tienden a recibir mayor apoyo local" (p. 120).

Eras (2019) comenta que "La implementación de proyectos de energía renovable en las Islas Galápagos ha recibido un amplio apoyo tanto de la población local como de las autoridades, debido a su alineación con los objetivos de conservación del patrimonio natural". Proyectos como ENER GAL que ya ha sido implementado e incluye la instalación de sistemas fotovoltaicos se ha visto particularmente bien recibido, con una alta aceptación de la comunidad local y visitante, por lo expuesto la aceptación es un factor a favor que mejorar un entorno sostenible en las islas encantadas.

El proyecto planteado no solo apoya las iniciativas ecoturísticas esenciales para la economía local, sino que también fomenta la conciencia ambiental en la comunidad promoviendo el uso de energías renovables. Al integrar tecnologías sostenibles en el transporte marítimo se reduce la dependencia de combustibles fósiles, se diversifica la economía y se atraen

turistas conscientes del medio ambiente, lo que impulsa el crecimiento del turismo sostenible y refuerza la posición de Galápagos como líder en sostenibilidad.

1.5.4 Factor Tecnológico

Embarcación. La tecnología náutica ha avanzado gracias a décadas de investigación “integrando ingeniería avanzada con las necesidades modernas de los navegantes esto incluye sistemas de gestión de energía inteligentes, ofreciendo una navegación más conectada, eficiente y ecológica” (Crowline Spain, s.f.).

- **Eficiencia y Sostenibilidad**

Propulsión. Innovaciones como motores diesel-eléctricos, híbridos, totalmente eléctricos y celdas de combustible están reemplazando al diesel tradicional, reduciendo emisiones y contaminación acústica.

- **Tecnología de Navegación y Seguridad**

Los sistemas de navegación avanzados inteligente integran datos meteorológicos en tiempo real para rutas óptimas, mejorando la seguridad y eficiencia de la embarcación, por otra parte, la seguridad avanzada incluye sistemas de alarma de hombre al agua, extinción de incendios, y monitoreo a través de aplicaciones móviles y finalmente los sistemas de monitoreo avanzado previenen fallos, mientras que tecnologías como AIS y EPIRB mejoran la prevención de accidentes (Crowline Spain, s.f.)

- **Conectividad y Entretenimiento**

La conectividad en alta mar ha mejorado con la tecnología de satélites y Wi-Fi, permitiendo entretenimiento y contacto con el mundo exterior. La domótica a bordo facilita el control de varios sistemas.

- **Tendencias Futuras**

La inteligencia artificial y la realidad aumentada están en el horizonte, prometiendo una navegación más segura y eficiente. Además, la investigación en energías alternativas y materiales sostenibles apunta a un futuro más verde en la navegación para esto la recopilación de datos es fundamental por lo que cada vez se dispone de más información que permite la interacción con el entorno.

- **Generación Eléctrica Eólica**

La energía eólica es la energía que se obtiene del viento, es decir, es el aprovechamiento de la energía cinética de las masas de aires y una de las innovaciones en la energía eólica que está ganando tracción es la creación de micro-redes: sistemas locales de generación y almacenamiento de energía que pueden operar independientemente o en conjunto con la red principal. Estas micro redes permiten una gestión más eficiente de la energía almacenada, distribuyéndola según las necesidades específicas de una comunidad o región.

- **Innovación**

Turbinas sin aspas. Son diseños innovadores utilizan principios aerodinámicos y resonancia para capturar la energía del viento, ofreciendo ventajas como menor ruido, menos impacto en la vida silvestre y un perfil más bajo.

Inteligencia y Conectividad en Turbinas. Las modernas turbinas están equipadas con sensores y sistemas de inteligencia artificial que monitorean constantemente su rendimiento, preceden mantenimientos y adaptan su operación según las condiciones del viento en tiempo real esta conectividad e inteligencia mejoran la eficiencia y prolongan la vida útil de las instalaciones.

Solar. Según el informe Low Emissions Scenario “la capacidad solar ha crecido 27 veces durante la última década y se espera que la energía solar supere a otras energías renovables como la fuente de electricidad más grande del mundo a partir de 2035, Statkraft (s.f.).

Paneles Solares Infrarrojos. Los paneles solares tradicionales captan la luz visible, pero al cambiar los materiales por otros como el vanadio o el titanio se puede captar distintas longitudes de onda para obtener electricidad de los rayos infrarrojos siendo imperceptibles por el ojo humano. Al ampliar el espectro visible de luz se obtendría más energía solar y así los paneles solares serían más eficientes., es así que en el 2018 se publicó un proyecto relacionado con paneles solares infrarrojos y gestados en el Lawrence Berkeley National Laboratory.

Granjas Solares Flotantes. Las granjas solares se han convertido en una fuente interesante de captación de energía solar a gran escala para ello es necesario una porción de terreno abundante normalmente en zonas desérticas o donde no se puede ni construir ni cultivar. Hay granjas solares en todo el mundo estas destacan por su tamaño como el parque solar de Bhadla, en India, con capacidad para 2.245 MW que ocupa casi 57 kilómetros cuadrados, el parque solar de Huanghe Hydropower, en China, con capacidad para 2.200 MW o el parque solar de Benban, en Egipto, con una capacidad de 1.650 MW.

Sistema Eléctrico Galápagos. El sistema eléctrico de las Galápagos se compone de cuatro centrales de generación térmica, dos sistemas eólicos y cinco plantas fotovoltaicas. Las centrales térmicas de ELECGALAPAGOS S.A., actualmente, abastecen el 85% de las necesidades energéticas de la población de las Islas, mientras que el 15% es cubierto por fuentes renovables desde el 2022 el sistema cuenta con centrales de generación y cobertura eléctrica. Galápagos Science (s.f.).

- **Almacenamiento de Energía**

Baterías de Ion-Litio y más Allá. Al hablar de almacenamiento de energía moderno, las baterías de ion-litio suelen ser las protagonistas. Estas baterías, populares en dispositivos móviles y vehículos eléctricos están encontrando su lugar en el almacenamiento de energía eólica su

capacidad para almacenar grandes cantidades de energía en un espacio relativamente pequeño las hace ideales. Sin embargo, distintas investigaciones en baterías de estado sólido, baterías de flujo y otras tecnologías prometen mayores capacidades y eficiencias en el futuro.

Más allá de las baterías, existen soluciones diseñadas específicamente para el almacenamiento a gran escala, un ejemplo es el almacenamiento por bombeo hidráulico, donde la energía excedente se utiliza para bombear agua a un depósito elevado y cuando es necesario, esta se libera para mover turbinas y generar electricidad. Otras soluciones incluyen “el almacenamiento térmico y sistemas de aire comprimido, que prometen integrarse perfectamente con la infraestructura eólica o fotovoltaica existente.” Estudiar Energías Renovables Online (s.f.).

El avance tecnológico en la navegación ha permitido integrar sistemas inteligentes de gestión de energía, propulsión sostenible y conectividad avanzada, lo que no solo optimiza la eficiencia operativa y la seguridad en embarcaciones como el catamarán solar "INER 1", sino que también respalda el uso de energías renovables en las Islas Galápagos. Al incorporar innovaciones en propulsión eléctrica, sistemas de monitoreo y tecnologías de generación y almacenamiento de energía se promueve un futuro más ecológico y sostenible para la región alineado con los objetivos globales de conservación y eficiencia energética.

1.5.12 Factor Ecológico

Los gases de efecto invernadero (GEI) y contaminantes primarios (PP) en varios sectores, incluyendo fuentes fijas y móviles de energía, residuos, entre otros, muestran que las fuentes móviles de energía, como el transporte aéreo, terrestre y marítimo, son los principales contribuyentes de emisiones. El transporte marítimo representa el 41% de las emisiones totales de CO₂ siendo los contaminantes más predominantes los óxidos de nitrógeno (NO_x) y el

monóxido de carbono (CO). El transporte aéreo contribuye con el 36% y la generación de electricidad con el 15%.

Existe dependencia de las islas en los combustibles fósiles especialmente para transporte y electricidad, y se proponen alternativas para reducir estas emisiones. El inventario espacial de emisiones se destaca como una herramienta valiosa para la toma de decisiones que promuevan la sostenibilidad a largo plazo del archipiélago. Galápagos Science (s.f.).

El turismo en las Islas Galápagos tiene un impacto significativo en su delicado ecosistema a pesar de ser una fuente importante de ingresos para la región la afluencia masiva de turistas puede afectar negativamente la biodiversidad única del archipiélago. Las principales preocupaciones incluyen la presión sobre los recursos naturales, la introducción de especies invasoras y el riesgo de contaminación.

En 2022, más de 267,688 turistas visitaron las islas, lo que generó impactos ambientales notables. Entre estos, la sobrecarga en las infraestructuras y servicios básicos, como el manejo de residuos y la provisión de agua dulce, son destacables. Además, el turismo masivo ha llevado a un aumento de las emisiones de gases de efecto invernadero, especialmente del transporte marítimo y aéreo, que juntos representan la mayor parte de las emisiones de CO₂ en el archipiélago.

Para mitigar estos efectos, las autoridades ecuatorianas han implementado medidas como la promoción del turismo sostenible y el incremento de la tasa de ingreso al Parque Nacional Galápagos. A partir de julio de 2024, la tasa para turistas extranjeros ha aumentado de 100 a 200 dólares, con el objetivo de limitar la cantidad de visitantes y financiar mejoras en la gestión de los recursos y la infraestructura.

El impacto ambiental del transporte marítimo y aéreo en las Islas Galápagos es significativo representando una gran parte de las emisiones de CO₂ y otros contaminantes, lo que amenaza la biodiversidad única del archipiélago. Frente a estos desafíos, la implementación de alternativas sostenibles y el uso de tecnologías limpias, como las que impulsa el catamarán solar "INER 1", son fundamentales para reducir las emisiones y preservar el delicado equilibrio ecológico de las islas, asegurando su sostenibilidad a largo plazo.

1.5.13 Factor Legal

La Convención sobre la Conservación de la Especies Migratorias de Animales Silvestres CEM fue adoptada en 1979 y entró en vigor en 1983 fue un resultado del Plan de Acción aprobado en la Conferencia de Estocolmo sobre el medio humano de 1972 que recomendó la adopción de convenios internacionales orientados a la protección de especies migratorias. Conforme quedó anotado, en Ecuador el tratado entró en vigor en el año 2004 el Ministerio del Ambiente actúa como punto focal nacional del tratado.

La Constitución del Ecuador (2008) establece en el Artículo 3, numeral 7, la protección del patrimonio natural y cultural del país. Además, el Artículo 400 señala que el Estado ejercerá la soberanía sobre la biodiversidad y su conservación se declara de interés público, mientras que el Artículo 73 prohíbe actividades que puedan causar la extinción de especies y la alteración de ciclos naturales.

La Ley Orgánica de Régimen Especial para la Conservación y Desarrollo Sustentable de la Provincia de Galápagos (2016) regula el régimen especial de la provincia, definiendo el régimen jurídico-administrativo aplicable a diversas entidades y personas, en estricto apego a los principios de conservación. El Ecuador, mediante la Convención sobre la Conservación de

Especies Migratorias y su legislación, subraya su compromiso con la biodiversidad y la sostenibilidad.

En este marco, el proyecto de desarrollar un modelo predictivo de machine learning para optimizar el consumo energético del catamarán solar "INER 1" es crucial, este modelo no solo mejora la eficiencia operativa del catamarán, sino que también apoya la reducción de la dependencia de combustibles fósiles y promueve el uso de energías renovables, en línea con las leyes y objetivos de conservación del país.

1.6 Stakeholders y Áreas del Negocio Involucradas

La preservación de las Islas Galápagos y su fauna y flora endémica es crucial, lo que hace necesario reducir la contaminación generada por la industria del transporte y el turismo que utilizan embarcaciones a base de combustibles fósiles. La implementación de un catamarán solar como alternativa requiere la colaboración de diversas áreas, incluyendo proveedores de materiales, paneles solares y baterías. Además, los esfuerzos de conservación deben considerar la participación de entidades que promueven un turismo regulado, siguiendo las políticas del Plan Nacional de Gobierno, ya que el turismo es una actividad económica clave que genera empleo en múltiples sectores.

Aquellos grupos de interés y relacionados directamente con la ejecución del proyecto serán aquellos, tales como: inversores, consumidores o el propio mercado en el que se desarrollará la actividad económica, también aquellos que trabajen de manera operativa directa en la construcción de paneles solares, así como organismos reguladores del ámbito en el que se desarrolla el proyecto.

- **Operativos:** Personal experto en ingeniería y construcción, encargados de asegurar la funcionalidad del catamarán y llevar a cabo la implementación de energía solar. Se

incluye la participación de personal con conocimiento legal y asesores internos o externos en temas contables, fiscales y aduaneros.

- **Inversores y accionistas:** Aquellos que invertirán su capital y recursos para la ejecución misma del proyecto y serán partícipes en las decisiones.
- **Organismos reguladores, supervisiones y ministerios:** Entes reguladores que gozan de personalidad jurídica de derecho público interno como marco regulador para controlar aspectos jurídicos y técnicos.
- **Proveedores de servicios:** Todos aquellos interventores comerciales y proveedores de materiales y servicios implicados en la construcción y adecuación.

La ejecución del proyecto requiere una colaboración estrecha con inversores que proporcionarán el capital necesario, así como con proveedores de materiales y servicios especializados en tecnología solar y construcción naval. El personal operativo, incluyendo ingenieros y técnicos, será crucial para la implementación efectiva del sistema de energía solar en el catamarán. Además, es vital la participación de organismos reguladores y ministerios, quienes supervisarán el cumplimiento de las normativas ambientales y técnicas.

1.7 Fuentes de Información

Los datos para el proyecto, al igual que la actividad principal en las Islas Galápagos, se generan en el contexto del transporte marítimo y el consumo de energía necesarios para el traslado de un gran número de pasajeros nacionales y extranjeros entre las islas. Según el Informe anual de visitantes del 2023 del Ministerio de Ambiente, Agua y Transición Ecológica, 179 mil turistas extranjeros y 151 mil turistas nacionales visitaron las Islas Galápagos, con un promedio mensual de 27.6 mil visitantes.

1.8 Estructura de Datos

Los datos utilizados son estructurados y se presentan en tablas que registran los eventos de manera cronológica, vinculados entre sí mediante la fecha y hora de su registro.

1.9 Fuentes de Datos Primarias

- **Elementos Climáticos**

Los datos climáticos son proporcionados por el Instituto de Investigación Geológico y Energético de Ecuador (IIGE) y datos obtenidos de base de NASA, entidad dedicada al estudio de la geología y la energía para este estudio, se utilizará información capturada mediante sistemas de monitoreo a los siguientes elementos climáticos:

- Radiación - Irradiación normal directa hacia abajo de onda corta en toda la superficie del cielo.
- Temperatura en grados centígrados (máxima, mínima y promedio).
- Porcentaje de humedad (máxima, mínima y promedio).
- Precipitación.
- Velocidad del viento.
- Dirección del viento.

- **Suministro Eléctrico del Punto de Recarga**

El suministro eléctrico que abastece a la embarcación INER 1 es administrado por ELECGALÁPAGOS este sistema está compuesto por una estación eólica en Baltra, una estación fotovoltaica en Puerto Ayora y una central eléctrica en Santa Cruz. La información disponible incluye:

- Estación de Generación.
- Generación en kilovatios por fecha y hora.

- **Operación de la Embarcación INER 1**

La embarcación INER 1 genera información sobre su autonomía y trayecto, la cual se registra con fecha y hora. Estos datos incluyen:

- Energía utilizada.
- Capacidad (pasajeros y tripulación).
- Datos del sistema.
- Potencia fotovoltaica.
- Datos de voltaje de generación, máximos y mínimos de carga.
- Capacidad de almacenamiento de batería.
- Datos de carga, recarga, temperatura, voltaje, entre otros.
- Consumo en kilovatios por hora.

1.10 Fuentes de Datos Secundarias

- **Datos del Clima Obtenidos desde base Datos NASA**

Programa NASA POWER Data Access Viewer - <https://power.larc.nasa.gov/data-access-viewer/>

- **Material de Documental**

- Informe Anual de Visitantes 2023 - Parque Nacional Galápagos (Ministerio del Ambiente, Agua y Transición Ecológica, 2024)
- Informe Anual de Visitantes 2022 - Parque Nacional Galápagos (Ministerio del Ambiente, Agua y Transición Ecológica, 2023)
- Información de consulta del INAMHI: Instituto Nacional de Meteorología e Hidrología - (Instituto Nacional de Meteorología e Hidrología [INAMHI], n.d.)

- Tesis - Marcelo, M. (09 de septiembre de 2019). Análisis del comportamiento de las variables ambientales y energéticas que inciden en la operación del catamarán solar "INER 1" en las Islas Galápagos mediante selección de atributos.

1.11 Tratamiento de Datos

La información deberá ser analizada y procesada para corregir datos atípicos, faltantes o errores en su captura.

Capítulo 2

2.1 Marco Teórico

2.1.1 Aprendizaje Supervisado

El IBM (2022), señala que el aprendizaje supervisado, o machine learning supervisado, es una rama del machine learning y la inteligencia artificial se caracteriza por el uso de datos etiquetados para entrenar algoritmos los cuales se encargan de clasificar la información o predecir resultados con exactitud. Además, emplea un conjunto de entrenamiento para instruir a los modelos a generar el resultado deseado.

Este conjunto de datos incluye tanto las entradas como las salidas correctas, lo que permite al modelo aprender y mejorar con el tiempo, mientras que el algoritmo evalúa su precisión mediante una función de pérdida, ajustando sus parámetros hasta reducir el error a un nivel aceptable. Por lo que hay dos tipos principales de problemas al analizar datos: la clasificación y la regresión.

- **Clasificación:** Utiliza un algoritmo para asignar datos a categorías específicas de manera precisa, identifica entidades dentro del conjunto de datos y busca determinar cómo deben etiquetarse o definirse esas entidades. Algunos algoritmos comunes para clasificación son los clasificadores lineales, las máquinas de vectores de soporte (SVM), los árboles de decisión, vecinos más cercanos y random forest.
- **Regresión:** Se enfoca en entender la relación entre variables dependientes e independientes y se usa principalmente para realizar proyecciones, como estimar los ingresos por ventas de una empresa. Entre los algoritmos de regresión más conocidos se encuentran la regresión lineal, la regresión logística y la regresión polinómica.

2.1.2 Definición de Machine Learning

El Machine Learning o aprendizaje automático conocido como una rama de la inteligencia artificial, se refiere a una disciplina científica que desarrolla sistemas capaces de adaptarse mediante la experiencia, Dueñas (2020) menciona que estos sistemas pueden identificar y corregir errores sin necesidad de estar explícitamente programados para ello. El objetivo es que las máquinas adquieran la capacidad de aprender, pensar y resolver problemas de manera similar a como lo hacen los humanos “los algoritmos de aprendizaje automático se clasifican en supervisados y no supervisados”, Alba (et al., 2020).

2.1.3 Modelos de Machine Learning

Modelo ARIMA (Series temporales).

Según George Pelcam, en su informe acerca de series temporales, define el modelo ARIMA como la compilación de técnicas estadísticas y econométricas que permiten describir un valor como una función lineal de datos anteriores y errores debidos al azar, además, puede incluir un componente cíclico o estacional, Pelcam (2010).

La metodología de Box y Jenkins se estructura en cuatro fases clave. En la primera fase, se identifica un modelo ARIMA apropiado para la serie temporal, lo que implica decidir sobre las transformaciones iniciales necesarias para preparar los datos. Esta preparación permite convertir la serie observada en una serie que cumpla con las condiciones de estacionariedad, después de lo cual se determinan los órdenes p y q al analizar la estructura autorregresiva y de media móvil de los datos.

La segunda etapa implica la selección de un modelo preliminar para la serie temporal estacionaria, seguido de la estimación de los parámetros autorregresivos (AR) y de medias móviles (MA) mediante el método de máxima verosimilitud. En este proceso, se calculan los errores estándar y los residuos del modelo. La elección final del modelo se sustenta en un

análisis detallado de los parámetros predefinidos, lo cual asegura una validación precisa del ajuste del modelo seleccionado.

En la tercera fase, se lleva a cabo un análisis diagnóstico para confirmar que los residuos del modelo no presentan patrones estructurales y se comportan como un ruido blanco. Si se encuentra alguna dependencia en los residuos, se ajusta el modelo y se repiten los pasos previos. La cuarta y última fase se enfoca en la predicción, donde se aplica el modelo ARIMA (p, d, q). Este modelo está determinado por los parámetros que indican el orden del componente autorregresivo, el número de diferenciaciones y el orden de la media móvil Pelcam (2010).

Condiciones de uso ARIMA

Datos no estacionales: ARIMA es ideal para series temporales que no exhiben un patrón estacional. Es decir, cuando no hay variaciones regulares o ciclos que se repiten en intervalos fijos (como estaciones del año o meses del año).

Datos con tendencia o estacionalidad a largo plazo: Aunque ARIMA no maneja estacionalidad, puede ser utilizado para datos con una tendencia o patrón de crecimiento a largo plazo al ajustar los componentes de tendencia y diferenciación. Aplicaciones comunes con el pronóstico de datos económicos, financieros, y otros tipos de datos donde las fluctuaciones no siguen un patrón estacional fijo.

Requerimientos: Los datos deben ser estacionarios o transformados para ser estacionarios. Esto significa que sus propiedades estadísticas, como la media y la varianza, deben ser constantes a lo largo del tiempo.

Modelo SARIMA con variable exógena

El modelo SARIMA es una extensión del ARIMA que incorpora términos estacionales para captar patrones estacionales en los datos. Este modelo se caracteriza por seis parámetros: p , d , q , P , D y Q , que definen el orden de los componentes estacionales y no estacionales, Chinlli (2021).

Los modelos SARIMA proponen la identificación tanto dependencias a corto como a largo plazo en los datos de manera que posibilita el predecir series temporales estacionales, por ejemplo, ventas mensuales, PIB trimestral o temperaturas anuales. Un modelo SARIMA es aplicado en condiciones en que el análisis de los datos presenta un patrón estacional distintivo con una tendencia creciente a lo largo del tiempo.

En un modelo ARIMA estacional o SARIMA, los términos ARAR y MAMA estacionales predicen utilizando valores de datos y errores en momentos con rezagos que son múltiplos de SS (el intervalo de la estacionalidad).

$SARIMA(p,d,q) \times (P,D,Q)_s$

Con parámetros:

- p =orden AR no estacional,
- d =orden de diferencias no estacional,
- q =orden MA no estacional,
- P =orden AR estacional,
- D =orden de diferencia estacional,
- Q =orden MA estacional y
- S =ventana de tiempo del patrón estacional.

Condiciones de uso SARIMA

El modelo SARIMA es apropiado para series temporales que exhiben un patrón estacional claro, donde los datos muestran regularidades en ciclos a intervalos específicos, como el aumento de ventas en diciembre cada año. SARIMA amplía el modelo ARIMA al incluir términos estacionales, permitiendo así la modelización de componentes tanto estacionales como no estacionales.

Al igual que ARIMA, los datos deben ser transformados para ser estacionarios antes de aplicar SARIMA. Además, es fundamental considerar la estacionalidad mediante los parámetros estacionales P, D, Q y S. La elección de SARIMA se justifica cuando un modelo ARIMA no logra capturar adecuadamente la complejidad de la serie temporal, lo que requiere una especificación más detallada.

Este modelo es ideal para pronosticar datos con componentes estacionales marcados, como ventas estacionales, demanda de productos en diferentes épocas del año, temperaturas anuales o datos de pasajeros de aerolíneas. Es importante tener en cuenta el escalamiento de los datos tanto durante el entrenamiento del modelo como en las predicciones.

2.1.4 Red Neuronal Artificial

Las redes neuronales artificiales son “modelos computacionales inspirados en el funcionamiento del cerebro humano. Su capacidad para aprender patrones complejos a partir de datos las hace especialmente útiles para tareas de predicción en entornos con múltiples variables interrelacionadas”, Haykin (2009).


Las principales ventajas de las redes neuronales explicadas por Zhang (1998) es su habilidad para capturar relaciones no lineales entre variables de entrada y salida, lo que las hace

particularmente adecuadas para modelar fenómenos complejos como el consumo energético en sistemas de transporte.

Las redes neuronales pueden “adaptarse a cambios en los patrones subyacentes de los datos a lo largo del tiempo, lo que es crucial en entornos dinámicos como los sistemas de transporte eléctrico, donde las condiciones operativas y ambientales pueden variar significativamente” Kaastra, I., & Boyd, M. (1996).

Ilustración 1

Arquitectura básica de una red neuronal (Haykin 1998)



Nota. Arquitectura básica de una red neuronal partiendo de la neurona la entrada está compuesta de un vector de tamaño. Reproducido de researchgate, por Haykin, 1998

(https://www.researchgate.net/figure/Figura-1-Arquitectura-basica-de-una-red-neuronal-Haykin-1998-Partiendo-de-la-neurona_fig1_314151933)

2.1.5 Tipos de Redes Neuronales

Es importante que dentro de los tipos de redes neuronales se puede identificar la red que mejor que adapte mejor al modelo predictivo del consumo de energía del catamarán solar INER1, dentro de los cuales se detallan a continuación:

Redes Neuronales Feed-Forward (FNN). Es el tipo más básico de red artificial, en estas redes la información “se mueve en una sola dirección, hacia adelante desde los nodos de entrada a través de los nodos ocultos (si los hay) y hasta los nodos de salida. No hay ciclos ni bucles en la red”, Haykin (2009, p. 21).

Redes Neuronales Convolucionales (CNN). Las CNN se encuentran diseñadas con el objetivo de “procesar datos que vienen en forma de múltiples matrices, por ejemplo, una imagen en color compuesta por tres matrices 2D que contienen intensidades de pixel en los tres canales de color”, LeCun et al. (2015, p. 439). Son redes efectivas en tareas de visión por computadora.

Redes Neuronales Profundas (DNN). Son redes artificiales que tienen “múltiples capas ocultas entre las capas de entrada y salida. Las arquitecturas profundas permiten que las redes neuronales aprendan representaciones jerárquicas de los datos con múltiples niveles de abstracción”, Goodfellow et al. (2016, p. 5)

Redes Neuronal Artificial Recurrente (RNN). Son una clase de redes donde “las conexiones entre nodos forman un grafo dirigido a lo largo de una secuencia temporal. Esto permite que exhiban un comportamiento temporal dinámico”, Graves (2012, p. 19). A diferencia de las Feedforward, estas son capaces de usar su estado interno (memoria) para poder procesar las secuencias de entradas.

Cañadas (2021) explica que las neuronas recurrentes tienen la capacidad no solo de enviar información hacia adelante en una red neuronal, sino también de retroalimentarse. Esto significa que, en cada paso del procesamiento, una neurona recurrente recibe tanto los datos provenientes de las neuronas anteriores como la información que ella misma procesó en el paso anterior. Este mecanismo permite que la red capture dependencias temporales y secuenciales en

los datos. Las redes LSTM son una variante avanzada de las redes neuronales recurrentes (RNN), conocidas por su habilidad para aprender dependencias a largo plazo en datos secuenciales.

Hochreiter y Schmidhuber (1997) señalan que las redes LSTM han demostrado ser altamente eficaces y se han aplicado a una amplia gama de problemas debido a su capacidad para resolver el desvanecimiento del gradiente, un desafío común en las redes neuronales recurrentes tradicionales. Este fenómeno ocurre cuando los gradientes disminuyen significativamente durante el proceso de entrenamiento, lo que dificulta el aprendizaje del modelo, como explica Cantuña (2024). Las LSTM están específicamente diseñadas para abordar este problema, permitiendo un entrenamiento más eficiente y eficaz, especialmente en modelos complejos.

En la predicción del consumo energético del catamarán INER1, las redes LSTM son esenciales por su capacidad para manejar secuencias temporales. Hochreiter y Schmidhuber (1997) resaltan su efectividad en la captura de patrones a largo plazo, lo cual es clave al considerar factores como la radiación solar y el número de turistas. Además, las LSTM pueden procesar eficientemente múltiples variables de entrada, lo que las hace ideales para integrar diversos factores operativos del catamarán, como también sugieren Greff et al. (2017).

2.1.6 Funciones de Activación

La red neuronal tiene los vectores de entrada denominados X y los vectores de salida denominados Y , inicialmente con la asignación de pesos como una pre activación dentro de la red donde se multiplicarán los pesos de los datos que ingresan, mediante el cual se requiere funciones principales de activación “las funciones se encargan de filtrar los datos de todas las entradas para que lleguen a la capa interna de la red, pues simulando al funcionamiento del cerebro” Cantuña (2024)

Función Sigmoide. La función sigmoide transforma los valores de entrada en un rango entre 0 y 1. "La función sigmoide fue históricamente popular porque tiene una interpretación agradable como la tasa de activación de una neurona", Goodfellow et al (2016). Sin embargo, tiene limitaciones en redes profundas debido al problema de desvanecimiento del gradiente. Se usa más frecuentemente en redes multicapa como Backpropagation.

Función Tangente Hiperbólica (TANH). Similar a la sigmoide, pero con un rango de -1 a 1. Aggarwal (2018) señala que la función tanh a menudo funciona mejor que la sigmoide para redes multicapa, ya que produce salidas centradas en cero, lo que hace que la siguiente capa aprenda más fácilmente.

Función Rectificadora Lineal Unitaria (RELU). La función ReLU es ampliamente utilizada en redes neuronales artificiales porque convierte los valores negativos en cero, preservando solo los positivos, lo que optimiza la eficiencia de la red. Glorot (2011) destaca que esta característica permite que la red se enfoque en los valores relevantes para su aprendizaje. Además, LeCun et al. (2015) señalan que ReLU mejora notablemente la convergencia durante el descenso de gradiente estocástico en comparación con funciones como la sigmoide y tanh, haciendo el entrenamiento más rápido y eficiente. En resumen, ReLU es una herramienta clave por su simplicidad y capacidad para acelerar el aprendizaje.


Softmax. Utilizada principalmente en la capa de salida para problemas de clasificación multiclase, "La función softmax asegura que las salidas sean positivas y sumen uno, lo que permite interpretarlas como probabilidades" (Bishop, 2006).

2.1.7 Número de Capas

Las redes neuronales constan de 3 capas principales, las capas de entrada que son los datos que ingresaran dentro de la red sin ningún tipo de procedimiento previo, las capas ocultas que contienen información no observable pero su función principal es que se aprenda patrones y relaciones difíciles de los datos. Y por último las capas de salida que reciben la información procesada para transmitirlo al exterior.

Ilustración 2

Red neuronal profunda con tres capas ocultas



Nota. Red neuronal profunda con tres capas ocultas. Reproducido de ¿Qué es una red neuronal?, por Codificando Bits, 2024 (<https://www.codificandobits.com/blog/que-es-una-red-neuronal/>)

Según Heaton (2008) sugiere que el número de neuronas en la capa oculta debería estar entre el tamaño de la capa de entrada y el tamaño de la capa de salida, preferiblemente el promedio de los dos. Por otro lado, Karsoliya (2012) sugiere que el número de neuronas en la capa oculta debería ser $\frac{2}{3}$ del tamaño de la capa de entrada más el tamaño de la capa de salida.

2.1.8 Gradiente Desciende

El gradiente descendiente es un algoritmo de optimización utilizado para minimizar una función de costo en redes neuronales "El gradiente descendiente es un algoritmo de optimización

de primer orden que minimiza la función objetivo tomando pesos proporcionales al negativo del gradiente (o del gradiente aproximado) de la función en el punto actual.", Goodfellow (2016). El objetivo es encontrar los pesos de la red que minimizan esta función.


2.1.9 Red Neuronal Híbrida Autoencoder-LSTM

Para lograr predicciones precisas del consumo energético del catamarán, los modelos híbridos de predicción de consumo integran de manera eficaz métodos tradicionales con enfoques basados en inteligencia artificial Hong (2009). Además, cabe mencionar que en los siguientes últimos años se ha demostrado que la combinación de técnicas de descomposición de modelos junto con técnicas de inteligencia artificial puede optimizar la eficiencia de los modelos de previsión de carga energética Moon (2018). Por lo tanto, la adopción de un modelo híbrido resulta ser la opción más recomendable para este tipo de análisis.

Para generar predicciones energéticas para el catamarán INER1, se implementará una red neuronal híbrida con el fin de mejorar los resultados obtenidos. Según International Journal for Research (2022), un autoencoder es un tipo particular de red neuronal en el que la entrada y la salida son idénticas. Este tipo de red comprime la información de entrada y luego la reconstruye a partir de una representación que se divide en tres partes: codificador, código y decodificador. Según Jyoti Prakash Mohanty (2022) el codificador comprime la entrada para crear el código, mientras que el decodificador utiliza este código para reconstruir la salida.

Ilustración 3

Arquitectura del autoencoder



Nota. Estructura base de Autoencoder. Reproducido de aprendizaje aplicado profundo, por Arden Dertat, 2017 (<https://towardsdatascience.com/applied-deep-learning-part-3-autoencoders-1c083af4d798>)

El decodificador utiliza únicamente el código para reconstruir la entrada. Para desarrollar un autoencoder, es necesario contar con una estrategia de codificación, una estrategia de decodificación y una función de pérdida que compare la salida con el objetivo. Según Jyoti Prakash Mohanty (2022) menciona que los autoencoders son usados principalmente para reducir la dimensionalidad y se distinguen de otros métodos comunes de compresión de datos, como gzip, al aprender las características específicas de los datos de entrenamiento.

En combinación con la red de memoria a largo y corto plazo (LSTM), se define su estructura, lo que permite que las puertas LSTM cumplan su función clave. Jyoti Prakash Mohanty (2022) comenta también que las puertas regulan la influencia selectiva de la

información utilizando funciones de activación como la sigmoide en una red neuronal completamente conectada. Esta configuración produce un valor entre 0 y 1: cuando la salida sigmoide es 1, la puerta se abre y se permite el paso de información, mientras que, si la salida es 0, la puerta se cierra y la información no se transmite.

El autoencoder se entrena para comprimir los datos de entrada, como la radiación solar, la temperatura y la velocidad del viento, en una representación de menor dimensión, permitiendo luego reconstruir los datos en su forma original, eliminando el ruido o información irrelevante. Por su parte, la red LSTM, una red recurrente especialmente útil para series temporales aprende cómo evolucionan las variables de entrada a lo largo del tiempo, lo que le permite capturar de manera más precisa los patrones estacionales a largo plazo de nuestro conjunto de variables, finalmente predice la energía de la variable objetivo energía.

2.1.10 Programación Python

El lenguaje de programación de Python es uno de los más utilizado a nivel mundial y cuenta con un sin número de bibliotecas especializadas para el aprendizaje automático centrándose especialmente en la red neuronal que ayudan a la ejecución de los diferentes modelos que se implementaran en la predicción del consumo de energía. No solo se contará con herramientas para el análisis, procesamiento, entrenamiento si no que se podrá realizar visualizaciones de datos.

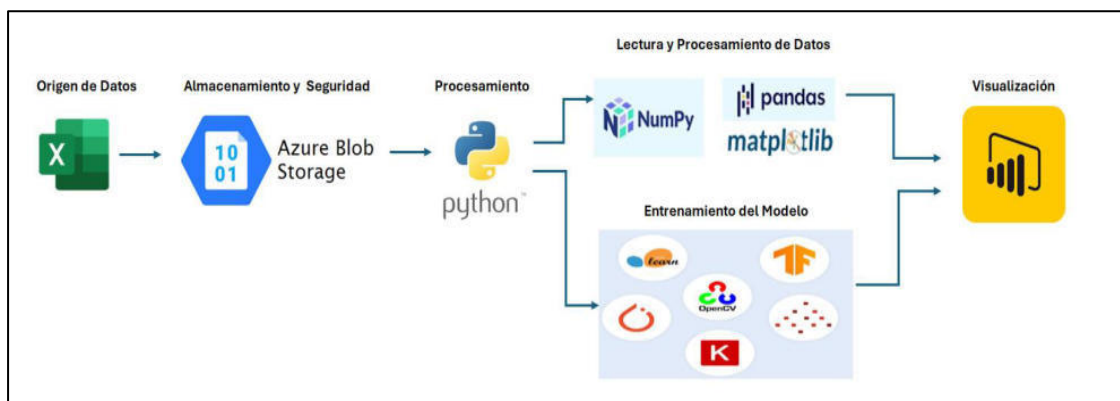
2.2 Arquitectura del Modelo

El flujo de datos comienza con la recolección y almacenamiento de datos en archivos csv de Excel, que contienen información sobre radiación solar, temperatura ambiental y parámetros

relacionados con la energía del catamarán "INER 1" estos archivos CSV son leídos y procesados utilizando bibliotecas de Python como pandas y NumPy. Luego, los datos procesados se emplean para entrenar un modelo de machine learning utilizando herramientas como TensorFlow, PyTorch y scikit-learn. Una vez entrenado, el modelo predictivo se evalúa con distintos escenarios de comportamiento de la embarcación tanto los resultados como los datos del modelo se almacenan de manera segura y escalable en Azure. Finalmente, los resultados y datos se visualizan y analizan a través de Power BI, lo que facilita la toma de decisiones y optimiza el consumo energético del catamarán.

Ilustración 4

Arquitectura del modelo



Nota. Imagen de la arquitectura del modelo.

2.2.1 Ecosistema de Datos

Para el presente proyecto se ha escogido Azure por la integración que tiene con el ecosistema de Microsoft, por lo tanto, se tiene las siguientes premisas:

- **Base inicial periodo 2022 -2023:** 17,520 registros
- **Crecimiento mensual:** 500 registros
- **Tamaño estimado por registro:** 1 MB

- **Costo de almacenamiento por GB:** \$0.0184
- **Base de datos:** Azure SQL Database S0 (10 DTUs) - \$15 por mes
- **Máquina Virtual:** VM B1s - \$8.64 por mes
- **Redes:** 50 GB de transferencia de datos - \$4.35 por mes
- **Incremento mensual de almacenamiento:** $500 \text{ registros} * 1 \text{ MB} = 500 \text{ MB} = 0.5 \text{ GB}$
- **Costo de almacenamiento mensual por GB:** \$0.0184

El cálculo del almacenamiento acumulado y su costo mensual se hace considerando el crecimiento mensual.

- **(Base de Datos Anual) Azure SQL Database (S0: 10 DTUs):** \$15 por mes * 12 meses = \$180
- **Almacenamiento anual:** \$22.86
- **VM B1s anual (720 horas al mes):** \$8.64 por mes * 12 meses = \$103.68
- **Ancho de Banda anual (50 GB transferidos):** \$4.35 por mes * 12 meses = \$52.20

Por lo tanto, el costo total anual para manejar los 15,000 registros iniciales con un crecimiento mensual de 500 registros sería aproximadamente \$358.74.

2.3 Métricas de Valor

Las métricas de valor ofrecen indicadores fundamentales para analizar la rentabilidad y viabilidad económica de un proyecto. Estas métricas son cruciales para inversores y otras partes interesadas, ya que facilitan la toma de decisiones informadas respecto a la efectividad y el retorno de la inversión Koller et al., (2020).

Tabla 1*Métricas de energía, ambiente y turismo*

Indicador	Definición	Valor	Fórmula	Unidad
Margen Neto	Rentabilidad de la empresa después de deducción de gastos	36%	$\frac{Utilidad\ Neta}{Ingresos}$	Puntos porcentuales
Margen Operativo	Rentabilidad de la empresa antes de deducción de gastos	56%	$\frac{Utilidad\ Operacional}{Ingresos}$	Puntos porcentuales
VAN	Determina el valor adicional	\$394,557	$Desembolso\ Inicial + Flujo\ de\ efectivo$	USD
TIR	Rentabilidad de una inversión comparada con el costo capital	16.76%	$\frac{Flujo\ de\ efectivo}{Inversión\ inicial}^{\frac{1}{\# de periodos}} - 1$	Puntos porcentuales
Payback	Medida de liquidez y tiempo en que una inversión genera retorno	61 Meses	$Payback\ Descontado = A + (ED)$	Mes

Nota. Cálculos financieros sobre la rentabilidad de la inversión en el proyecto.

2.3.1 Margen Operativo

El proyecto obtuvo un margen operativo promedio del 56% a lo largo de los 10 años, lo que indica una alta eficiencia en la gestión de los gastos operativos. Esto significa que después de cubrir los costos operativos, el proyecto retiene más de la mitad de sus ingresos como ganancias antes de deducir intereses e impuestos, reflejando una buena capacidad de generar beneficios operativos.

2.3.2 Margen Neto

El proyecto logró un margen neto promedio del 36% durante los 10 años, lo cual es un resultado favorable. Este porcentaje indica que después de deducir todos los gastos, incluyendo impuestos, el proyecto retiene un poco más de un tercio de sus ingresos como utilidad neta, lo que es un indicador positivo de rentabilidad global.

2.3.3 VAN

El valor actual neto del proyecto a lo largo de los 10 años es de USD 394,557 lo que significa que el proyecto genera valor adicional al superar el costo de la inversión inicial. Un VAN positivo como este confirma que la inversión es rentable y que el proyecto contribuye a incrementar el valor para los inversionistas.

2.3.4 TIR

La tasa interna de retorno obtenida es del 16.76%, lo que es aceptable dado el contexto del proyecto. Esta tasa representa la rentabilidad esperada de la inversión, y aunque es modesta, indica que el proyecto supera el costo de capital, justificando su viabilidad financiera.

2.3.5 Payback

El proyecto alcanza su punto de equilibrio financiero al mes 61, lo que significa que a partir de ese momento la inversión inicial está completamente recuperada y los flujos de caja posteriores se traducen en ganancias netas. Este periodo de recuperación es razonable y sugiere que el proyecto es capaz de generar retornos sostenibles en el largo plazo.

Tabla 2*Métricas de energía, ambiente y turismo*

Categoría	Indicador	Unidades
Energía utilizada en la embarcación	Energía utilizada por la embarcación (red eléctrica Baltra - Santa Cruz)	kWh
	Generación Fotovoltaica de la embarcación	kWh
Radiación Global	Radiación global	kWm ² /h
Parque Fotovoltaico Santa Cruz	Parque Fotovoltaico Santa Cruz (Producción de energía)	kWh
Unidad termoeléctrica 9	Unidad termoeléctrica central de generación eléctrica de Santa Cruz (Producción de energía)	kWh
Turismo	Número de turistas	Número de personas
Condiciones ambientales	Temperatura	°C
	Humedad relativa	%
	Dirección del viento	m/s
	Precipitación	Mm

Nota. Cálculos métricos relacionados a la energía producida, las condiciones ambientales y el turismo en la zona donde se lleva a cabo el proyecto.

2.4 Metodología

Las metodologías tienen como uno de sus objetivos principales organizar de mejor manera el trabajo estructurando y estandarizando para mejorar el proyecto que se ha planteado. Por lo tanto, se expone las metodologías más acordes a la implementación necesaria.

2.4.1 CRISP-DM (Cross-Industry Standard Process for Data Mining)

La metodología CRISP-DM es un “conjunto de tareas jerarquizadas que están organizadas en cuatro niveles de abstracción: fases, tareas generales, tareas especializadas e instancias de proceso”, Corona (2020).

- **Comprensión del negocio (business understanding):** Comprende los objetivos del negocio y los requisitos del proyecto.
- **Comprensión de los Datos (Data Understanding):** Realiza una exploración inicial de los datos disponibles.
- **Preparación de los datos (data preparation):** Limpieza, transformación y selección de datos para el modelado.
- **Modelado (modeling):** Construye modelos utilizando técnicas de minería de datos.
- **Evaluación (evaluation):** Evalúa el rendimiento del modelo y su idoneidad para los objetivos del negocio.
- **Despliegue (deployment):** Implementa el modelo en el entorno de producción.

Ilustración 5

Fases de la metodología CRISP-DM



Nota. Fases de la metodología CRISP-DM. Reproducido de Principales Metodologías en el desarrollo de Proyectos de Minería de Datos, por Edgar Corona, 2020
(<https://www.datavaluemanagement.es/metodologia/>)

En conclusión, la metodología que se adapta mejor al desarrollo del modelo predictivo del catamarán solar INER 1 es CRISP-DM ya que posee un enfoque del negocio y da a conocer y entender las operaciones del catamarán y los objetivos sostenibles. Aparte que permite volver a las fases anteriores por su proceso cíclico según sea requerido y pone un énfasis en la comunicación a largo plazo en especial cuando se trabaja con proyectos como el IIGE o ELECGALÁPAGOS S.A.

2.5 Análisis EDA

Tabla 3*Estructura de datos*

Campo	Tipo de Campo
Fecha	datetime64
Radiación (MWh/m ²)	float64
Temperature C	float64
Relative Humidity %	float64
Precipitation Water mm	float64
Wind Speed (Velocidad del viento) m/s	float64
Wind Direction (Direccion del Viento) (deg)	float64
Termica MWh (unidad 9)	float64
Fotovoltaica MWh	float64
Turistas	Int
Energia Mwh	float64

Nota. Estructura de datos extraídos a partir del análisis EDA

El conjunto de datos presenta 17,520 registros y 17 variables. La mayoría de las variables son numéricas (float64) lo que indica medidas cuantitativas y otra de formato entero. Sin embargo, hay una variable en formato fecha (datetime64). La mayoría de las variables en este conjunto de datos son numéricas, lo que indica que se están midiendo cantidades.

2.5.1 Valores Faltantes

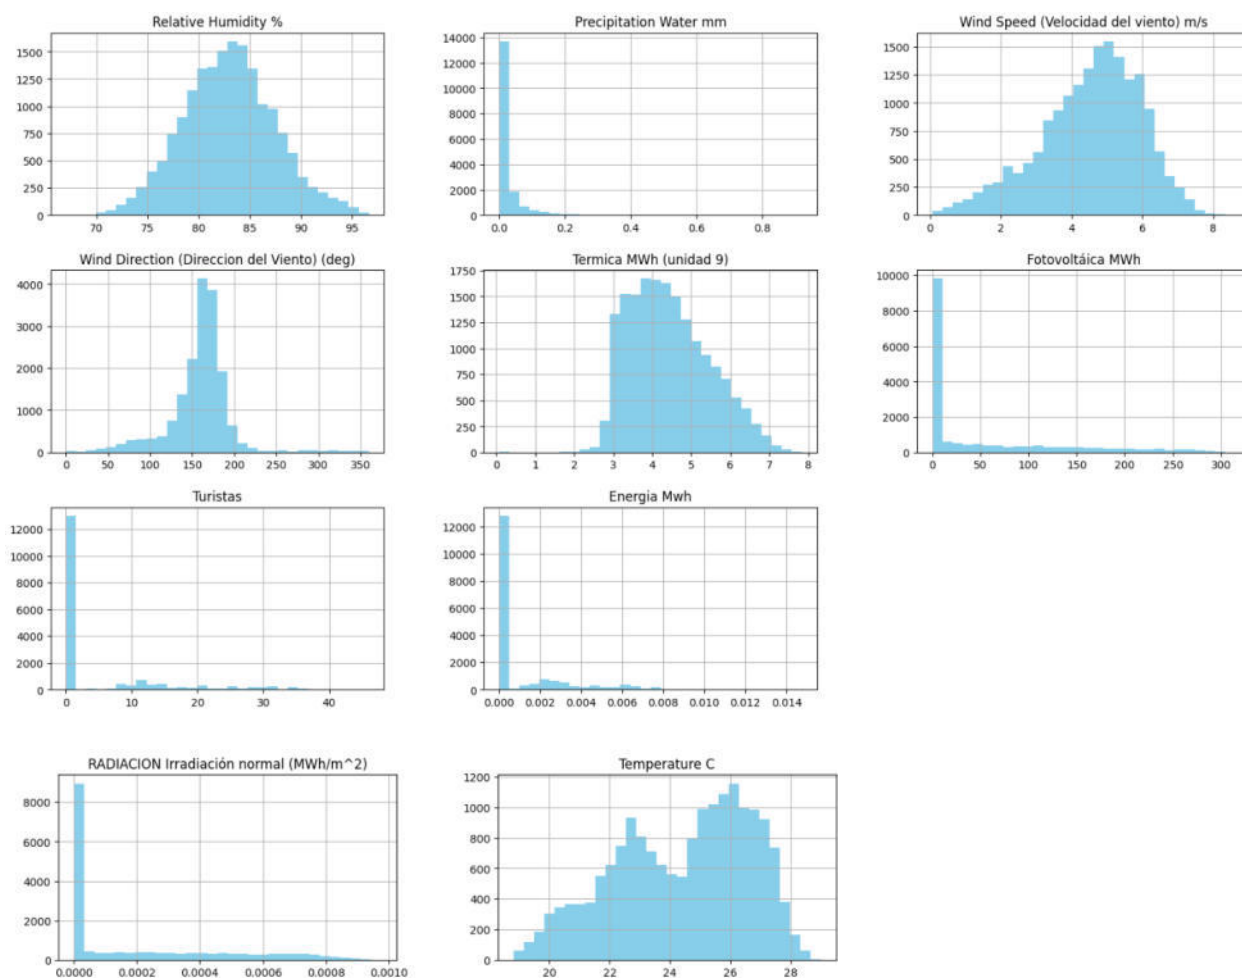
El análisis de los valores atípicos en el conjunto de datos revela que las variables temporales como Semana, Mes, Año y Hora no presentan valores atípicos, lo que indica una consistencia temporal en la recolección de los datos. Esto sugiere que no hay desviaciones significativas en la periodicidad de los registros.

Por otro lado, variables climáticas como RADIACION Irradiación normal, Temperature C, Relative Humidity %, Precipitation Water mm y Wind Direction muestran una mayor presencia de valores atípicos. En particular, Temperature C y Relative Humidity % presentan un porcentaje de valores atípicos superior al 10%, lo que sugiere fluctuaciones notables en las condiciones climáticas. Esto podría estar relacionado con fenómenos meteorológicos o eventos inusuales en el periodo estudiado.

El alto porcentaje de valores atípicos en la variable Energia Mwh (23.63%) indica una considerable variabilidad en el consumo o generación de energía, lo cual puede reflejar cambios en la demanda, fluctuaciones en la generación de energía renovable o variaciones en la operación de la infraestructura energética. Las variables relacionadas con la generación de energía, como Termica MWh y Fotovoltáica MWh, también muestran un porcentaje moderado de valores atípicos, lo que podría deberse a variaciones en la producción energética o a eventos operacionales.

Ilustración 6

Histogramas de las variables representativas



Nota. Estructura de datos extraídos a partir del análisis EDA

- **Humedad Relativa:** La humedad relativa tiene una distribución normal, concentrada entre el 80% y 85%, lo que indica estabilidad en la región, beneficiando el rendimiento de los sistemas fotovoltaicos y eólicos.
- **Precipitación:** La precipitación es escasa, con una distribución sesgada hacia la derecha y la mayoría de los valores cercanos a cero. Esto sugiere un clima seco con lluvias esporádicas, favoreciendo la generación de energía solar.

- **Velocidad del Viento:** La velocidad del viento es moderada, con un pico en 5-6 m/s, proporcionando condiciones favorables para una generación eólica constante.
- **Dirección del Viento:** La dirección del viento está concentrada entre 150 y 200 grados, lo que ayuda a optimizar la orientación de las turbinas eólicas.
- **Generación Térmica:** La generación térmica tiene una distribución sesgada a la derecha, con la mayoría de los valores entre 2 y 5 MWh, siendo una fuente complementaria a las energías renovables en momentos de alta demanda.
- **Generación Fotovoltaica:** La generación fotovoltaica presenta una distribución muy sesgada hacia la derecha, con la mayoría de los datos por debajo de 50 MWh, lo que refleja una producción solar irregular debido a variaciones en la radiación solar.
- **Afluencia de Turistas:** La afluencia de turistas es muy variable, con la mayoría de los datos cercanos a cero y algunos picos elevados, lo que afecta la demanda energética según la estacionalidad.
- **Radiación Solar:** La radiación solar es baja en su mayoría, con algunos picos en días más soleados, lo que debe considerarse en el diseño de sistemas fotovoltaicos.
- **Temperatura:** La temperatura tiene una distribución bimodal con picos en 22°C y 26°C, sugiriendo dos patrones climáticos distintos que pueden afectar la eficiencia de los sistemas de generación energética.
- **Energía Total:** La energía total muestra una distribución sesgada a la derecha, con picos ocasionales y una demanda energética variable, lo que requiere estrategias para optimizar el uso de fuentes renovables y térmicas.

2.5.2 Medidas Descriptivas

Ilustración 7

Medidas descriptivas

	Fecha	RADIACION Irradiación normal (MWh/m ²)	Temperature C	Relative Humidity %	Precipitation Water mm	Wind Speed (Velocidad del viento) m/s	Wind Direction (Dirección del Viento) (deg)	Termica MWh (unidad 9)	Fotovoltaica\nMWh	Turistas	Energia MWh
0	2022-01-01	0	21,83	86,56	0	5,6	201,95	3,464	0	0	0,00001
1	2022-01-01	0	21,74	86,94	0	5,42	204,87	3,387	0	0	0,00001
2	2022-01-01	0	21,65	87,56	0	5,03	204,3	3,263	0	0	0,00001
3	2022-01-01	0	21,58	88	0	4,75	202,52	3,156	0	0	0,00019
4	2022-01-01	0	21,56	88,31	0	4,61	200,34	3,058	0	0	0,00001
...
17515	2023-12-31	0	25,69	85,38	0,03	5,06	153,67	7,356	29,636	0	0,0001
17516	2023-12-31	0	25,62	85,94	0,02	5,05	155,42	6,828	4,676	0	0,0001
17517	2023-12-31	0	25,53	86,44	0,02	5,06	156,24	6,184	0	0	0,0001

Nota. Medidas descriptivas de los datos históricos 2022 - 2023

El análisis de los datos climáticos y energéticos revela una alta variabilidad en los parámetros evaluados. La irradiación solar, con una media de 0,000205 MWh/m² y un máximo de 0,000975 MWh/m², presenta un considerable potencial fotovoltaico, pero su variabilidad con el 50% de los registros en valores bajos de 0,000000 MWh/m² subraya la necesidad de almacenamiento o fuentes complementarias para garantizar estabilidad.

La temperatura media es de 24,40°C, con una desviación de 2,235°C y un rango de 18,81 °C a 28,9 °C, condiciones favorables para sistemas fotovoltaicos y eólicos. La humedad relativa, con un promedio de 82,98 %, aunque alta, es estable, facilitando la previsibilidad operativa. La baja precipitación media de 2.79 mm y un máximo de 92 mm favorece la eficiencia de los paneles solares al reducir la nubosidad, mientras que la velocidad del viento, con un promedio de 4,53 m/s y dirección constante, respalda la energía eólica.


En cuanto a la generación, la energía térmica es esencial como respaldo, con una media de 4,44 MWh y picos de 7,83 MWh. La energía fotovoltaica, aunque alcanza hasta 314,548

MWh, es altamente variable, lo que hace necesario un sistema híbrido. La afluencia turística exige flexibilidad en el sistema energético para adaptarse a las variaciones en la demanda.

2.5.3 Matrices de Correlación

Ilustración 8

Matrices de correlación



Nota. Cuadro de correlación con relación a todas las variables existentes en la base.

Existe una correlación extremadamente alta entre el número de turistas y el consumo total de energía. Esto indica que el número de visitantes es el principal impulsor del consumo energético. Un aumento en la afluencia turística genera una mayor demanda de energía, no solo en el catamarán sino también en los servicios asociados, como climatización, transporte y otros servicios turísticos.

La radiación solar presenta una correlación positiva significativa con el consumo de energía. Esto sugiere que, en los periodos de alta irradiación solar, la producción de energía fotovoltaica aumenta, contribuyendo a cubrir una parte del consumo energético, aunque no es el factor dominante en este contexto. A pesar de ser una fuente de energía importante, la correlación moderada sugiere que la producción de energía fotovoltaica no es el principal determinante del consumo total. Esto puede deberse a que la demanda energética está más influenciada por otros factores, como el número de turistas.

Por otra parte, las variables que tienen correlaciones muy bajas y negativas, como el viento, sienten un factor poco determinante en el consumo energético, lo que puede deberse a la limitada dependencia del sistema en la energía eólica. La temperatura tiene una correlación positiva muy baja, mientras que la humedad muestra una correlación negativa. Esto puede implicar que, en condiciones más cálidas y secas, el consumo de energía tiende a aumentar ligeramente, aunque su impacto es limitado.

2.6 Validación de variables influyente

El Análisis de Componentes Principales (PCA) es una técnica estadística utilizada en investigaciones para simplificar grandes conjuntos de datos y revelar patrones y relaciones entre variables Jolliffe & Cadima (2016). El primer paso en la aplicación del PCA es normalizar los datos, ya que las variables, al ser medidas en escalas distintas, pueden sesgar los resultados según Abdi & Williams (2010). Para evitar que una variable tenga un peso desproporcionado, se realiza un proceso de estandarización que consiste en restar la media de cada valor y dividir entre la

desviación estándar. Esto asegura que las variables tengan una media de cero y una desviación estándar de uno, permitiendo una comparación justa entre ellas Shlens (2014).

Después de la normalización, se procede al cálculo de la matriz de covarianza, que mide la relación lineal entre las variables y cómo varían conjuntamente, Jolliffe (2002). Este paso es crucial para identificar las direcciones con mayor variabilidad en el conjunto de datos. En situaciones donde las variables tienen diferentes unidades, se prefiere utilizar la matriz de correlación en lugar de la matriz de covarianza, ya que esto evita que las diferencias en escalas afecten el análisis, Shlens (2014). La precisión en el cálculo de esta matriz es esencial, ya que sirve de base para los pasos siguientes del PCA, que permiten descomponer los datos en componentes más fáciles de interpretar, Jolliffe (2002).

El Análisis de Componentes Principales (PCA) descompone la matriz de covarianza o correlación en valores y vectores propios. Los valores propios muestran la cantidad de varianza explicada por cada componente, mientras que los vectores propios indican su dirección en el espacio original (Abdi & Williams, 2010). Los componentes principales, combinaciones lineales de las variables originales, no están correlacionados y capturan las dimensiones más importantes del análisis (Jolliffe & Cadima, 2016). Para seleccionar los componentes más representativos, se eligen aquellos que explican un porcentaje acumulado significativo de la varianza, como el 80%, o con un valor propio superior a uno (Shlens, 2014).

Una vez seleccionados los componentes principales, el conjunto de datos se transforma sobre ellos, lo que reduce su dimensionalidad manteniendo la mayor cantidad de información posible (Jolliffe, 2002). Los datos proyectados se visualizan mediante gráficos de dispersión, lo que permite identificar patrones y tendencias en el espacio definido por los componentes (Abdi

& Williams, 2010). En resumen, el PCA es una herramienta efectiva para reducir la complejidad de los datos, preservando información clave y facilitando su interpretación (Jolliffe & Cadima, 2016

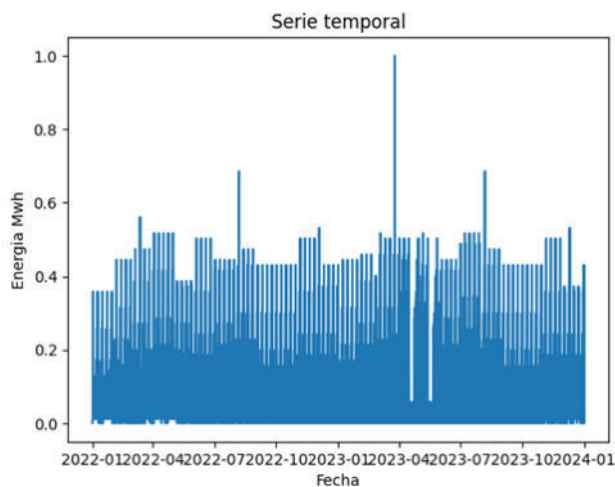
2.7 Modelación con series temporales

2.7.1 Modelo ARIMA

Para de modelos de series temporales como alternativa predictiva de la energía empleada por el catamarán “INNER 1”, se define la variable de tiempo “Fecha” como la temporalidad del modelo aplicado-declarada con formato fecha y hora. Se establece una frecuencia por hora transcurrida. Visualización de la serie temporal para la variable dependiente, el modelo ARIMA genera predicciones de una sola variable dependiente continua sin incurrir en variables complementarias, por lo tanto, se define la variable “Energía Mwh” como la variable a predecir.

Ilustración 9

Serie temporal



Nota. Grupo investigativo. (2024). Estructura de serie temporal de la variable Energía (Mwh) por fecha; generado en Python.

Test de estacionalidad: Para evaluar la estacionalidad de la variable a predecir, se utilizará la prueba estadística de Augmented Dickey-Fuller. En este contexto, se establecen dos hipótesis: la hipótesis nula (H_0) sostiene que la serie temporal no es estacionaria, mientras que la hipótesis alternativa (H_1) indica que la serie temporal sí es estacionaria. Esta prueba permitirá determinar si la serie presenta características estacionales significativas que deben considerarse en el análisis.

Tabla 4

Prueba de estacionalidad

Estadística ADF:	-18.146339
p-value:	0.0000

Nota. Valor del estadístico ADF y probabilidad asociada para probar estacionalidad.


Si el p-valor es menor que el nivel de significancia (por ejemplo, 0.05), se puede rechazar la hipótesis nula y concluir que la serie es estacionaria.

Identificación de los parámetros (p, d, q)

La selección de parámetros para ajustar el modelo ARIMA se derivan de la siguiente gráfica: Gráfico de Autocorrelación (ACF): Mide la correlación entre la serie y sus retardos (lags). Es útil para identificar q (el componente MA).

Ilustración 10

Autocorrelación de residuos




Nota. Grupo investigativo. (2024). Visualización de la correlación existente y lags en la serie de tiempo; generado en Python.

El gráfico de Autocorrelación Parcial (PACF) muestra la correlación entre la serie y sus retardos, eliminando la influencia de los lags intermedios. Es útil para identificar p (el componente AR) y ajustar el parámetro correcto al modelo elegido.

Ilustración 11

Autocorrelación parcial



Nota. Grupo investigativo. (2024). Visualización de la autocorrelación sin retardos en la serie de tiempo; generado en Python.

El modelo ARIMA necesita identificar los coeficientes y número de regresiones que se utilizarán. Este modelo es muy sensible a la precisión con que se determinen sus coeficientes.

Se suele expresar como $ARIMA(p,d,q)$ donde los parámetros p , d y q son números enteros no negativos que indican el orden de las distintas componentes del modelo respectivamente, las componentes autorregresivas, integrada y de media móvil.

p - Orden de la parte autorregresiva (AR):

El parámetro p representa el número de rezagos (lags) de la serie temporal que se utilizan para modelar la dependencia autorregresiva. De tal manera que, un valor de p indica cuántos términos autorregresivos se incluyen en el modelo. Si $p=2$, por ejemplo, el modelo incluye los rezagos de la serie temporal hasta el segundo orden. Para el presente caso de estudio usaremos un valor p de 1.

d - Orden de diferenciación

El parámetro d representa el número de veces que se diferencia la serie temporal para hacerla estacionaria. La diferenciación es una técnica para eliminar tendencias y estacionalidades. Si $d=1$, se diferencia la serie temporal una vez para obtener una serie que se espera que sea estacionaria. Un valor de $d=2$ indica que se realiza una diferenciación de segundo orden.

q - Orden de la parte de media móvil (MA)

El parámetro q representa el número de rezagos de los errores de la predicción que se utilizan en el modelo. Estos errores son las diferencias entre los valores observados y los valores predichos por el modelo. Un valor de q indica cuántos términos de media móvil se incluyen en el modelo. Si $q=1$, el modelo considera los errores hasta el primer rezago.

Ejecución del modelo

Para la estimación del modelo se definen los parámetros según las gráficas ACF y PACF, adicionalmente se entrena el modelo. Para efectos del modelo ARIMA en los datos correspondientes a variables de energía a predecir, los parámetros a usarse serán los siguientes respectivamente (p,d,q), (1,0,1)

Ilustración 12

Resultados ARIMA

```

=====
SARIMAX Results
=====
Dep. Variable:      Energia Mwh      No. Observations:      14016
Model:              ARIMA(1, 0, 1)   Log Likelihood         16130.180
Date:               Tue, 27 Aug 2024  AIC                        -32252.359
Time:               22:42:04          BIC                    -32222.168
Sample:             01-01-2022        HQIC                   -32242.309
                  - 08-07-2023
Covariance Type:    opg
=====
              coef      std err      z      P>|z|      [0.025      0.975]
-----
const         0.0730      0.005     13.789     0.000      0.063      0.083
ar.L1         0.7738      0.008     96.151     0.000      0.758      0.790
ma.L1         0.0994      0.021      4.681     0.000      0.058      0.141
sigma2        0.0059     4.33e-05    135.471     0.000      0.006      0.006
=====
Ljung-Box (L1) (Q):           0.86   Jarque-Bera (JB):       200450.68
Prob(Q):                     0.35   Prob(JB):              0.00
Heteroskedasticity (H):       1.67   Skew:                  0.94
Prob(H) (two-sided):          0.00   Kurtosis:              21.43
=====

Warnings:
[1] Covariance matrix calculated using the outer product of gradients (complex-step).

```

Nota. Grupo investigativo. (2024). Coeficientes y pruebas de validación del modelo ARIMA; generado en Python.

El error estándar del coeficiente estimado indica la precisión de la estimación, los valores más bajos sugieren estimaciones más precisas de las variables usadas. Así también, el estadístico

z también sugiere ajuste de los términos usados para la predicción según el valor de los coeficientes observados, valores menores a 0.05 indican mayor significancia.

Una prueba que sugiere la significancia estadística de los parámetros estimados es el intervalo de confianza, en el caso de la modelación presente el intervalo comprende valores entre $[0.025, 0.975]$, para los coeficientes estimados. Si este intervalo incluye el 0, el coeficiente podría no ser estadísticamente significativo. Por lo tanto, se descarta el caso en el que el coeficiente no es significativo para el modelo.

Diagnóstico del modelo

En el diagnóstico del modelo ARIMA, el coeficiente AR1 revela que el 77% del valor actual de la serie está influenciado por su valor anterior, lo que es crucial en el análisis de series temporales. Este hallazgo sugiere que la relación entre observaciones pasadas y futuras es fuerte, aunque se podría mejorar el ajuste con diferentes valores p . Por otro lado, el coeficiente MA1 indica una relación positiva, aunque moderada, entre el error de predicción anterior y el valor actual, implicando que un error positivo en el tiempo anterior afecta moderadamente la observación actual.

Para evaluar la calidad y ajuste del modelo, se utilizan diversas métricas, como el AIC (Criterio de Información de Akaike), que permite comparar modelos; un menor valor de AIC indica un mejor ajuste. También se consideran el BIC (Criterio de Información Bayesiana) y el HQIC (Criterio de Información de Hannan-Quinn), que son pruebas comparables entre diferentes modelos ARIMA con distintos valores de p , d y q . Estas métricas son esenciales para seleccionar el modelo más adecuado.

El cumplimiento de los supuestos del modelo se verifica mediante diversas pruebas. La medición de Ljung-Box Q, con un valor de 0.86 y un p-valor de 0.35, sugiere que no hay evidencia significativa de autocorrelación en los residuos, lo que indica que el modelo ha capturado adecuadamente la estructura de la serie. Sin embargo, un resultado de Jarque-Bera de 200450.68 con un bajo p-valor indica que los residuos no son normalmente distribuidos, lo que podría requerir una revisión del modelo.

Adicionalmente, un valor de 1.67 en la prueba de heterocedasticidad sugiere que los residuos son heterocedásticos, lo que implica que la varianza de los errores no es constante a lo largo de la serie. Esto podría señalar variaciones en los residuos que dependen de los niveles de la serie temporal. Para que el modelo ARIMA sea aplicable, es esencial que los residuos no estén autocorrelacionados, sean homocedásticos y sigan una distribución normal.

Dada la falta de cumplimiento de estas condiciones, los parámetros resultantes del modelo ARIMA para la predicción de energía del "ENER 1" no son representativos para su aplicación a la base de datos actual. En consecuencia, se concluye que el modelo de series temporales ARIMA no es apto para esta tarea específica.

2.7.2. Modelo SARIMAX

Ilustración 13

Resultados SARIMAX

SARIMAX Results

Dep. Variable: Energia Mwh

No. Observations: 14015

Model: SARIMAX(1, 0, 1)x(1, 0, 1, 12)

Log Likelihood 18834.311

Date: Wed, 25 Sep 2024

AIC -37656.623

Time: 19:33:49

BIC -37611.336

Sample: 01-01-2022

HQIC -37641.547

- 08-07-2023

Covariance Type: opg

	coef	std err	z	P> z	[0.025	0.975]
x1	0.1144	0.006	19.934	0.000	0.103	0.126
ar.L1	0.7647	0.006	129.890	0.000	0.753	0.776
ma.L1	0.0930	0.018	5.103	0.000	0.057	0.129
ar.S.L12	-0.9999	2.23e-05	-4.48e+04	0.000	-1.000	-1.000
ma.S.L12	0.9930	0.001	1080.634	0.000	0.991	0.995
sigma2	0.0040	2.05e-05	193.406	0.000	0.004	0.004

Ljung-Box (L1) (Q): 0.15

Jarque-Bera (JB): 224128.49

Prob(Q): 0.70

Prob(JB): 0.00

Heteroskedasticity (H): 1.54

Skew: 1.36

Prob(H) (two-sided): 0.00

Kurtosis: 22.40

Nota. Grupo investigativo. (2024). Coeficientes y pruebas de validación del modelo SARIMAX; generado en Python.

El modelo SARIMAX (1, 1, 1) x (1, 1, 1, 12) incluye términos AR (1), MA (1) y estacionales AR (1), MA (1) con una periodicidad de 12 periodos. El coeficiente AR L1 de 0.76 indica una fuerte dependencia entre el valor actual de la serie temporal y su valor pasado, sugiriendo una correlación positiva. Asimismo, el coeficiente MA L1 de 0.93 refleja que los errores de predicción anteriores influyen considerablemente en el valor actual. Estos parámetros demuestran que el modelo está bien ajustado, capturando tanto las tendencias pasadas como las correcciones basadas en errores previos.

En cuanto a los coeficientes estacionales, un AR.S. L12 de -0.99 indica una fuerte correlación inversa con el valor del mismo periodo en ciclos de 12 unidades, lo que sugiere que un valor alto en el periodo anterior tiende a estar seguido por uno bajo. Este comportamiento

refleja patrones estacionales definidos, como ciclos anuales. El MA.S. L12 de 0.99 muestra que los errores de predicción de periodos anteriores tienen una influencia casi completa en los valores actuales, resaltando la importancia de corregir errores para mejorar la precisión del modelo.

Por último, el coeficiente x_1 de 0.11 indica que un aumento unitario en la variable explicativa produce un incremento moderado en la variable de respuesta, mientras que un σ sigma de 0.0040 sugiere que el modelo ofrece predicciones precisas. Una desviación estándar baja implica que los errores de predicción son pequeños en relación con la magnitud de la variable dependiente, confirmando la confiabilidad del ajuste del modelo.

Diagnóstico del modelo

El estadístico L de Ljung-Box (L1) de 0.15 sugiere que no hay evidencia suficiente para rechazar la hipótesis nula de que los residuos de un modelo son independientes. Un valor bajo indica que, al menos a un rezago, los residuos no muestran correlación significativa, lo que es un signo positivo de que el modelo captura adecuadamente la estructura temporal de la serie. Esto sugiere que el modelo está bien especificado y que no hay patrones no capturados en los errores.

El valor de heterocedasticidad (H) de 1.74 se refiere a la variabilidad de los residuos, un valor cercano a 1 generalmente indica que no hay problemas significativos de heterocedasticidad, lo que significa que la varianza de los residuos es constante a lo largo de las observaciones. Sin embargo, un H ligeramente mayor que 1 puede señalar una leve variabilidad en la dispersión de los errores, lo que sugiere que podría ser útil revisar el modelo para asegurarse de que no se estén omitiendo variables que podrían afectar la varianza.

El estadístico de Jarque-Bera de 224128 indica una desviación considerable de la normalidad en la distribución de los residuos. Un valor tan alto sugiere que los residuos no siguen una distribución normal, lo que puede afectar la validez de las inferencias estadísticamente significativas basadas en el modelo. Esto puede ser un indicativo de que el modelo requiere ajustes, como la transformación de los datos o la incorporación de variables adicionales, para mejorar la normalidad de los errores y, por lo tanto, la robustez de las conclusiones derivadas del análisis.

2.8 Construcción de la Red- Autoencoder-LSTM

2.8.1 Preparación de datos

Una vez que el Instituto de Investigación Geológico y Energético nos facilitó la información necesaria para el desarrollo de nuestra investigación, en base a las distintas variables que influyen en el consumo de energía del catamarán INER 1 del año 2022-2023. El conjunto de datos de entrada pasa por un preprocesamiento donde se descartan los valores ausentes, redundantes, se eliminan los valores atípicos y los datos también se normalizan para lograr resultados de predicción razonables.

Después de recopilar los datos, se determinan las entradas de la red neuronal e incluyen diferentes variables que afectan el consumo de energía. Los datos se recopilarán durante dos años y cada conjunto de valores ingresados en la red neuronal multicapa se denomina época. Luego de que la neurona haya recibido el conocimiento se realizará una prueba de validación que consiste en agregar más información sobre el consumo de energía y posterior compárala con los datos que se proporcionaron.

2.8.2 Ingreso de Datos

Se inicio con la importación de librerías necesarias entre las principales NumPy, Pandas para la manipulación de datos, Matplotlib para la visualización de resultados, TensorFlow y Keras para la construcción de la red neuronal, Scikit-learn para preprocesamiento (escalado de datos), partición de datos, y cálculo de métricas.

Se repararon los datos identificando las variables características del modelo como radiación, temperatura, humedad, viento, energía térmica, fotovoltaica, turistas y la variable objetivo que es energía, posteriormente se escalan las variables utilizando StandardScaler para normalizar los datos.

Tabla 5

Descripción variables

Variable Objetivo	Variables Dependientes
Energía Mwh	RADIACION Irradiación normal (MWh/m ²)
	Temperature C
	Relative Humidity %
	Precipitation Water mm
	Wind Speed (Velocidad del viento) m/s
	Wind Direction (Direccion del Viento) (deg)
	Térmica MWh (unidad 9)
	Fotovoltaica MWh
	Turistas

Nota. Se describe las variables que se utilizan dentro de la base de datos identificando las dependientes de la variable objetivo.

Se añadió una señal estacional para capturar la periodicidad anual en los datos. Esto se realiza utilizando una función sinusoidal que se concatena con las características de entrada, se

crea las secuencias de datos donde se reorganizan en secuencias temporales utilizando ventanas deslizantes, ya que ayudan para los modelos LSTM que requieren entradas en forma de secuencias, posterior se realizó la división de los datos en conjunto de entrenamiento y conjunto de prueba utilizando `train_test_split`.

2.8.3 Creación de la Red neuronal

La arquitectura del Autoencoder LSTM fue diseñada utilizando un codificador (Encoder), que toma las secuencias de entrada de las diversas variables de los datos y las comprime en una representación reducida mediante capas LSTM, además de incluir capas como GaussianNoise, Dropout y regularización L2. El GaussianNoise añade ruido gaussiano a las entradas durante el entrenamiento, fortaleciendo el modelo al hacerlo más resistente a variaciones.

Por otro lado, Surriel (2023) menciona que Dropout es una técnica que apaga aleatoriamente algunas neuronas durante el entrenamiento para prevenir el sobreajuste, lo que permite que el modelo no se limite a memorizar los datos, sino que generalice mejor. La regularización L2, por su parte, penaliza los pesos de las neuronas para evitar que se vuelvan demasiado grandes, ayudando a controlar el sobreajuste y mejorando la capacidad del modelo para generalizar.

El resultado del codificador es una representación comprimida que captura la información clave de las secuencias originales. Esta representación es luego procesada por el decodificador (Decoder), que utiliza LSTM y capas densas para reconstruir las secuencias originales, ajustando las dimensiones hasta igualarlas.

El modelo final, un Autoencoder, aprende a comprimir y descomprimir secuencias. Se compila utilizando el optimizador RMSprop con una tasa de aprendizaje baja, y la función de pérdida utilizada es el error cuadrático medio (`mean_squared_error`). El entrenamiento incluye callbacks como `EarlyStopping`, que detiene el proceso si la pérdida no mejora tras varias épocas, y `ReduceLROnPlateau`, que disminuye la tasa de aprendizaje si la pérdida se estanca.

2.8.4 Hiperparámetros de la red neuronal

- **Número de Capas:** El modelo uso dos capas LSTM principales (una en el codificador y otra en el decodificador). A esto se le suman las capas adicionales: `GaussianNoise` y `Dropout` en el codificador para regularización y una capa densa final en el decodificador para ajustar la salida.

Entrada → LSTM (Codificador) → `GaussianNoise` → `Dropout` → LSTM (Decodificador) → Capa Densa → Salida.

- **Épocas:** Se definió que el entrenamiento se realizará durante 700 épocas lo que el modelo verá el conjunto completo de datos de entrenamiento durante el proceso de aprendizaje, se determinó ese valor, luego de realizar varios intentos (prueba-error) y determinar como el más optimo en el porcentaje de precisión del modelo.
- **Tamaño del Lote:** El `batch_size` determina cuántas muestras de los datos se procesan antes de actualizar los pesos del modelo. Se especificado 64 lo que significa que el modelo procesará los datos en lotes de 64 muestras antes de ajustar los pesos durante cada actualización de la red.
- **Callbacks:** Permitió incluir funciones que controlan el entrenamiento de forma dinámica. El `EarlyStopping` detendrá el entrenamiento si el modelo deja de mejorar, ahorrando tiempo

y recursos y el ReduceLROnPlateau reducirá la tasa de aprendizaje si la pérdida del modelo no mejora.

2.8.5 Simulaciones de escenarios factor Turistas

Las simulaciones permiten anticipar cómo los requerimientos energéticos fluctúan en función de las variaciones en el turismo, de manera que es un factor externo que impacta significativamente la operación del INER 1. Según Rodríguez & Torres comentan que, con el incremento de visitantes, es fundamental ofrecer un servicio de transporte eficiente y accesible de manera que la situación presenta retos en términos de sostenibilidad, ya que el aumento de pasajeros resulta en un mayor consumo energético, lo que sobrepasa la capacidad de generación del catamarán solar Rodríguez & Torres (2023).

A través de estas simulaciones, es posible identificar riesgos potenciales y desarrollar estrategias de mitigación. Además, se pueden establecer planes de contingencia para manejar fluctuaciones inesperadas tanto en la demanda como en la disponibilidad de energía, garantizando así una operación estable, rentable y sostenible incluso ante condiciones adversas.

En el desarrollo de las simulaciones, se tomó como base la estructura de una red neuronal LSTM que fue diseñada específicamente para modelar la predicción del consumo energético del catamarán solar. Este modelo se caracterizó por su capacidad para aprender patrones temporales complejos, lo que es fundamental dado que los datos energéticos dependen de múltiples variables meteorológicas y de comportamiento a lo largo del tiempo.

Una vez que el modelo fue entrenado y validado con los datos históricos, se guardó en un archivo utilizando el formato .h5, este paso fue crucial para facilitar su reutilización en futuras simulaciones y para evitar tener que volver a entrenar el modelo desde cero, ahorrando tiempo y

recursos computacionales. Para realizar las simulaciones de diferentes escenarios, se utilizaron nuevas bases de datos que contenían información actualizada y variada sobre la demanda turística. Estos conjuntos de datos se procesaron de manera similar a los datos originales, asegurando que las entradas fueran compatibles con la estructura del modelo.

Tabla 6

Resultados de predicción de la energía Red Neuronal

Fecha	Predicción Energía MWh Media	Predicción Energía MWh Alta	Predicción Energía MWh Baja
1/1/2024	0.041125	0.056784	0.029373
2/1/2024	0.015906	0.022199	0.010840
3/1/2024	0.017337	0.023653	0.011610
4/1/2024	0.018382	0.025216	0.012740
5/1/2024	0.020464	0.028610	0.014521
6/1/2024	0.024503	0.033807	0.016653
7/1/2024	0.035226	0.048042	0.023738
8/1/2024	0.049405	0.067237	0.033985
9/1/2024	0.013609	0.019098	0.009394
10/1/2024	0.016699	0.022827	0.011239

Nota. Resultados de energía proveniente de la red neuronal de las diferentes simulaciones

Las simulaciones se ejecutaron en estas nuevas bases para evaluar cómo variaciones en las condiciones externas, de cómo las fluctuaciones en el número de turistas podrían impactar el consumo energético. Esto permitió obtener proyecciones más realistas y adaptadas a escenarios futuros.

2.8.6 Simulaciones de escenarios factor Clima

Las condiciones climáticas son otro elemento clave que puede impactar la producción de energía solar del INER 1. La radiación solar es fundamental para el adecuado funcionamiento de

los paneles fotovoltaicos, y las fluctuaciones en la intensidad de dicha radiación pueden afectar directamente la cantidad de energía disponible para impulsar la embarcación.

Asimismo, las temperaturas extremas pueden influir en el rendimiento de los componentes eléctricos y de energía del catamarán, lo que podría resultar en un mayor consumo de energía para asegurar la comodidad a bordo, especialmente en el sistema de climatización. La variabilidad climática no solo afecta la generación de energía, sino que también impacta la operación general de la embarcación, lo que genera desafíos para el modelo predictivo, que debe ajustarse a estas condiciones fluctuantes Pérez & Gómez (2022).

La radiación solar se eligió como el principal factor climático debido a su importante impacto en el consumo energético de la embarcación, según el análisis de componentes principales (ACP). Este análisis reveló que la radiación, junto con la cantidad de turistas, explica el 26.2% y 13.1% de la variabilidad en el sistema, siendo un elemento clave para predecir el comportamiento energético.

Otras variables climáticas, como la temperatura y la humedad, fueron descartadas porque, de acuerdo con las conclusiones de la tesis de origen, no influyen en el consumo de energía, gracias a los sistemas de ventilación pasivos de la embarcación. Asimismo, variables como el viento y la marea tampoco mostraron una relación poco significativa con el consumo energético, lo que justifica su exclusión en el modelo.

Los incrementos del 5%, 10% y 15% en la radiación solar proyectados para las Islas Galápagos se justifican a partir de análisis sobre el impacto del cambio climático en los patrones climáticos locales. Un aumento del 5% se considera un cambio moderado, reflejando proyecciones

que indican variaciones leves en la radiación a causa de cambios climáticos menores (Trenberth, 2011).

Por otro lado, el incremento del 10% se presenta como un escenario más realista que toma en cuenta la intensificación del ciclo hidrológico y la probabilidad de eventos climáticos extremos, que pueden aumentar la radiación solar al reducir la nubosidad (Pfenninger & Staffell, 2016). En cuanto al aumento del 15%, este se proyecta bajo condiciones severas, donde se anticipa una disminución significativa de la cobertura nubosa y un incremento en las temperaturas superficiales del océano, lo que a su vez podría impactar de forma considerable la disponibilidad de radiación solar para la generación de energía (Mastrorillo et al., 2016).

2.9 Desarrollo Business Case: Operación de Catamaranes Solares con Energía Solar

2.9.1. Introducción

Este estudio evalúa la viabilidad de operar catamaranes eléctricos en 2024, mediante la proyección del consumo y la generación de energía para ese año. El análisis considera diversos escenarios, tomando en cuenta el impacto de la cantidad de turistas y la demanda energética. Además, se contempla el uso de la red eléctrica como complemento a la producción de energía solar en caso de ser necesario

2.9.2 Análisis de la Demanda de Energía y Operación de Catamaranes Energía Solar y Red Eléctrica

El análisis muestra cómo la energía solar y la red eléctrica cubren las necesidades energéticas del catamarán, donde se detallan los resultados a continuación:

Tabla 7*Resultados energía solar, red eléctrica y energía total*

Año	Energía Solar (kWh/año)	Energía Eléctrica (kWh/año)	Red Energía (kWh/año)
2022	6,227.41	2,867.44	9,094.85
2023	6,483.38	2,985.30	9,468.68
2024	7,955.40	3,663.10	11,618.49

Nota. Resultados del modelo

En 2024, se proyecta que el sistema solar genere 7,955.40 kWh, mientras que 3,663.10 kWh provendrán de la red eléctrica, cubriendo un total de 11,618.49 kWh anuales, equivalente a un consumo promedio de 31.83 kWh diarios.

Actualmente, la flota consta de 7 catamaranes (6 a diésel y 1 eléctrico). A partir de los datos recolectados de este último, se ha calculado la cantidad de energía requerida en caso de que todas las embarcaciones migraran a ser eléctricas, sería de 81.319,5 kWh anuales. Considerando que la capacidad de generación proveniente de fuentes solares asciende al 69% (55.687,5 kWh), la demanda en la red eléctrica sería del 31% (25.641,7 kWh) representando un 0.33% de la capacidad total de generación de la isla de Santa Cruz- Baltra.

2.9.3 Simulaciones de Escenarios de Demanda de Energía para 2024

Se han modelado tres escenarios en los que la cantidad de visitantes determina la demanda de energía, lo que tiene un impacto directo en el uso de la red eléctrica. La capacidad de generación propia se determina por el factor planta que afecta la cantidad de energía solar generada se detalla a continuación.

Tabla 8*Factor Planta*

Años	Capacida d Solar (kWp)	Factor Planta (fp)	Horas operativas (h)	Capacidad Teórica (kWh/año)	Energía Fotovoltaic a	Factor Planta óptimo 18% - 22%
2022	4,2	1	8760	36792	6,227.41	16,93%
2023	4,2	1	8760	36792	6,463.51	17,57%
2024 base	4,2	1	8760	36792	7,955.4	21,62%
2024 baja 23%	4,2	1	8760	36792	9,246.2	25,13%
2024 medina 46%	4,2	1	8760	36792	10,720.41	29,14%
2024 alta -15%	4,2	1	8760	36792	5,390.58	14,65%

Nota. Cálculos realizados

El factor de planta es una medida de eficiencia que indica el porcentaje de energía que un sistema de generación (como los paneles solares) produce en relación con su capacidad teórica máxima. En el caso de los paneles solares del catamarán, con una capacidad de 4.2 kWp, el factor de planta depende de las horas de sol, las condiciones climáticas y la eficiencia del sistema. Aunque teóricamente podrían generar hasta 36,792 kWh al año, en la realidad, solo producen una fracción de esa cantidad debido a estas limitaciones.

En 2023, el factor de planta fue del 18%, lo que significa que los paneles generaron 6,463.51 kWh de los 36,792 kWh posibles. Para 2024, en condiciones ideales, se espera un factor de planta del 22%, alcanzando una producción de 7,955.4 kWh al año, que es prácticamente el máximo realista para el sistema actual.

En los escenarios simulados para 2024, donde aumenta la demanda de energía debido al incremento en la cantidad de turistas y, por lo tanto, en el número de viajes del catamarán, el sistema solar no puede abastecer toda la demanda. A pesar de operar en condiciones óptimas con un factor de planta del 22%, el tope de generación es limitado. Por lo tanto, cualquier energía adicional requerida debe ser cubierta por la red eléctrica.

En el escenario de demanda alta (con un aumento del 46%), el factor de planta proyectado llega a un 29%, lo que excede las capacidades del sistema actual. Esto implica que, aunque la demanda energética aumente significativamente, el sistema solar no puede satisfacerla debido a las limitaciones físicas de generación. Como resultado, se debe depender aún más de la red eléctrica para cubrir la diferencia.

En resumen, el factor de planta juega un papel crucial en determinar cuánta energía puede generar el sistema solar, y en los escenarios proyectados para 2024, muestra que el sistema alcanza su límite máximo de producción solar, necesitando complementarse con energía de la red eléctrica para satisfacer el incremento en la demanda. A continuación, se muestran los escenarios reales de la cantidad de energía solar y eléctrica que se requiere:

Tabla 9

Resultados de simulaciones escenarios

Escenario 2024	EnergíaSolar (kWh/año)	EnergíaRed Eléctrica (kWh/año)	Total Energía (kWh /año)
Demanda Base 2024	7,955.40	3,663.10	11,618.49
Demanda Media 23% turistas	7,955.40	5,548.25	13,503.65
Demanda Alta 46% turistas	7,955.40	7,701.27	15,656.673
Demanda Baja (-15%) turistas	5,390.58	2,482.12	7,872.70

Nota. Cálculos realizados

- En este escenario base, el factor de planta se estima en un 22%. Esto significa que la capacidad solar del sistema está casi al máximo rendimiento posible con 7,955.40 kWh generados de los paneles solares. Sin embargo, esta generación es insuficiente para cubrir toda la demanda energética, por lo que el 31% de la energía debe ser suplida por la red eléctrica (3,663.10 kWh).
- Con un aumento del 23% en el número de turistas, el consumo energético incrementa, pero la energía solar se mantiene constante en 7,955.40 kWh debido al límite de generación impuesto por el factor de planta. Esto significa que, aunque la demanda aumenta, el sistema solar ya está operando al máximo de su capacidad, por lo que se incrementa la dependencia de la red eléctrica, que debe suplir 5,548.25 kWh, lo cual representa un aumento significativo del 52% en la energía eléctrica requerida en comparación con el escenario base.
- En este escenario, la demanda energética sigue aumentando en función del mayor número de turistas. Nuevamente, la energía solar permanece en 7,955.40 kWh debido al límite del factor de planta. La red eléctrica cubre ahora casi la mitad de la demanda total, aportando 7,701.27 kWh. Esto evidencia la insuficiencia de la energía solar para cubrir la demanda creciente, lo que resulta en una dependencia crítica de la red eléctrica, alcanzando un 49% de la energía total consumida.
- En este escenario de menor demanda, la producción solar disminuye a 5,390.58 kWh debido a una reducción proporcional en el uso de los catamaranes. Aunque la energía solar disminuye, sigue cubriendo una mayor proporción del total energético. La

dependencia de la red eléctrica se reduce a 2,482.12 kWh, lo que alivia la presión sobre la red y refleja un escenario más manejable desde el punto de vista energético.

2.9.4. Capacidad de Operación de Catamaranes Eléctricos

La capacidad de operación de los catamaranes dependerá de la disponibilidad de energía solar y eléctrica:

Tabla 10

Resultados energía solar, red eléctrica, energía total de 7 catamaranes

Escenario de Demanda 2024	Energía Solar (kWh/año)	Energía Red Eléctrica (kWh/año)	Total Energía (kWh/año)	Energía eléctrica 7 catamaranes (kWh/año)
Demanda Base 2024	7,955.40	3,663.10	11,618.49	25,641.7
Demanda Media 23%	7,955.40	5,548.25	13,503.65	38,837.8
Demanda Alta 46%	7,955.40	7,701.27	15,656.67	53,908.9
Demanda Baja (-15%)	5,390.58	2,482.12	7,872.70	17,374.8

Nota. Cálculos realizados

- Este escenario base refleja que, para operar un catamarán, se requiere 11,618.49 kWh/año. Para cubrir las necesidades de los 7 catamaranes, se necesitarán 25,641.7 kWh/año de la red eléctrica, además de la energía solar generada por los paneles solares para cada embarcación.
- Este escenario media muestra que para operar un catamarán se requieren 13,503.65 kWh/año. Para cubrir las necesidades de los 7 catamaranes, se necesitarán 38,837.8 kWh/año de la red eléctrica, además de la energía solar generada.

- En este escenario alto, se requiere un total de 15.656,67 kWh/año para operar un catamarán, para los 7 catamaranes, se necesitarán 53,908.9 kWh/año de la red eléctrica, además de la energía solar generada.
- En este escenario bajo, se requiere un total de 7,872.70 kWh/año para operar un catamarán. La energía solar representa 5,390.58 kWh, y 2,482.12.27 kWh deben ser obtenidos de la red eléctrica. Para cubrir las necesidades de los 7 catamaranes, se necesitarán 17,374.8 kWh/año de la red eléctrica, además de la energía solar generada.

2.9.5. Impacto Financiero

La tabla muestra cómo varían los costos energéticos anuales para la operación de un catamarán y de 7 catamaranes en función de diferentes escenarios de demanda en 2024. Estos costos están basados en un precio de \$0.09 por kWh de energía de la red eléctrica.

Tabla 11

Costo de energía

Escenario 2024	Costo Energía un catamarán anual kWh / USD	Costo Energía 7 catamaranes anual kWh/USD
Demanda Base 2024	\$420,58	\$2,944.0
Demanda Media 23%	\$517,31	\$3,621.2
Demanda Alta 46%	\$614,04	\$4,298.3
Demanda Baja (-15%)	\$ 357,49	\$2,502.4

Nota. Cálculos realizados

- Demanda Base: En este escenario base, los costos energéticos para operar un solo catamarán son relativamente bajos, destacando la eficiencia y el equilibrio entre la energía

solar y la de la red eléctrica. Esto sugiere que, bajo condiciones de demanda estándar, la operación de los catamaranes es económicamente viable.

- **Demanda Media:** Con un aumento del 23% en turistas, los costos se incrementan considerablemente. Esto refleja una mayor demanda de energía debido a un mayor uso de los catamaranes, lo que hace más evidente la necesidad de gestionar el consumo energético de forma eficiente para evitar que los costos aumenten de manera desproporcionada.
- **Demanda Alta:** En este escenario de alta demanda con 46%, los costos se disparan significativamente, resalta cómo el incremento en el uso de los catamaranes puede poner presión sobre los costos operativos, indicando que se necesitarían estrategias para mejorar la eficiencia energética, como una mayor inversión en paneles solares de mayor capacidad, para mantener el control de los gastos.
- **Demanda Baja:** Con una disminución del 15% en la demanda de turistas, se observa una caída en los costos. Esto demuestra cómo una menor demanda reduce significativamente los gastos energéticos, lo que podría ofrecer una operación más rentable en períodos de menor actividad, o si la demanda no crece tanto como se anticipa.

2.9.6. Almacenamiento

La capacidad actual de almacenamiento es de 11.5 kWh. Se detalla el ahorro en energía:

Tabla 12

Resultados costo, ahorro y proyección

Año	Costo kWh anual (\$)	Costo kWh anual Energía - no almacenada (\$)	Porcentaje de Ahorro en Energía	Costo de Proyección en 5 años
Escenario base 2024	\$420,58	\$76	18%	381
Escenario 7 Catamaranes	\$2.944	\$533	18%	2.664

Nota. Cálculos realizados

La capacidad de 11.5 kWh permite acumular el excedente de energía solar generada, lo que es crucial para asegurar un suministro energético constante y eficiente durante períodos de baja generación solar o alta demanda. El sistema de almacenamiento ayuda a reducir el consumo de energía no almacenada en un 18%, lo que se traduce en un ahorro significativo en los costos operativos.

Esto es relevante en la dependencia de la red eléctrica, ya que minimiza la necesidad de recurrir a la energía más costosa de la red. Adicional los costos proyectados para el escenario base y para dos catamaranes indican un aumento en la carga financiera, pero el ahorro en energía almacenada compensa parte de este costo adicional. Sin embargo, la reducción en el costo de la energía no almacenada resalta la importancia del almacenamiento como un factor clave en la gestión económica de la operación.

2.9.7. Control operativo - Oportunidades de Carga

Se realiza un análisis de costos para carga vespertina y nocturna según la tabla de continuación mostrando el costo y el porcentaje.

Tabla 13

Resultados costo energía vespertina y nocturna

Año	Costo kWh anual Carga Vespertina (USD)	Costo kWh anual Carga Nocturna (USD)	Porcentaje de Ahorro en Energía
Escenario base 2024	\$ 421	\$ 384	9,44%
Escenario 2 Catamaranes	\$ 2.944	\$ 2.690	9,44%

Nota. Cálculos realizados

Las oportunidades de carga vespertina y nocturna presentan ahorros del 9,44%, lo que puede contribuir significativamente a la reducción de costos operativos, la diferenciación entre costos de carga vespertina y nocturna permite gestionar mejor los momentos de mayor demanda y optimizar el uso de la energía.

2.9.8. Análisis Comparativo del Consumo Energético de Catamaranes Eléctricos en Relación con la Capacidad de Generación de la Isla Santa Cruz

La tabla de generación de la red en la Isla Santa Cruz muestra las fuentes de energía actuales y su capacidad de generación anual estimada en (MWh). A continuación, se presenta un análisis de esta capacidad en comparación con el consumo energético proyectado de los 7 catamaranes eléctricos bajo diferentes escenarios de demanda.

Tabla 14

Capacidad total de generación de la isla

Fuente de Energía	Potencia Instalada (MW)	Disponibilidad Factor de Planta	Energía Estimada Disponibile (Mwh/año)
Eólica Baltra	2,25	0,00%	0
Fotovoltaica Baltra	0,067	18,7%	109,75
Fotovoltaica Puerto Ayora	1,5	12,0%	1,576.80
Generación Térmica	11,5	22,8%	22,968.72
Total	-	-	24,655.27

Nota. Generación de energía total de la Isla. Reproducido de Ecuador Central Solar, por PVmagazine, 2014(<https://www.pv-magazine-latam.com/2014/12/23/ecuador-correa-inaugura-central-solar-de-1-5-mw-en-galapagos/>)

La capacidad total estimada de generación energética de la isla es de 24,655.27 MWh al año, lo que equivale a 24,655,274 kWh. Según el plan de transición Energética de las islas Galápagos muestra la demanda del consumo de la isla de santa Cruz-Baltra en el 2022:

Tabla 15

Demanda máxima

Año	Demanda máxima kWh/año	Capacidad máxima red kWh	Déficit de energía en kWh
2022	39,690,000	24,655,274.04	15,034,725.96

Nota. Generación de energía total de la Isla. Reproducido del Plan de transición Energética de las islas Galápagos, por Gobierno de Ecuador, 2022 (<https://www.recursosyenergia.gob.ec/wp-content/uploads/2023/11/BID-GALAPAGOS-PUBLICACION-v7-fotos-comprimido.pdf>)

Podemos apreciar que existe déficit energético entre la demanda máxima de energía en 2022 (39,690,000 kWh) y la capacidad máxima de la red (24,655,274 kWh), con un saldo negativo que alcanza cifras que varían en torno a 15,034,725.96 kWh. Esto refleja que, incluso con el consumo de los catamaranes eléctricos, la red enfrenta un déficit considerable en su capacidad de generación.

Tabla 16*Consumo energético con relación a las islas*

Escenario 2024	Energía 7 catamaran es anual kWh	Capacidad de Generación Total red Isla Baltra (kWh)	% consumo energético en relación con la capacidad total Isla
Demanda Base 2024	25.641,7	24.655.274,04	0,33%
Demanda Media 23%	38.837,8	24.655.274,04	0,38%
Demanda Alta 46%	53.908,9	24.655.274,04	0,44%
Demanda Baja (-15%)	17.374,8	24.655.274,04	0,22%

Nota. Cálculos realizados

El consumo proyectado de los catamaranes en todos los escenarios se mantiene por debajo de la capacidad total de generación de la isla, sugiriendo que, aunque el uso de catamaranes eléctricos es sostenible, la red actual no es suficiente para satisfacer la demanda total. La demanda máxima en 2022 supera considerablemente la capacidad de generación disponible, lo que plantea preocupaciones sobre la sostenibilidad del sistema energético actual y su capacidad para soportar un aumento en el uso de vehículos eléctricos.

2.9.9. Comparación de rentabilidad entre Catamarán y Lancha

Tabla 17*Comparación de rentabilidad entre Catamarán y Lancha*

INGRESOS	CATAMARAN	LANCHA	Var USD	Var %
Precio por pasaje	2	2		
Capacidad promedio por viaje	40	18		
Número de viajes anuales	1584	1584		
TOTAL INGRESOS	126.720	57.024	69.696	122%
EGRESOS				
Permisos y Certificados	3.349	550		

Seguro	9.194	3.500		
Sueldos	36.000	15.000		
Mantenimiento	15.000	7.500		
Costo electricidad (red eléctrica)	420			
Costo combustible		6.912		
Servicios básicos	3.710	1.250		
TOTAL EGRESOS	67.673	34.712	32.961	95%
Impuestos		5.214		
UTILIDAD NETA	59.047	17.098	41.949	245%
MARGEN DE CONTRIBUCIÓN	59.047	22.312	36.735	165%
% MARGEN DE CONTRIBUCIÓN	47%	39%		7%

Nota. Cálculos realizados

En el análisis comparativo de los estados de resultados entre el catamarán y la lancha, se observa una clara diferencia en los ingresos y egresos. El catamarán, con una capacidad de 40 pasajeros por viaje, genera \$126,720, lo que representa un aumento del 122% respecto a los \$57,024 obtenidos por la lancha, que transporta 18 pasajeros. Esta diferencia en los ingresos se debe a la mayor capacidad de transporte del catamarán, ya que el precio por pasaje y el número de viajes anuales (1584) son idénticos en ambas embarcaciones. Este resultado refleja una mejor utilización de recursos en el catamarán.

En cuanto a los egresos, el catamarán presenta un total de \$67,674, un 95% más que los \$34,712 de la lancha. Los sueldos y los costos de mantenimiento son factores clave en esta diferencia, con \$36,000 y \$15,000 en el catamarán, frente a \$15,000 y \$7,500 en la lancha, respectivamente. Sin embargo, el catamarán tiene un ahorro significativo en energía, gastando solo \$420 gracias al uso de energía renovable, mientras que la lancha gasta \$6,912 en combustible.

Además, la lancha enfrenta \$5,214 en impuestos, de los que el catamarán está exento por su uso de energías limpias.

En términos de rentabilidad, el catamarán presenta una utilidad neta de \$59,046, muy superior a los \$17,098 de la lancha, lo que implica una variación del 245%. Asimismo, el margen de contribución del catamarán 47% supera al de la lancha 39%, evidenciando una mayor eficiencia operativa. A pesar de que el catamarán incurre en mayores egresos, su capacidad para generar ingresos más elevados y aprovechar beneficios fiscales asociados a la sostenibilidad le otorgan una ventaja competitiva en términos financieros. Esto lo convierte en una opción más rentable a largo plazo frente a la lancha.

2.9.10. Impacto ambiental

Tabla 18

Análisis de valor unidad

Concepto	Valor	Unidad
Meses trabajados al año	12	meses
Días trabajados al mes	26	días
Combustible consumido por día	12	galones
Total de combustible consumido	3,744	galones
Emisión de CO2 por galón de diésel	10.16	kg
CO2 evitado	38,039	kg
CO2 evitado	38	toneladas

Nota. Cálculos realizados

El análisis del impacto ambiental muestra que la operación de la embarcación durante todo el año, con 26 días laborables por mes, resulta en un consumo anual de 3,744 galones de combustible. Este uso de diésel genera un total de 38,039 kg de emisiones de CO2, equivalentes a

38 toneladas anuales. Estas cifras reflejan el considerable impacto ambiental, principalmente en términos de emisiones de gases de efecto invernadero, lo que subraya la necesidad de considerar alternativas más sostenibles para mitigar la huella de carbono asociada a la embarcación.

2.9.11. Escalabilidad y Aplicación del Modelo de Catamarán Solar a Gran Escala

El modelo energético del catamarán solar "INER 1" tiene gran potencial de escalabilidad, permitiendo su adaptación a diferentes tipos de embarcaciones, como ferries, lanchas rápidas y barcos de mayor tamaño. Para expandir este modelo a mayor escala, sería necesario ajustar aspectos técnicos clave como la capacidad de las baterías, el peso de las embarcaciones y la demanda energética de cada trayecto. Este enfoque garantiza que el modelo pueda satisfacer diferentes necesidades operativas manteniendo su enfoque en la eficiencia energética y sostenibilidad.

Para operar una flota completa de embarcaciones sostenibles, es esencial construir una red de estaciones de carga que funcione con fuentes de energía renovable, como la solar y la eólica. Estas estaciones permitirían una gestión eficiente de la energía, facilitando el almacenamiento y la distribución según la demanda de cada embarcación Blunden & Arora, (2020). La integración de energía renovable es crítica para la estabilidad de la operación, especialmente en lugares insulares donde los recursos naturales como el viento pueden complementar la energía solar en momentos de baja radiación Pérez et al (2020).

Además, se deben instalar paneles solares en las estaciones de carga y optimizarlos para maximizar su eficiencia mediante sistemas de seguimiento solar, cuando sea posible Smil (2021). La generación de energía eólica a escala media también complementa esta red, garantizando un suministro energético constante durante todo el año, incluso en días nublados. Las turbinas

eólicas de mediana escala son especialmente útiles en zonas insulares, donde las condiciones del viento son más favorables Pérez et al. (2020).

Las baterías avanzadas, como las de litio-ferrofosfato (LiFePO_4), son esenciales para garantizar un suministro continuo de energía, ya que permiten ciclos intensivos de carga y descarga comenta McKinsey & Company (2021). La gestión eficiente de la energía es clave para evitar el desperdicio y mantener el equilibrio entre la oferta y la demanda de energía. Los sistemas de gestión energética (EMS), junto con la inteligencia artificial, permiten optimizar el uso de energía, anticipar fluctuaciones y maximizar la durabilidad del sistema Ahmad et al. (2021).

El financiamiento para expandir este modelo podría obtenerse a través de bonos verdes, que ofrecen una vía eficiente para captar capital destinado a proyectos de energía limpia. En Ecuador, tanto el sector público como el privado han comenzado a explorar este tipo de financiamiento para proyectos sostenibles, incluyendo la construcción de estaciones de carga para embarcaciones eléctricas BID (2020). Además, los incentivos fiscales del gobierno ecuatoriano para energías renovables, como la exoneración de impuestos, pueden reducir significativamente los costos iniciales de infraestructura según el Ministerio de Energía y Recursos Naturales no Renovables (2020).

El mercado de carbono también representa una oportunidad de ingresos adicionales mediante la venta de certificados de reducción de emisiones (CERs). Los catamaranes solares que sustituyen embarcaciones de combustibles fósiles pueden generar CERs, los cuales pueden ser comercializados en mercados internacionales. Esto no solo contribuiría a la viabilidad

económica del proyecto, sino que también apoyaría la transición hacia un transporte marítimo más sostenible y respetuoso con el medio ambiente Ministerio del Ambiente (2021).

La expansión del catamarán solar "INER 1" hacia una flota más grande ofrece una gran oportunidad para transformar el transporte marítimo. No obstante, esta escalabilidad enfrenta desafíos relacionados con la capacidad de generación de energía y la variabilidad climática, lo que requiere una infraestructura adecuada y fuentes de energía renovable. La combinación de paneles solares y turbinas eólicas, junto con sistemas de gestión energética, es fundamental para garantizar un suministro estable. Además, los incentivos fiscales y el financiamiento mediante bonos verdes son esenciales para facilitar la inversión necesaria. Por último, es vital equilibrar la demanda energética con la infraestructura disponible para asegurar la sostenibilidad a largo plazo en la región.

Capítulo 3

3.1 Resultados Análisis PCA

La varianza explicada por los dos primeros componentes principales es de aproximadamente el 26.2% y el 13.1%, respectivamente. Esto significa que el primer componente principal captura el 26.2% de la variabilidad total de los datos mientras que el segundo componente captura el 13.1%. Juntos, estos dos componentes explican aproximadamente el 39.4% de la variabilidad en el conjunto de datos, aunque este porcentaje no es extremadamente alto, indica que una parte significativa de la variabilidad se puede resumir en dos dimensiones lo que facilita la visualización y el análisis de patrones subyacentes en los datos.

Tabla 19

Componentes principales

	Radiación Irradiación normal (MWh/m ²)	Temperature C
Componente 1	0,492545	0,061124
Componente 2	-0,021037	0,408674
	Precipitation Water mm	Relative Humidity %
Componente 1	-0,063953	-0,016638
Componente 2	-0,1292	0,268294
	Wind Speed	Wind Direction
Componente 1	-0,031547	-0,071352
Componente 2	-0,521347	-0,369819
	Termica MWh	Fotovoltaica\nMWh
Componente 1	0,114984	0,31909
Componente 2	0,511262	0,16343
	Turistas	Energia Mwh
Componente 1	0,564914	0,555917
Componente 2	-0,156095	-0,151115

Nota. Estructura de datos extraídos a partir del análisis PCA

Los componentes principales representan combinaciones lineales de las variables originales las cargas que has proporcionado indican cómo cada variable contribuye a los primeros dos componentes principales (Componente 1 y Componente 2).

3.1.1 Componente 1

- Turistas (0.564914) y Energía MWh (0.555917) tienen las cargas más altas y positivas en el primer componente. Esto indica que este componente está principalmente influenciado por el número de turistas y el consumo total de energía, sugiriendo una estrecha relación entre ambos factores.
- Radiación (0.492545) también tiene una carga positiva significativa, lo que indica que la irradiación solar es un factor relevante en este componente, probablemente a través de su impacto en la generación de energía fotovoltaica.
- Fotovoltaica MWh (0.31909) y Térmica MWh (0.114984), aunque con cargas menores, también contribuyen positivamente, mostrando su relación con el consumo de energía, aunque de forma menos marcada.
- Viento (-0.031547) y la dirección del viento (-0.071352) presentan cargas negativas, lo que sugiere una influencia inversa muy débil en este componente.

3.1.2 Componente 2

- Temperatura (0.408674) y Térmica MWh (0.511262) tienen cargas considerables en el segundo componente. Esto sugiere que este componente refleja una relación positiva entre la temperatura y la generación de energía térmica.
- Velocidad del viento (-0.521347) y dirección del viento (-0.369819) tienen cargas negativas altas, lo que indica una relación inversa importante entre estas variables y el

segundo componente. Es decir, cuando la velocidad del viento aumenta, la contribución de este componente disminuye.

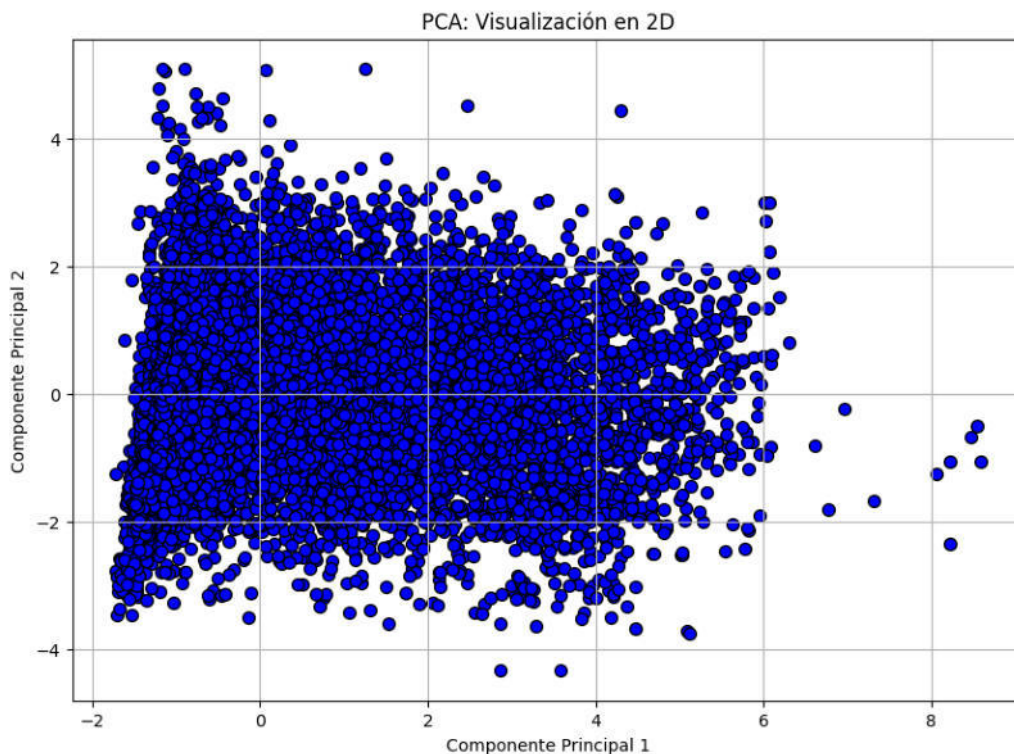
- Precipitación (0.268294) muestra una carga positiva moderada, lo que indica que las condiciones climáticas húmedas también influyen en este componente.

Componente 1 refleja principalmente la influencia del turismo y la irradiación solar en el consumo energético, mientras que el Componente 2 resalta la relación entre las condiciones climáticas, especialmente la temperatura y el viento, y las fuentes de energía renovable. Ambos

componentes muestran una interdependencia significativa entre las condiciones ambientales y el consumo energético, abriendo la posibilidad de optimizar la eficiencia energética.

Ilustración 14

Proyección de los datos



Nota. Estructura del análisis PCA visualización en 2D

El gráfico PCA muestra la proyección de los datos en un espacio bidimensional utilizando los dos primeros componentes principales. La mayoría de los puntos se concentran en un área específica lo que indica que estas dos componentes capturan una cantidad significativa de la variabilidad de los datos, aunque también hay algunos puntos dispersos que podrían representar outliers o variabilidad.


3.2 Resultados Red neuronal Autoencoder-LSTM

En la presente sección se exponen los resultados obtenidos para el modelo Autoencoder-LSTM, los resultados de la predicción y el rendimiento del modelo.

Se realizó las predicciones para los datos de prueba y evaluación donde se calcula el Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) y el R^2 evaluando el rendimiento del modelo. Los valores predichos y reales se desescalan para visualizarlos en su escala original. Se grafica la energía real vs energía predicha y se generan predicciones para los datos futuros, simulando un año adicional de predicción, visualizando las proyecciones futuras junto con los datos históricos.

Ilustración 15

Serie temporal Perdida del modelo Autoencoder-LSTM




Nota. Resultado del error de entrenamiento aplicado las 700 épocas

La en grafica de pérdida del modelo muestra el seguimiento de la pérdida o error del conjunto de entrenamiento y pérdida en el conjunto de validación a lo largo de las épocas de entrenamiento, donde se aprecia que ambas curvas de pérdida disminuyen de manera consistente, lo que indica que el modelo está aprendiendo durante el entrenamiento y ambas convergen hacia

valores bajos significa que el modelo no está sobre ajustando los datos de entrenamiento y por ultimo las pérdidas parecen estabilizarse al finalizar el grafico, lo que indica que el modelo ha alcanzado un punto donde no mejora mucho más.

Ilustración 16

Predicciones del Autoencoder-LSTM



Nota. Resultado de las predicciones versus los valores reales para todo el conjunto de datos

Ahora se muestra las grafica de predicciones realizadas por el modelo Autoencoder-LSTM en comparación a los valores reales en el rango de tiempo del 2022 y 2023. A lo largo del gráfico, las predicciones siguen bastante de cerca a los valores reales, lo que indica que el modelo está capturando bien la estructura general y los patrones estacionales de los datos reales.

También se observa una clara estacionalidad en ambas series de tiempo, donde los picos y valles reflejan ciclos de consumo de energía repetitivos. Esto sugiere que el modelo Autoencoder-LSTM ha capturado correctamente las variaciones temporales. Ahora se muestra la

evaluación para el modelo de serie de tiempo del rendimiento de las predicciones en el conjunto de testeo y las predicciones de la red neuronal

Tabla 20

Métricas de evaluación

Métricas de Evaluación	
Mean Absolute Error	0.0015352053
Root Mean Squared Error	0.0024598261
R ² Score	0.9681813700

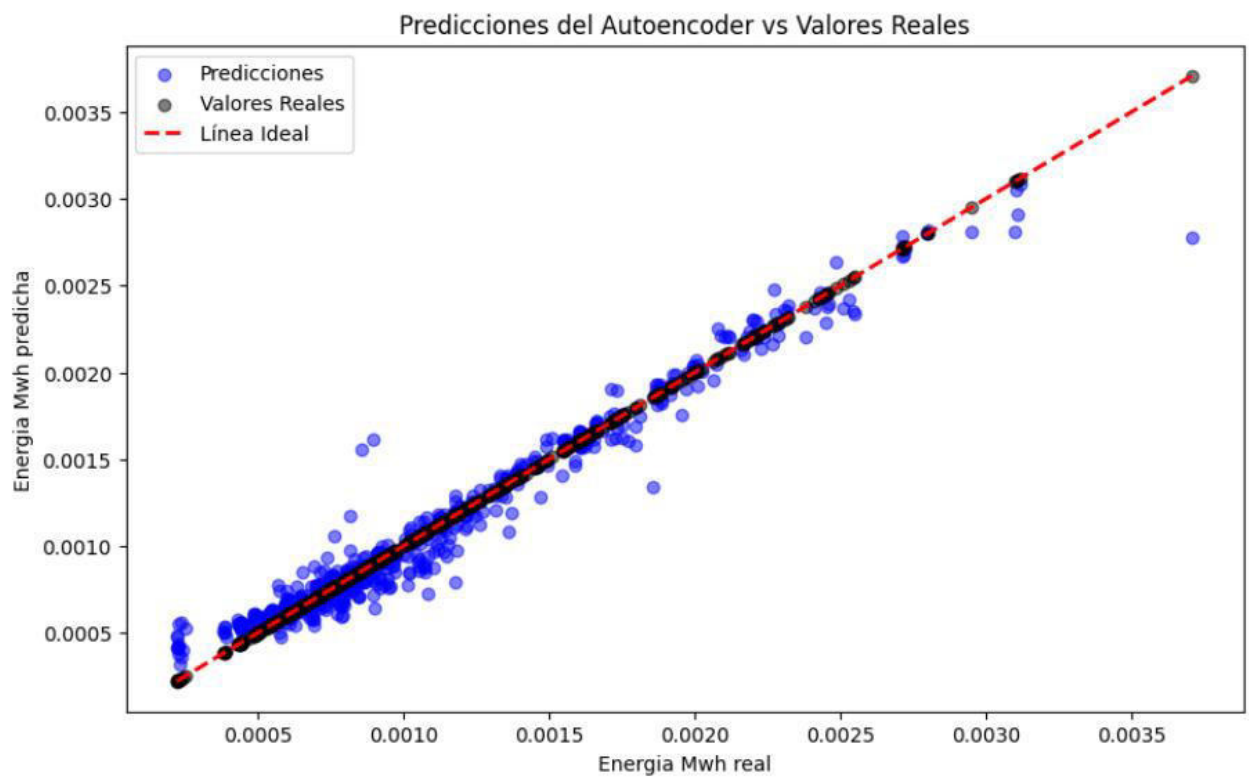
Nota. Resultado de las meticas de la red neuronal con datos de base original

- **Mean Absolute Error (MAE):** El MAE mide el error promedio en las predicciones del modelo, en este caso, el valor es extremadamente bajo, lo que significa que, en promedio, el modelo tiene un error absoluto de 0.0015 MWh al predecir la energía. El modelo está prediciendo con una precisión alta, con errores relativamente pequeños.
- **Root Mean Squared Error (RMSE):** El RMSE también mide el error promedio, pero da más peso a los errores grandes (eleva al cuadrado las diferencias entre los valores predichos y reales). El valor obtenido es de 0.00246 MWh, lo que indica que el modelo tiene errores ligeramente más grandes en algunos casos, pero aun así son bajos, el modelo tiene buen rendimiento con errores muy bajos.
- **R² Score:** El coeficiente de determinación, indica qué tan bien el modelo explica la variabilidad de los datos reales, el modelo explica el 96.8% de la varianza en los datos de energía es decir que tiene un excelente ajuste a los datos, explicando casi toda la variabilidad, lo que indica una gran capacidad predictiva.

Se realiza una evaluación adicional donde se calculan métricas como el Mean Absolute Percentage Error (MAPE) y el MSE para analizar el error porcentual y se visualizan las predicciones futuras y las proyecciones de energía para los próximos 365 días.

Ilustración 17

Gráfica de predicciones con lineal ideal



Nota. Resultado de las predicciones de la red neuronal comparando con valores reales en base a la lineal ideal de datos

Tabla 21

Otras métricas de evaluación


Otras Métricas de Evaluación	
MSE	0.00000
Error Absoluto Porcentual Medio	0.08259

Nota. Resultado de las meticas de la red neuronal con datos de base original

- **MSE (Error Cuadrático Medio):** Es extremadamente bajo (0.0000), lo que indica que el modelo está haciendo predicciones muy precisas en términos del error cuadrático, lo que es una señal positiva de que el modelo está funcionando bien.
- **(Error Absoluto Porcentual Medio):** Un MAPE del 8.259% es relativamente bajo, lo que sugiere que el modelo tiene un buen desempeño. Sin embargo, a pesar de que el MSE es extremadamente bajo, el MAPE muestra que las predicciones no son perfectas, lo cual es normal en escenarios de predicción

Ilustración 18

Predicción de energía un año futuro



Nota. Resultado de las predicciones comparando en una serie temporal las variaciones de los datos reales y predicción de energía a un año futuro

Finalmente se crea una función para generar características futuras a partir de los últimos datos conocidos, añadiendo una señal estacional. Es decir que se implementa una predicción iterativa en la que los valores predichos se utilizan como entrada para predicciones futuras. Se

puede ver en la gráfica que hay tendencia cíclica en los datos históricos con fluctuaciones estacionales y las predicciones mantienen un patrón estacional similar al de los datos históricos, aunque más suaves y con menos variabilidad que los datos reales. Esto podría ser un signo de suavización en el modelo predictivo, donde las fluctuaciones extremas se ven moderadas.

3.3 Resultados Simulaciones de Escenarios

Las simulaciones de escenarios se llevaron a cabo con el objetivo de analizar cómo varían las necesidades energéticas del catamarán en función de diferentes niveles de demanda, ajustados principalmente por la cantidad de turistas. Los resultados de las simulaciones para el año 2024 se presentan a continuación, con variaciones en la demanda que van desde una proyección base hasta un escenario de alta demanda (46%) y uno de baja demanda (-15%).

Tabla 22

Simulaciones de varios escenarios

Escenario	Energía Solar (kWh/año)	Energía Red Eléctrica (kWh /año)	Total, Energía	Energía Total 7 Catamaranes
2024 Base	7,955.40	3,663.10	11,618.49	25,641.70
2024 Media 23%	7,955.40	5,548.25	13,503.65	38,837.80
2023 Alta 46%	7,955.40	7,701.27	15,656.73	53,908.90
2024 Baja (-15%)	5,390.58	2,482.12	7,872.70	17,374.82

Nota. Resultado de las simulaciones en diferentes escenarios con variación de porcentaje

Las simulaciones permiten identificar tanto riesgos como oportunidades bajo diferentes escenarios de demanda. En un escenario de alta demanda, el aumento de turistas eleva la necesidad de energía proveniente de la red eléctrica, lo que podría traducirse en un incremento de costos operativos si las tarifas de energía suben. Este escenario destaca la necesidad de optimizar

el consumo energético y buscar estrategias para mitigar los costos en momentos de alta demanda, tales como la inversión en infraestructura energética alternativa o la negociación de contratos de suministro a largo plazo con precios fijos.

Por el contrario, en el escenario de baja demanda, aunque los costos energéticos se reducen gracias a la suficiencia de la generación solar, la menor afluencia de turistas afecta directamente los ingresos del negocio. En este contexto, es crucial ajustar la operación del catamarán de manera que la eficiencia sea máxima y los recursos solares sean aprovechados en su totalidad, reduciendo al mínimo la dependencia de la red eléctrica.

Estas simulaciones reflejan también la importancia de contar con un plan flexible de operación que permita adaptarse tanto a picos de demanda como a períodos de baja actividad. En ambos casos, se observa que la planificación adecuada puede contribuir a reducir la variabilidad de los costos energéticos y mejorar la viabilidad financiera del proyecto. Cabe mencionar también que en los diferentes escenarios el rendimiento del modelo también tuvo el coeficiente de determinación en el 96% con una gran capacidad predictiva y lograron mostrar las fluctuaciones de la energía indicadas en cada escenario.

Mediante simulaciones de diferentes escenarios de turismo se pudo evaluar cómo estos factores impactan el consumo energético y el rendimiento del INER 1. Esto permite ajustar el modelo predictivo y optimizar el uso de la energía solar en función de las fluctuaciones externas. Este enfoque garantiza que el modelo sea más robusto y adaptable a las condiciones reales del entorno, como se logró evidenciar en la tabla 22 con las variaciones de energía requeridas en las diferentes situaciones de demanda turística.

3.4 Análisis del Impacto de Factores Externos: Clima

Se realizaron las simulaciones según el impacto del clima variando el porcentaje del –5%, 10%, 15% y se obtuvieron los siguientes resultados donde se identificaron la cantidad total de energía que se requiere, entre ellas la energía solar y la energía de la red eléctrica necesaria.

Tabla 23

Simulaciones de varios escenarios Clima

Escenario Clima	Energía Solar (kWh/año)	Energía Red Eléctrica (kWh /año)	Total, Energía
2024 Baja -5%	6,022.32	2,773.00	8,795.33
2024 Media 10%	6,967.38	3,208.16	10,175.54
2023 Alta 15%	7,283.36	3,353.65	10,637.02

Nota. Resultado de las simulaciones de clima en diferentes escenarios con variación de porcentaje

Escenario Clima Bajo: Este escenario proyecta una reducción en la generación de energía solar a 6,022.32 kWh/año, lo que incrementa la dependencia de la red eléctrica a 2,773.00 kWh/año. El total de energía requerida se sitúa en 8,795.33 kWh/año, lo que subraya la vulnerabilidad del catamarán ante condiciones climáticas menos favorables.

Escenario Clima Medio: Con un incremento del 10% en la disponibilidad de energía solar, el catamarán genera 6,967.38 kWh/año de energía solar, lo que reduce la necesidad de energía de la red eléctrica a 3,208.16 kWh/año. El consumo total en este escenario alcanza los 10,175.54 kWh/año, lo que refleja una mejora en la autosuficiencia energética del catamarán, mitigando los costos asociados a la energía externa.

Escenario Clima Alto: En este escenario optimista, con un aumento del 15% en la energía solar, el catamarán genera 7,283.36 kWh/año, mientras que la energía de la red eléctrica se mantiene en 3,353.65 kWh/año. El consumo total asciende a 10,637.02 kWh/año, lo que

resalta el potencial de aprovechar condiciones climáticas favorables para minimizar la dependencia de la red eléctrica.

Las simulaciones climáticas reflejan que las variaciones en las condiciones del clima influyen considerablemente en la generación de energía solar y la necesidad de depender de la red eléctrica. En situaciones de menor disponibilidad de energía solar, como una reducción del 5%, se incrementa la dependencia de la red eléctrica, lo que eleva los costos operativos. En contraste, un incremento del 15% en la energía solar mejora la autosuficiencia del catamarán, reduciendo la necesidad de energía externa.

Estos resultados subrayan la relevancia de un sistema energético flexible capaz de adaptarse a los cambios climáticos. Estrategias como el almacenamiento de energía y la mejora de la infraestructura solar pueden ser esenciales para mantener la eficiencia operativa, minimizando los riesgos financieros y garantizando la sostenibilidad a largo plazo del catamarán en distintas condiciones meteorológicas.

Capítulo 4

Conclusiones

- El análisis PCA muestra que tanto los factores climáticos como la demanda turística son fundamentales para el consumo energético. El primer componente, influido por la radiación solar y el número de turistas, explica el 26.2% de la variabilidad, mientras que el segundo explica el 13.2%. En conjunto, ambos componentes explican el 39.4% de la variabilidad, resaltando la importancia de las condiciones ambientales y el turismo en la gestión y eficiencia del consumo energético.
- Aunque el modelo ARIMA ha logrado un ajuste adecuado para las fluctuaciones a corto plazo en la serie temporal de energía, su simplicidad y la falta de capacidad para capturar dinámicas complejas a largo plazo limitan su efectividad. El intento de aplicar un modelo SARIMA también resultó insatisfactorio, dado que no pudo manejar la complejidad y la variabilidad de los datos, lo que indica la necesidad de enfoques más avanzados para la predicción energética.
- Para el modelo de la red neuronal Autoencoder-LSTM muestra un excelente rendimiento en términos de predicción de la energía, con un coeficiente de determinación de 0.968 refleja que el modelo puede explicar el 96.8% de la variabilidad en los datos, lo que significa que la estructura y los patrones estacionales del consumo de energía han sido capturados de manera efectiva.
- El uso del Autoencoder no solo ha comprimido eficientemente las variables de entrada en una representación compacta, sino que también ha eliminado el ruido innecesario de los datos, lo que ha mejorado significativamente el rendimiento general del modelo en la serie temporal que contenía muchas irregularidades

- Las proyecciones realizadas a futuro exactamente para un año adicional de energía muestran predicciones realistas lo que sugiere que el modelo mantiene su precisión a la hora de prever tendencias futuras, lo cual es clave para la toma de decisiones en términos de planificación y sostenibilidad energética.

Caso de Estudio

- El análisis de la demanda de energía para los catamaranes demuestra la creciente importancia de la energía solar, con una proyección en 2024 que indica que el 68.4% de las necesidades cubiertas por energía solar, mientras que el 31.6% dependerá de la red eléctrica. Si toda la flota migrara a ser eléctrica, se requerirían 81,319.5 kWh anuales. Este escenario demuestra que la capacidad de generación solar actual es significativa, pero aún existe una dependencia considerable de la red eléctrica, lo que limita la autonomía energética de la flota.
- El análisis de los escenarios de demanda energética para muestra que el sistema solar del catamarán tiene un límite máximo de generación, determinado por el factor de planta, que se proyecta en 7,955.40 kWh/año. Este valor se mantiene constante lo que refleja la incapacidad del sistema solar de adaptarse a incrementos significativos en la demanda energética, como el aumento en la cantidad de turistas. En los escenarios de mayor demanda, la red eléctrica se convierte en una fuente esencial para suplir la diferencia, llegando a cubrir hasta el 49% de la energía total requerida.
- El análisis revela que, a medida que la demanda de energía se incrementa, los costos operativos de los catamaranes eléctricos también aumentan de manera significativa. Esto resalta la necesidad de realizar pronósticos precisos sobre la demanda energética para optimizar su uso y prevenir gastos innecesarios. Además, evaluar y mejorar el diseño de los

catamaranes, incorporando materiales más ligeros y eficientes, puede facilitar una operación más rentable y ecológica.

- La capacidad de almacenamiento de 11.5 kWh es fundamental para optimizar la eficiencia energética de los catamaranes eléctricos, ya que permite utilizar la energía solar generada durante el día en momentos de alta demanda. Este sistema no solo reduce la dependencia de la red eléctrica, sino que también contribuye a disminuir significativamente los costos operativos al minimizar el uso de energía no almacenada. Además, el ahorro del 18% en energía almacenada es un factor clave en la gestión económica de la operación.
- Las oportunidades de carga vespertina y nocturna ofrecen un ahorro significativo del 9.44%, lo que puede impactar positivamente en la reducción de costos operativos de los catamaranes eléctricos. Al diferenciar entre estos costos de carga, se facilita la gestión de la energía, permitiendo una optimización en el uso y distribución de los recursos energéticos disponibles durante los momentos de menor demanda.
- Aunque el consumo energético de los catamaranes eléctricos se mantiene por debajo de la capacidad de generación de la isla Santa Cruz, el análisis revela un déficit significativo entre la demanda máxima y la capacidad actual. Esta situación pone en riesgo la sostenibilidad del sistema energético, especialmente ante un posible aumento en la adopción de vehículos eléctricos, lo que podría exacerbar la presión sobre la infraestructura existente.
- El análisis de rentabilidad revela que, a pesar de los mayores egresos del catamarán, este se posiciona como una opción más rentable que la lancha, gracias a su capacidad superior de generación de ingresos y a los beneficios fiscales que recibe por el uso de energía renovable. La mayor capacidad de pasajeros y los ahorros en costos energéticos contribuyen a una utilidad neta significativamente más alta y un margen de contribución superior. Esto enfatiza

la ventaja competitiva del catamarán en un contexto donde la sostenibilidad y la eficiencia son cruciales.

- El análisis del impacto ambiental revela que la operación genera un total de 38,039 kg de CO2 anualmente, lo que equivale a 38 toneladas de emisiones de gases de efecto invernadero. Este dato subraya la relevancia de adoptar medidas para reducir el consumo de combustible, no solo por motivos económicos, sino también por la responsabilidad ambiental inherente a las organizaciones en la lucha contra el cambio climático.
- La escalabilidad del catamarán solar "INER 1" ofrece una valiosa oportunidad para transformar el transporte marítimo en Ecuador, siempre que se establezcan las infraestructuras adecuadas y tecnologías energéticas eficientes. La combinación de fuentes de energía renovable y la optimización del almacenamiento son clave para garantizar la viabilidad financiera del proyecto, promoviendo así un futuro más sostenible para el sector.

Recomendaciones

- El análisis de componentes principales (PCA) sugiere optimizar el consumo energético enfocándose en la demanda turística y las condiciones climáticas, ya que la radiación solar y el número de turistas son los factores clave. Ajustar la generación según los pronósticos meteorológicos y desarrollar sistemas predictivos para anticipar la demanda energética podría mejorar la eficiencia a largo plazo.
- Se sugiere explorar modelos más sofisticados, como redes neuronales o enfoques de aprendizaje automático, que puedan capturar las interacciones no lineales y la influencia de factores externos en la generación y consumo de energía. Asimismo, considerar la integración de datos adicionales, como variables climáticas y económicas, podría mejorar la precisión de las predicciones.
- Las redes neuronales profundas podrían captar mejor los patrones no lineales en los datos. Además, sería útil explorar modelos híbridos que combinen series temporales con algoritmos de machine learning, lo que mejoraría la precisión de las proyecciones energéticas.
- Un análisis más exhaustivo de variables exógenas, como políticas energéticas y cambios en el mercado, puede enriquecer la modelización y proporcionar una mejor comprensión de los factores que influyen en la demanda y oferta de energía. Esta combinación de enfoques podría ofrecer una solución más robusta para abordar las incertidumbres y dinámicas del sector energético a largo plazo.
- Se recomendaría incrementar la complejidad del modelo, realizando una red híbrida más compleja que incluya otras arquitecturas como CNN-LSTM o Transformer-LSTM, para ver si capturan mejor las relaciones espaciales y temporales entre las variables o variables

externas como cambios climáticos extremos, tormentas que afecten el consumo energético del catamarán.

Caso de Estudio

- Es fundamental seguir invirtiendo en tecnologías avanzadas que incrementen la eficiencia de generación solar y el almacenamiento de energía. Se recomienda la adopción de paneles solares de Perovskita, debido a su mayor capacidad de conversión de luz solar en energía, y la implementación de baterías de estado sólido, que mejoran significativamente la capacidad de almacenamiento frente a las baterías tradicionales de iones de litio.
- Dado que el sistema solar alcanza su capacidad máxima de generación en estos escenarios, es necesario explorar alternativas para incrementar la eficiencia o ampliar la capacidad de generación solar. Se recomienda la adopción de tecnologías más eficientes, como paneles solares de mayor rendimiento y almacenamiento, lo que permitiría reducir la creciente dependencia de la red eléctrica, mejorando la sostenibilidad y asegurando una mayor autonomía energética para los catamaranes.
- Se sugiere priorizar la integración de tecnologías renovables, como la energía solar, en la infraestructura de los catamaranes para maximizar el aprovechamiento de la energía solar generada. Asimismo, es esencial implementar un sistema de gestión energética que permita monitorear y ajustar el consumo en tiempo real, adaptándose a las variaciones en la demanda y asegurando una operación más eficiente y económica.
- Se sugiere realizar una inversión en la expansión de la capacidad de almacenamiento mediante la incorporación de baterías adicionales, adaptadas al espacio disponible en los catamaranes. Esta mejora permitirá maximizar el uso de la energía solar generada, asegurando un suministro más constante y sostenible, lo que a su vez impulsará la viabilidad

financiera y operativa de la flota en el largo plazo (en un arreglo de baterías más por el espacio disponible del catamarán que existe actualmente).

- Se sugiere implementar un horario de carga que priorice las tarifas más bajas de la noche y maximice la carga vespertina. Además, sería beneficioso negociar contratos de suministro eléctrico que incluyan tarifas preferenciales para estos horarios, lo que podría resultar en una reducción aún mayor de los costos operativos y contribuir a una operación más eficiente y económica de la flota de catamaranes.
- Se recomienda implementar estrategias que aumenten la capacidad de generación de energía eléctrica, la expansión de fuentes renovables y mejoras en la infraestructura de almacenamiento. Además, es fundamental optimizar los horarios de carga de los catamaranes eléctricos para alinearlos con períodos de menor demanda y maximizar el uso de energía renovable disponible, lo que contribuiría a una operación más sostenible y eficiente en la isla.
- Se recomienda continuar invirtiendo en la optimización de la operación del catamarán, especialmente en la reducción de costos de mantenimiento y la capacitación del personal, para maximizar aún más su rentabilidad. Además, considerar la posibilidad de aumentar la capacidad de pasajeros o diversificar los servicios ofrecidos podría incrementar aún más los ingresos, consolidando su posición como la opción más sostenible y económicamente viable en el transporte marítimo.
- Se recomienda implementar iniciativas que promuevan el uso de energías renovables y tecnologías más limpias, así como fomentar prácticas operativas que optimicen el consumo de combustible. La inversión en estrategias de eficiencia energética no solo contribuirá a la sostenibilidad ambiental, sino que también permitirá cumplir con las normativas y

expectativas sociales en materia de reducción de emisiones, fortaleciendo así la imagen de la organización y su compromiso con el medio ambiente.

- Se sugiere que las autoridades y los inversores colaboren en el desarrollo de estaciones de carga que utilicen energías renovables y que se aprovechen los incentivos fiscales y los bonos verdes. Además, la implementación de un sistema de gestión energética inteligente será crucial para optimizar el uso de la energía y asegurar una transición exitosa hacia un transporte marítimo más sostenible en Ecuador.

Anexos

Anexo 1

Flujo del Proyecto

	0	1	2	3	4	5	6	7	8	9	10											
INGRESOS OPERACIONALES																						
VENTAS	\$	126,720	\$	133,056	\$	139,709	\$	146,694	\$	154,029	\$	161,730	\$	169,817	\$	178,308	\$	187,223	\$	196,584		
COSTO DE VENTAS	\$	61,464	\$	62,693	\$	63,947	\$	65,226	\$	66,530	\$	67,861	\$	69,218	\$	70,602	\$	72,014	\$	73,455		
MARGEN DE CONTRIBUCION	\$	65,256	\$	70,363	\$	75,762	\$	81,469	\$	87,499	\$	93,870	\$	100,599	\$	107,705	\$	115,209	\$	123,130		
GASTOS OPERACIONALES																						
SERVICIOS BASICOS	\$	3,360	\$	3,494	\$	3,634	\$	3,780	\$	3,931	\$	4,088	\$	4,251	\$	4,422	\$	4,598	\$	4,782		
GASTOS POR RENOVACION DE TASAS	\$	2,500	\$	2,600	\$	2,704	\$	2,812	\$	2,925	\$	3,042	\$	3,163	\$	3,290	\$	3,421	\$	3,558		
GASTOS DE SUMINISTROS	\$	350	\$	364	\$	379	\$	394	\$	409	\$	426	\$	443	\$	461	\$	479	\$	498		
TOTAL GASTOS OPERACIONALES	\$	6,210	\$	6,458	\$	6,717	\$	6,985	\$	7,265	\$	7,555	\$	7,858	\$	8,172	\$	8,499	\$	8,839		
UTILIDAD OPERACIONAL	\$	59,046	\$	63,905	\$	69,045	\$	74,483	\$	80,234	\$	86,314	\$	92,741	\$	99,534	\$	106,710	\$	114,291		
IMPUESTOS																						
UTILIDAD NETA	\$	59,046	\$	63,905	\$	69,045	\$	74,483	\$	80,234	\$	86,314	\$	92,741	\$	99,534	\$	106,710	\$	114,291		
INVERSION INICIAL	\$	-313,378																				
CAPITAL DE TRABAJO	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500	\$	-6,500				
RECUPERACION DE CAP. TRABAJO																			\$	-65,000		
FLUJO DEL PROYECTO	\$	-319,878	\$	52,546	\$	57,405	\$	62,545	\$	67,983	\$	73,734	\$	79,814	\$	86,241	\$	93,034	\$	100,210	\$	49,291

Anexo 2*Van*

Periodo	VF	(1+i)^n	VP
0			\$ -319,878
1 \$	52,546	1.15	\$ 45,693
2 \$	57,405	1.02	\$ 56,142
3 \$	62,545	1.00	\$ 62,335
4 \$	67,983	1.00	\$ 67,949
5 \$	73,734	1.00	\$ 73,728
6 \$	79,814	1.00	\$ 79,813
7 \$	86,241	1.00	\$ 86,241
8 \$	93,034	1.00	\$ 93,033
9 \$	100,210	1.00	\$ 100,210
10 \$	49,291	1.00	\$ 49,291
VAN			\$ 394,557
TIR			16.76%

Anexo 3

Payback

Mes	Flujo mensual		Flujo m.a.		Payback
0					
1	\$	4,379	\$	4,379	\$ -315,499
2	\$	4,379	\$	8,758	\$ -311,120
3	\$	4,379	\$	13,137	\$ -306,742
4	\$	4,379	\$	17,515	\$ -302,363
5	\$	4,379	\$	21,894	\$ -297,984
6	\$	4,379	\$	26,273	\$ -293,605
7	\$	4,379	\$	30,652	\$ -289,226
8	\$	4,379	\$	35,031	\$ -284,847
9	\$	4,379	\$	39,410	\$ -280,468
10	\$	4,379	\$	43,789	\$ -276,089
11	\$	4,379	\$	48,168	\$ -271,711
12	\$	4,379	\$	52,546	\$ -267,332
13	\$	4,784	\$	57,330	\$ -262,548
14	\$	4,784	\$	62,114	\$ -257,764
15	\$	4,784	\$	66,898	\$ -252,981
16	\$	4,784	\$	71,681	\$ -248,197
17	\$	4,784	\$	76,465	\$ -243,413
18	\$	4,784	\$	81,249	\$ -238,629
19	\$	4,784	\$	86,033	\$ -233,846
20	\$	4,784	\$	90,816	\$ -229,062
21	\$	4,784	\$	95,600	\$ -224,278
22	\$	4,784	\$	100,384	\$ -219,494
23	\$	4,784	\$	105,167	\$ -214,711
24	\$	4,784	\$	109,951	\$ -209,927
25	\$	5,212	\$	115,163	\$ -204,715
26	\$	5,212	\$	120,375	\$ -199,503
27	\$	5,212	\$	125,588	\$ -194,291
28	\$	5,212	\$	130,800	\$ -189,079
29	\$	5,212	\$	136,012	\$ -183,866
30	\$	5,212	\$	141,224	\$ -178,654
31	\$	5,212	\$	146,436	\$ -173,442
32	\$	5,212	\$	151,648	\$ -168,230
33	\$	5,212	\$	156,860	\$ -163,018
34	\$	5,212	\$	162,072	\$ -157,806
35	\$	5,212	\$	167,284	\$ -152,594
36	\$	5,212	\$	172,497	\$ -147,382
37	\$	5,665	\$	178,162	\$ -141,716
38	\$	5,665	\$	183,827	\$ -136,051
39	\$	5,665	\$	189,492	\$ -130,386
40	\$	5,665	\$	195,158	\$ -124,721
41	\$	5,665	\$	200,823	\$ -119,055
42	\$	5,665	\$	206,488	\$ -113,390
43	\$	5,665	\$	212,153	\$ -107,725
44	\$	5,665	\$	217,819	\$ -102,059
45	\$	5,665	\$	223,484	\$ -96,394
46	\$	5,665	\$	229,149	\$ -90,729
47	\$	5,665	\$	234,814	\$ -85,064
48	\$	5,665	\$	240,480	\$ -79,398
49	\$	6,144	\$	246,624	\$ -73,254
50	\$	6,144	\$	252,769	\$ -67,109
51	\$	6,144	\$	258,913	\$ -60,965
52	\$	6,144	\$	265,058	\$ -54,820
53	\$	6,144	\$	271,202	\$ -48,676
54	\$	6,144	\$	277,347	\$ -42,531
55	\$	6,144	\$	283,491	\$ -36,387
56	\$	6,144	\$	289,636	\$ -30,242
57	\$	6,144	\$	295,780	\$ -24,098
58	\$	6,144	\$	301,925	\$ -17,953
59	\$	6,144	\$	308,069	\$ -11,809
60	\$	6,144	\$	314,214	\$ -5,664
61	\$	6,651	\$	320,865	\$ 987

Anexo 4

Cronograma



Bibliografía

- ACM (2009). *Computing Surveys*. <https://doi.org/10.1145/1541880.1541882>
- Aggarwal, C. C. (2018). *Neural networks and deep learning: A textbook*. Springer.
- Alba Vega, D. A., Calle Jara, J. F., & Cevallos Torres, L. (2020). *Aplicación de técnicas de Machine Learning basado en información sísmica para profundizar la probabilidad de terremotos mediante el uso de regresión logística y redes neuronales*. [Tesis de pregrado, Universidad de Guayaquil]. Repositorio Universidad de Guayaquil.
<http://repositorio.ug.edu.ec/handle/redug/48862>
- Alba, J. F., Dueñas, M., & Ortega, P. (2020). *Machine learning: Una introducción*. Editorial Académica Española.
- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2(4), 433-459.
- Amazon Web Services. (s.f.). *¿Qué es la regresión lineal?*. <https://aws.amazon.com/es/what-is/linear-regression/>
- Ahmad, A., et al. (2021). Artificial Intelligence in Energy Management. *Energy Reports*, 7, 3810–3823.
- Arrijoja, N. (24 de Septiembre de 2021). *Cómo actuar ante el desbalance de datos*.
<https://medium.com/@nicolasarrijoja/c%C3%B3mo-actuar-ante-el-desbalance-de-datos-a0d64f2b9619>
- Banco Interamericano de Desarrollo (BID). (2020). Primer Bono Verde emitido en Ecuador.
<https://www.iadb.org/es/noticias/banco-internacional-ecuador-emite-primer-bono-verde>
- Banco Interamericano de Desarrollo (BID). (2020). Proyectos sostenibles y mercado de carbono en Ecuador. <https://www.iadb.org/es/proyectos-sostenibles>
- Benítez-Capistros, F., Hugé, J., & Koedam, N. (2014). *Environmental impacts on the Galapagos*

Islands: Identification of interactions, perceptions and steps ahead. Ecological Indicators.

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Breiman, Friedman, Olshen, & Stone. (1984). *Classification and regression trees*.

Breiman, L. (2001). *Random Forest*. <https://link.springer.com/article/10.1023/A:1010933404324>

Cañadas, R. (22 de octubre de 2021). *AbDatum*. <https://abdatum.com/tecnologia/redes-neuronales-recurrentes>

Blunden, J., & Arora, V. K. (2020). State of the Climate. *Bulletin of the American Meteorological Society*, 101(8), S1–S429.

Cantuña, L. (2024). *Modelos avanzados de redes neuronales recurrentes en predicción energética*. Editorial Académica.

CAF (Banco de Desarrollo de América Latina). (2020). Financiamiento del Proyecto Coca Codo Sinclair. <https://www.caf.com/es/proyectos/coca-codo-sinclair/>

Chandola, V., Banerjee, A., & Kumar, V. (2009). *Anomaly detection: A survey*

Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). *SMOTE: Synthetic minority over-sampling technique*. *Journal of Artificial Intelligence Research*.
<https://doi.org/10.1613/jair.953>

Chinlli, C. M. (2021). Modelización de Series Temporales modelos SARIMA. Obtenido de https://masteres.ugr.es/estadistica-aplicada/sites/master/moea/public/inline-files/TFM_MIRANDA_CHINLLI_CARLOS.pdf

Codificando Bits. (2024). ¿Qué es una red neuronal?
<https://www.codificandobits.com/blog/que-es-una-red-neuronal/>

Constitución del Ecuador. (2008). *Constitución de la República del Ecuador*.

<https://www.registrocivil.gob.ec/constitucion-de-la-republica-del-ecuador/>

Corona E. (2020). Principales Metodologías en el Desarrollo de Proyectos de Minería de Datos.

Tecnocultura, 19.

Crownline Spain. (s.f.). *Innovaciones náuticas: Las últimas tendencias en tecnología de barcos*.

<https://crownlinespain.com/innovaciones-nauticas-las-ultimas-tendencias-en-tecnologia-de-barcos/>

Dueñas Quesada, J. M. (2020). *Aplicación de técnicas de machine learning a la ciberseguridad:*

Aprendizaje supervisado para la detección de amenazas web mediante clasificación basada en árboles de decisión

Eras, J. J. C., Morejón, M. B., Gutiérrez, A. S., García, M. P., Vaca, A. V., Brito, M. L., &

Cornejo, Z. M. (2019). *Renewable energy for the Galapagos Islands: Contributions of the ENERGA project. Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*. <https://doi.org/10.1080/15567036.2018.1549134>

Estudiar Energías Renovables Online. (s.f.). *Innovaciones en la energía eólica*.

<https://estudiarenergiasrenovablesonline.es/innovaciones-en-la-energia-eolica/>

Fernández, L., et al. (2020). IoT-Based Predictive Maintenance. *Renewable Energy*, 147, 258–

270.

George, M. & Pelcam, R. (2010). *Análisis de series temporales con ARIMA*. Springer.

Granda León, J. (2019). *El impacto del ecoturismo en las Islas Galápagos*. Universidad

Internacional del Ecuador.

- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). *LSTM: A search space odyssey. IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222-2232.
- Galápagos Science. (s.f.). *Inventario de emisiones antropogénicas y análisis espacial de gases de efecto invernadero y contaminantes primarios*.
<https://www.galapagossience.org/inventario-de-emisiones-antropogenicas-y-analisis-espacial-de-gases-de-efecto-invernadero-y-contaminantes-primarios/>
- García, S., Luengo, J., & Herrera, F. (2016). *Tutorial on practical tips of the most influential data preprocessing algorithms in data mining. Knowledge-Based Systems*.
- Gielen, D., et al. (2019). Global Energy Transformation. *International Renewable Energy Agency (IRENA)*. <https://www.irena.org/Publications/2019/Apr/Global-energy-transformation-A-roadmap-to-2050-2019Edition>
- Glorot, X. (2011). *Deep sparse rectifier neural networks. In Proceedings of the fourteenth international conference on artificial intelligence and statistics*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning. MIT Press*.
- Granda León, M., Guillén Granda, V., & Muñoz Torrecillas, M. J. (2019). *Sustainable tourism as a driving force of the tourism industry in the Galapagos Islands. CienciAmérica*.
<https://doi.org/10.33210/ca.v8i1.217>
- Graves, A. (2012). *Supervised sequence labelling with recurrent neural networks. Springer*.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2017). *LSTM: A search space odyssey. IEEE Transactions on Neural Networks and Learning Systems*.
<https://doi.org/10.1109/TNNLS.2016.2582924>
- Han, Kamber, & Pei. (2012). *Data mining: concepts and techniques. Morgan*.

- Haykin, S. (2009). *Neural networks and learning machines (3rd ed.)*. Pearson.
- Haykin, S. (1998). *Neural networks: A comprehensive foundation (2nd ed.)*. Prentice Hall.
- Heaton, J. (2008). *Introduction to Neural Networks for Java, 2nd Edition*. Heaton Research, Inc.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hong, W. (2009). Hybrid forecasting model for energy consumption using ARIMA and machine learning techniques. *Energy Economics*, 31(4), 578-585.
- International Energy Agency (IEA). (2020). Energy Policy Review: Ecuador. *OECD/IEA*. <https://www.iea.org/reports/ecuador-2020>
- International Energy Agency (IEA). (2021). Net Zero by 2050: A Roadmap for the Global Energy Sector. *OECD/IEA*. <https://www.iea.org/reports/net-zero-by-2050>
- International Renewable Energy Agency (IRENA). (2018). Renewable Power Generation Costs in 2018. <https://www.irena.org/publications/2019/Jun/Renewable-power-generation-costs-in-2018>
- IBM. (2022). *International Business Machine*. <https://www.ibm.com/es-es/topics/random-forest>
- IBM. (2024). ¿Qué es el aprendizaje supervisado? <https://www.ibm.com/es-es/topics/supervised-learning>
- Irene, R. (2021). *Proyectos de energía renovable en Galápagos. Informe Energético Anual*, 7, 23-35.
- Iglewicz, B., & Hoaglin, D. C. (1993). *How to detect and handle outliers*. ASQC Quality Press.
- Instituto Nacional de Meteorología e Hidrología (INAMHI). (s.f.). *Información de consulta del*

INAMHI. <https://www.inamhi.gob.ec/>

International Journal for Research (2022). *Forecasting Energy Consumption Using Hybrid CNN and LSTM Auto-Encoder Network with Hyperband Optimization*. *Informacion de*
https://www.researchgate.net/publication/364948293_Forecasting_Energy_Consumption_Using_Hybrid_CNN_and_LSTM_AutoEncoder_Network_with_Hyperband_Optimization.
 on.

INEC. (2023). *Boletín técnico anual, enero-diciembre 2023*.

Irena. (2021). *Renewable Energy Statistics 2021*. International Renewable Energy Agency.
<https://www.irena.org/publications/2021/Aug/Renewable-energy-statistics-2021>

Jyoti Prakash Mohanty. (2022). *Autoencoders and their applications*. *Journal of Applied Deep Learning*, 5(4), 102-118.

Jones, N. (2018). Wind Energy in Coastal Regions. *Nature Energy*, 3(12), 1040–1042.

Jolliffe, I. T. (2002). *Principal Component Analysis* (2nd ed.). Springer.

Jolliffe, I. T., & Cadima, J. (2016). Principal component analysis: A review and recent developments. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 374(2065), 20150202. Kaastra, I., & Boyd, M. (1996). *Designing a neural network for forecasting financial and economic time series*. *Neurocomputing*. [https://doi.org/10.1016/0925-2312\(95\)00039-9](https://doi.org/10.1016/0925-2312(95)00039-9)

Karsoliya, S. (2012). *Approximating Number of Hidden layer neurons in Multiple Hidden Layer*

Koller, T., Goedhart, M., & Wessels, D. (2020). *Valuation: Measuring and Managing the Value of Companies*. Wiley.

- Lawrence Berkeley National Laboratory. (2018). Infrared solar panels project. *Lawrence Berkeley National Laboratory*. <https://newscenter.lbl.gov/2018/03/05/infrared-solar-panels/>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep learning*. *Nature*.
<https://doi.org/10.1038/nature14539>
- Ley Orgánica de Régimen Especial para la Conservación y Desarrollo Sustentable de la Provincia de Galápagos. (2016). *Ley Orgánica de Régimen Especial para la Conservación y Desarrollo Sustentable de la Provincia de Galápagos*.
<https://www.galapagos.gob.ec/ley-organica-de-regimen-especial-para-la-conservacion-y-desarrollo-sustentable-de-la-provincia-de-galapagos/>
- Marcelo, M. (9 de septiembre de 2019). *Análisis del comportamiento de las variables ambientales y energéticas que inciden en la operación del catamarán solar "INER I" en las Islas Galápagos mediante selección de atributos* [Tesis de pregrado, Universidad Internacional SEK].
- Mastrorillo, M., et al. (2016). Global and regional assessment of the potential for solar energy. *Renewable and Sustainable Energy Reviews*, 64, 412-426.
- McKinsey & Company. (2021). The Future of Energy Storage. *McKinsey Insights*.
<https://www.mckinsey.com/business-functions/sustainability/our-insights/the-future-of-energy-storage>
- Ministerio del Ambiente, Agua y Transición Ecológica. (s.f.). *Convención sobre la Conservación de las Especies Migratorias de Animales Silvestres*.
<https://www.ambiente.gob.ec/convencion-sobre-la-conservacion-de-las-especies-migratorias-de-animales-silvestres/>

Ministerio del Ambiente, Agua y Transición Ecológica. (2023). *Informe Anual de Visitantes 2022 - Parque Nacional Galápagos*. https://galapagos.gob.ec/wp-content/uploads/2023/02/INFORME_ANUAL_VISITANTES_2022_DUP.pdf

Ministerio de Ambiente, Agua y Transición Ecológica. (2024). *Informe anual de visitantes 2023. Dirección del Parque Nacional Galápagos*. https://galapagos.gob.ec/wpcontent/uploads/2024/03/INFORME_ANUAL_VISITANTE_S-2023_WEB-LQ.pdf

Ministerio de Energía y Minas. (11 de Mayo de 2023). *El Nuevo Ecuador*. Obtenido de <https://www.rekursyenergia.gob.ec/ministerio-de-energia-y-minas-presento-plan-de-transicion-energetica-para-galapagos/>

Ministerio de Energía y Minas. (5 de Agosto de 2023). *El Nuevo Ecuador*. <https://www.rekursyenergia.gob.ec/gobierno-del-ecuador-ratifica-la-hoja-de-ruta-del-proyecto-cero-combustibles-fosiles-en-galapagos/>

Ministerio del Ambiente y Agua. (2020). Bonos soberanos verdes y su aplicación en Ecuador. <https://www.ambiente.gob.ec/bonos-verdes-ecuador>

Ministerio del Ambiente. (2021). Estrategia Nacional de Mitigación de Gases de Efecto Invernadero y Mercado de Carbono. <https://www.ambiente.gob.ec/mercado-de-carbono/>

Mitchell, T. M. (1997). *Machine learning*. McGraw Hill.

Morales, J. M., Conejo, A. J., & Pérez-Ruiz, J. (2020). *Economic valuation of reserves in power systems with high penetration of wind power*. *IEEE Transactions on Power Systems*. <https://doi.org/10.1109/TPWRS.2009.2016598>

Moya, R. (2019). Transporte marítimo de pasajeros en las Islas Galápagos: Impacto ambiental y soluciones sostenibles. *Revista de Ecología Marítima*, 12(3), 45-58

- Moon, K. (2018). *Energy load forecasting with hybrid neural networks*. *Energy Journal*, 35(4), 45-60.
- Moon, T. (2018). Optimization of hybrid machine learning models for energy forecasting. *IEEE Transactions on Neural Networks*, 29(3), 567-576.
- Moya, F. (2019). *El transporte marítimo sostenible en las Islas Galápagos*. Tesis de maestría, Universidad Internacional del Ecuador.
- Organización Mundial del Turismo (OMT). (2019). *Panorama del turismo internacional, edición 2019*. OMT. <https://www.e-unwto.org/doi/book/10.18111/9789284421237>
- Parque-Nacional-Galápagos. (2022). *Informe anual 2022 visitantes a las áreas protegidas de Galápagos*. <http://www.galapagos.gob.ec/>
- Patro, S. G. K., & Sahu, K. K. (2015). *Normalization: A preprocessing stage*.
- Plan transición Energética de las islas Galápagos. (2022). *Informe anual 2022 BIB Galápagos*. <https://www.rekursyenergia.gob.ec/wp-content/uploads/2023/11/BID-GALAPAGOS-PUBLICACION-v7-fotos-comprimido.pdf>
- Pérez, J., et al. (2020). Hybrid Renewable Energy Systems for Maritime Applications. *Applied Energy*, 275, 115407.
- Pelcam, G. (2010). *Series temporales y modelos econométricos*. Editorial Científica Internacional
- Pérez, R., & Gómez, L. (2022). Eficiencia y sostenibilidad en sistemas de transporte impulsados por energía solar. *Energía y Medio Ambiente*, 15(4), 102-118.
- Pfenninger, S., & Staffell, I. (2016). Long-term patterns of European PV output using open-source weather data. *Energy*, 114, 1251-1265. <https://doi.org/10.1016/j.energy.2016.08.060>

PVMagazine. (2014). Ecuador: Correa inaugura central solar de 1,5 MW en Galápagos.

<https://www.pv-magazine-latam.com/2014/12/23/ecuador-correa-inaugura-central-solar-de-1-5-mw-en-galapagos/>

Programa de las Naciones Unidas para el Desarrollo (PNUD). (2019). Informe sobre el impacto de los proyectos REDD+ en Ecuador.

<https://www.ec.undp.org/content/ecuador/es/home/sustainable-development.html>

Review, H. I. (2023). Harvard International Review. <https://hir.harvard.edu/the-galapagos-islands-economy-over-ecosystems/>

PwC (PricewaterhouseCoopers). (2021). Energy Transformation: IoT and Renewables. *PwC Global*. <https://www.pwc.com/gx/en/services/sustainability/energy-transformation.html>

Review, G. (2023). Economía de las Islas Galápagos: Dependencia del turismo y desarrollo sostenible. *Global Economy Review*, 18(2), 101-112.

Rivera, M. A., & Croes, R. (2010). *Ecotourists' loyalty: Will they tell about the destination or will they return?* *Journal of Ecotourism*. <https://doi.org/10.1080/14724040902795964>

Rokach, & Maimon. (2008). *Data mining with decision trees: theory and applications*. World Scientific.

Statkraft. (s.f.). *Energía solar*. <https://www.statkraft.cl/lo-que-hacemos/energia-renovable/energia-solar/>

Shlens, J. (2014). A tutorial on principal component analysis. Obtenido de <https://arxiv.org/pdf/1404.1100>

Smil, V. (2021). Power Density: A Key to Understanding Energy Sources and Uses. *MIT Press*. <https://mitpress.mit.edu/books/power-density>

Trenberth, K. E. (2011). Changes in precipitation with climate change. *Climate Research*, 47(1-2), 123-138.

UISek. <https://repositorio.uisek.edu.ec/handle/123456789/3558>

United Nations Environment Programme (UNEP). (2020). Green Finance: Mobilizing Investment for Renewables. <https://www.unep.org/resources/report/green-finance-mobilizing-investment-renewables>

Wang, H., Lei, Z., Zhang, X., Zhou, B., & Peng, J. (2019). *A review of deep learning for renewable energy forecasting. Energy Conversion and Management.*

World Bank. (2019). Renewable Energy Projects and Their Economic Impact. *World Bank Group*. <https://www.worldbank.org/en/topic/renewableenergy>

Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). *Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting.* [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7)

Enlace código de programación: <https://github.com/Michelle2897/MODELO-DE-MACHINE-LEARNING-PARA-ESTIMAR-LA-CANTIDAD-DE-ENERGIA-REQUERIDA-POR-UN-SISTEMA-DE-TRANSPORT>