



EDUCACIÓN

SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Tecnológico Nacional de México

**Centro Nacional de Investigación
y Desarrollo Tecnológico**

Tesis de Maestría

**Aplicación de Inteligencia Artificial para el
pronóstico de series temporales de velocidad del
viento en entornos urbanos para la evaluación
del recurso eólico.**

presentada por

Ing. William Flores Gómez

como requisito para la obtención del grado de
Maestro en Ciencias en Ingeniería

Director de tesis

Dr. Hugo Estrada Esquivel

Codirectora de tesis

Dra. Luisana Claudio Pachecano

Cuernavaca, Morelos, México. Agosto de 2026.



Educación
Secretaría de Educación Pública



TECNOLÓGICO
NACIONAL DE MÉXICO



Centro Nacional de Investigación y Desarrollo tecnológico
Coordinación de Ciencias de la Ingeniería

Cuernavaca, Mor., 12/ junio/ 2025

OFICIO No. MCI/046/2026
CENIDET-AC-004-M14-OFICIO

Asunto: Aceptación de documento de tesis


DR. CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO
PRESENTE

Por este conducto, los integrantes de Comité Tutorial de la estudiante **WILLIAM FLORES GÓMEZ**, con número de control M24CE035, de la Maestría en Ciencias de la Ingeniería, le informamos que hemos revisado el trabajo de tesis de grado titulado **"APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL PRONÓSTICO DE SERIES TEMPORALES DE VELOCIDAD DEL VIENTO EN ENTORNOS URBANOS PARA LA EVALUACIÓN DEL RECURSO EÓLICO"** y hemos encontrado que se han atendido todas las observaciones que se le indicaron, por lo que hemos acordado aceptar el documento de tesis y le solicitamos la autorización de impresión definitiva.


DR. HUGO ESTRADA ESQUIVEL
Director de tesis


DRA. ALICIA MARTÍNEZ REBOLLAR
Revisor 1


DRA. LUISANA CLAUDIO PACHECANO
Codirectora de Tesis


DR. VITERVO LOPEZ CABALLERO
Revisor 2

C.c.p. Depto. Servicios Escolares.
Expediente / Estudiante
RAVM/ehh



2025
Año de
La Mujer
Indígena

Tel. 01 (777) 3627770
Apatzingán 212, Palmira, 62490 Cuernavaca, Mor.
e-mail: coord.ingenieria@cenidet.tecnm.mx | cenidet.tecnm.mx

cenidet
Centro Nacional de Investigación y Desarrollo Tecnológico





Cuernavaca Mor, **18/junio/2026**

Oficio No. SAC/171/2026

Asunto: Autorización de impresión de tesis

WILLIAM FLORES GÓMEZ
CANDIDATO AL GRADO DE MAESTRO EN
CIENCIAS DE LA INGENIERÍA
P R E S E N T E

Por este conducto, tengo el agrado de comunicarle que el Comité Tutorial asignado a su trabajo de tesis titulado **"APLICACIÓN DE INTELIGENCIA ARTIFICIAL PARA EL PRONÓSTICO DE SERIES TEMPORALES DE VELOCIDAD DEL VIENTO EN ENTORNOS URBANOS PARA LA EVALUACIÓN DEL RECURSO EÓLICO"**, ha informado a esta Subdirección Académica, que están de acuerdo con el trabajo presentado. Por lo anterior, se le autoriza a que proceda con la impresión definitiva de su trabajo de tesis.


Esperando que el logro del mismo sea acorde con sus aspiraciones profesionales, reciba un cordial saludo.

ATENTAMENTE

Excelencia en Educación Tecnológica

"Conocimiento y Tecnología al servicio de México"


CARLOS MANUEL ASTORGA ZARAGOZA
SUBDIRECTOR ACADÉMICO



c.c.p. Coordinación de Ciencias de la Ingeniería
Departamento de Servicios Escolares

CMAZ/lmz



2026
año de
Margarita
Maza



Agradecimientos

Expreso mi gratitud a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) por la beca otorgada para mi formación en el programa de maestría. Asimismo, agradezco al Tecnológico Nacional de México / Centro Nacional de Investigación y Desarrollo Tecnológico (TECNM/CENIDET) por facilitar los recursos y los espacios necesarios para el desarrollo de mis estudios de posgrado.

A Dios, por brindarme la oportunidad de culminar esta importante etapa de mi vida y por guiar mis decisiones en todo momento.

A mi padre, mi madre, mi hermana, mi tío y mi novia, por nunca darse por vencidos conmigo y apoyarme incondicionalmente durante cada paso de este posgrado. Gracias por ser mi pilar, por creer en mí y motivarme a ser mejor cada día.

A mis directores de investigación, el Dr. Hugo Estrada Esquivel y la Dra. Luisana Claudio Pachecano, a quienes reconozco con el mismo nivel de importancia y gratitud. Gracias por la confianza depositada en mí al permitirme desarrollar esta tesis bajo su supervisión conjunta. Su guía académica, su experiencia compartida y el valioso tiempo que dedicaron a mi acompañamiento fueron fundamentales durante estos dos años.

Expreso también mi gratitud a los revisores de este trabajo, la Dra. Alicia Martínez Rebollar y el Dr. Vitervo López Caballero, por sus observaciones, su retroalimentación enriquecedora y la gran atención brindada durante todo el proceso de evaluación.

Al cuerpo docente del Departamento de Ciencias de la Ingeniería y al personal administrativo, por su continuo acompañamiento y apoyo.

Resumen

La transición hacia fuentes de energía limpias en entornos urbanos enfrenta retos técnicos debido a que la infraestructura de las ciudades genera rugosidad, dificultando la predicción del viento. Los métodos tradicionales de pronóstico, como el modelo univariado ARIMA, presentan limitaciones ante estas variaciones no lineales debido a su incapacidad para procesar factores termodinámicos simultáneos como la temperatura. Para mitigar esta incertidumbre, esta investigación desarrolló y validó un modelo multivariado de pronóstico de velocidad del viento a corto plazo utilizando Redes Neuronales Recurrentes de Memoria a Corto y Largo Plazo (LSTM). La metodología empleó 8,776 registros horarios del año 2024 provenientes de la estación de monitoreo de Nezahualcóyotl. El preprocesamiento de los datos incluyó la imputación de faltantes mediante interpolación lineal con ruido gaussiano, normalización Min-Max y la selección de la velocidad del viento y la temperatura como variables de entrada. Tras optimizar los hiperparámetros, se seleccionó una arquitectura en "embudo profundo" (128-64-32 neuronas con Dropout de 0.2), cuya estabilidad se verificó mediante 10 ejecuciones independientes, logrando una precisión promedio del 79.77% (con $\pm 0.85\%$ de desviación estándar). La evaluación del modelo se realizó con un conjunto independiente de 745 horas correspondiente a enero de 2025. La red LSTM obtuvo una precisión del 80.71% (MAPE: 19.29%, MAE: 0.4787 m/s, RMSE: 0.6607 m/s) frente al 78.98% de ARIMA (MAPE: 21.02%, MAE: 0.5217 m/s, RMSE: 0.7083 m/s). Estos resultados confirman que la integración de variables exógenas y la flexibilidad no lineal de la red LSTM reducen el error predictivo en microclimas urbanos, consolidando la arquitectura como un instrumento para la evaluación preliminar del recurso eólico en ciudades.

Palabras clave: Inteligencia Artificial, LSTM, ARIMA, Pronóstico del Viento, Entornos Urbanos, Recurso Eólico.

Abstract

The transition towards clean energy sources in urban environments faces technical challenges because city infrastructure increases surface roughness, complicating wind speed forecasting. Traditional forecasting methods, such as the univariate ARIMA model, exhibit limitations when dealing with these non-linear variations due to their inability to simultaneously process thermodynamic factors like temperature. To mitigate this uncertainty, this research developed and validated a multivariate short-term wind speed forecasting model using Long Short-Term Memory (LSTM) Recurrent Neural Networks. The methodology utilized 8,776 hourly records from the year 2024, collected from the Nezahualcóyotl monitoring station. Data preprocessing included missing data imputation via linear interpolation with Gaussian noise, Min-Max normalization, and the selection of wind speed and temperature as input variables. After hyperparameter optimization, a "deep funnel" architecture (128-64-32 neurons with a 0.2 Dropout rate) was selected, and its stability was verified through 10 independent runs, achieving an average accuracy of 79.77% (with a $\pm 0.85\%$ standard deviation). The evaluation of the model was conducted using an independent dataset consisting of 745 hours from January 2025. The LSTM network achieved an accuracy of 80.71% (MAPE: 19.29%, MAE: 0.4787 m/s, RMSE: 0.6607 m/s) compared to ARIMA's 78.98% (MAPE: 21.02%, MAE: 0.5217 m/s, RMSE: 0.7083 m/s). These results confirm that integrating exogenous variables and leveraging the non-linear flexibility of the LSTM network reduces forecasting errors in urban microclimates, establishing this architecture as a tool for preliminary urban wind resource assessment.

Keywords: Artificial Intelligence, LSTM, ARIMA, Wind Forecasting, Urban Environments, Wind Resource.

Contenido

Lista de figuras.....	iii
Lista de tablas	iv
Capítulo 1. Introducción	1
1.1 Introducción / Motivación.....	1
1.2 Objetivos	2
1.3 Metodología de Solución	3
1.4 Estructura de la tesis	4
Capítulo 2. Marco teórico	6
2.1 El recurso eólico en entornos urbanos	6
2.2 Inteligencia artificial y series de tiempo	8
2.3 Métricas de evaluación	11
Capítulo 3. Estado del arte	16
3.1 Pronóstico de velocidad del viento basado en algoritmos ARIMA	16
3.2 Pronóstico de velocidad del viento basado en algoritmos con redes neuronales	19
3.3 Pronóstico de velocidad del viento basado en métodos híbridos	24
3.4 Conclusiones del estado del arte	29
Capítulo 4. Modelo de pronóstico propuesto	32
4.1 Introducción a la metodología.....	32
4.2 Fase 1: Construcción del conjunto de datos.....	33
4.3 Fase 2: Desarrollo y entrenamiento de modelo.....	42
4.4 Fase 3: Selección y validación del modelo final.....	48
Capítulo 5. Análisis comparativo y presentación de resultados	52
5.1 Estructuración de las pruebas comparativas	52
5.2 Análisis de resultados en el conjunto de validación (20 %).....	53
5.3 Análisis de errores en la prueba independiente (enero 2025)	54
5.4 Análisis gráfico del comportamiento predictivo	56
5.5 Análisis de la distribución de errores de pronóstico	56

5.6 Desempeño predictivo en escenarios independientes	58
Capítulo 6. Conclusiones y trabajos futuros	60
6.1. Conclusiones	60
6.2. Trabajos futuros	61

Lista de figuras

Figura 2.1 Diferentes escalas de los procesos atmosféricos en áreas urbanas, ilustrando la capa límite urbana (UBL) y la capa del dosel urbano (UCL)..	7
Figura 2.2 Diagrama de bloques de una celda LSTM. Fuente: Olah (2015).	9
Figura 4.1 Metodología implementada para el desarrollo del modelo de pronóstico de la velocidad del viento	32
Figura 4.2 Interfaz del portal de la RAMA donde se obtuvieron los datos.	34
Figura 4.3 Cantidad de datos faltantes por estación de monitoreo (ordenado de mayor a menor completitud).	35
Figura 4.4 Matriz de correlación entre variables meteorológicas	36
Figura 4.5 Serie Temporal de la Velocidad del Viento con Datos Crudos.	39
Figura 4.6 Análisis detallado de las discontinuidades / Zoom de la Serie Temporal Cruda	39
Figura 4.7 Zoom de la Serie Temporal reconstruida con interpolación y ruido	40
Figura 4.8 Serie Temporal de la Velocidad del Viento / Dataset Reconstruido).	41
Figura 4.9 Comparativa de la Velocidad del Viento Real vs. Predicción del Modelo LSTM Simple.	44
Figura 4.10 Comparativa de la Velocidad del Viento Real vs. Predicción del Modelo LSTM final.	45
Figura 4.11 Comparativa de las 3 configuraciones de Hiperparámetros probadas.	47
Figura 4.12 Evolución de la Pérdida del Nuevo Modelo.	49
Figura 5.1 Comportamiento predictivo en el conjunto de validación (20 %): LSTM vs ARIMA	53
Figura 5.2 Comparativa de errores predictivos en la fase de validación: LSTM vs ARIMA.	54
Figura 5.3 Comportamiento predictivo en la prueba independiente (Enero 2025): LSTM vs ARIMA.	56
Figura 5.4 Gráfica comparativa de la distribución de errores de pronóstico (LSTM vs ARIMA).	57

Lista de tablas

Tabla 4.1 Análisis inicial del conjunto de datos meteorológicos.....	36
Tabla 4.2 Resumen estadístico de la velocidad del viento.....	37
Tabla 4.3 Resumen del conjunto de datos final.	42
Tabla 4.4 Métricas de Evaluación del Modelo LSTM Simple.	44
Tabla 4.5 Métricas de Evaluación del Modelo LSTM Profundo.....	46
Tabla 4.6 Hiperparámetros seleccionados para el Modelo Definitivo.....	47
Tabla 4.7 Resultados de precisión para las 10 corridas independientes del modelo.	49
Tabla 5.1 Comparativa de métricas ARIMA vs LSTM fase de pruebas	55

Capítulo 1. Introducción

Capítulo 1. Introducción

1.1 Introducción / Motivación

La necesidad de abastecer de electricidad a las grandes ciudades reduciendo el impacto ambiental exige una solución directa: generar energía limpia exactamente donde más se consume. El rápido crecimiento de la población y la expansión de las zonas metropolitanas hacen indispensable distribuir la generación eléctrica. Sin embargo, el aprovechamiento de la energía eólica dentro de áreas muy pobladas presenta un reto técnico enorme: evaluar con exactitud cuánto viento realmente hay disponible. A diferencia de los parques eólicos tradicionales ubicados en zonas abiertas o en el mar, donde el viento es más constante, intenso y con menor turbulencia, la propia estructura de la ciudad actúa como una gran barrera. Los edificios, las calles y la infraestructura aumentan la rugosidad del terreno, chocando contra el flujo natural del aire. Esta fricción rompe las corrientes, provocando el efecto estela y generando una turbulencia que vuelve el comportamiento del viento muy difícil de predecir (Liu et al., 2022).

El pronóstico de la velocidad del viento es una herramienta fundamental en la gestión energética que se clasifica en diferentes horizontes temporales, como el corto, mediano y largo plazo. De manera específica, el pronóstico a corto plazo resulta de vital importancia, ya que está dedicado directamente a la planificación y a la inyección de energía eléctrica a la red. Un pronóstico deficiente en este horizonte dentro de un entorno urbano impacta directamente en la planeación operativa, ya que, si los ingenieros no pueden anticipar el viento con alta precisión, resulta imposible programar de forma segura la inyección de electricidad hacia la red. Por otro lado, esta falta de exactitud también representa un riesgo crítico para la viabilidad de la inversión económica. El análisis detallado de las variaciones en la velocidad del viento es un factor clave para generar proyecciones confiables en un entorno urbano. Por lo tanto, contar con modelos predictivos exactos ayuda a evaluar correctamente el recurso eólico disponible dentro de la ciudad.

La viabilidad de cualquier proyecto exige una correcta evaluación del recurso eólico para alcanzar dicha exactitud, lo cual se realiza mediante el análisis riguroso de series temporales que registran las variaciones de la velocidad y dirección del viento a través del tiempo. La industria

energética ha dependido de diversos modelos estadísticos y matemáticos convencionales para intentar proyectar el comportamiento futuro de la velocidad y dirección del viento (Soman et al., 2010). Dentro de estos enfoques, los modelos como el método Autorregresivo Integrado de Media Móvil (ARIMA, por sus siglas en inglés) han mostrado limitaciones (Cadenas et al., 2016) cuando se enfrentan a la alta inestabilidad del microclima en una ciudad. Al ser el ARIMA un modelo estrictamente univariado, depende exclusivamente de la secuencia histórica de una sola variable, careciendo de la capacidad para procesar de manera simultánea otros factores termodinámicos que afectan la densidad del aire, como las fluctuaciones repentinas de temperatura. Esta naturaleza univariada genera importantes desviaciones de pronóstico, creando una falsa expectativa sobre la cantidad de energía que realmente se puede cosechar en entornos urbanos complejos (Stathopoulos et al., 2018).

La presente tesis de maestría se centró en el análisis de la incertidumbre predictiva durante la evaluación del recurso eólico urbano. El trabajo de investigación desarrolló, entrenó y validó un modelo de pronóstico basado en Inteligencia Artificial para procesar la dinámica de las series temporales del viento en la ciudad. La elección del caso de estudio de la meteorología urbana permitió evaluar de forma cuantitativa el desempeño de la arquitectura de aprendizaje profundo frente al modelo estadístico univariado ARIMA. El análisis de estas métricas de error estandarizadas sirvió como base para que este proyecto aportara una metodología computacional fundamentada en datos orientada a asistir en la planeación e instalación de aerogeneradores en zonas pobladas, y contribuye a la integración de fuentes de energía sostenible (Budanko & Guzović, 2024).

1.2 Objetivos

1.2.1 Objetivo general

Desarrollar un modelo de pronóstico de velocidad del viento para evaluar el recurso eólico en entornos urbanos, utilizando series temporales y algoritmos de inteligencia artificial.

1.2.2 Objetivos específicos

- Generar un dataset de series temporales de la velocidad de viento para contar con información estructurada y de calidad que permita el entrenamiento y validación de modelos de pronóstico, mediante la recopilación de datos históricos.
- Entrenar modelos de redes neuronales recurrentes aplicados a series temporales de la velocidad del viento para capturar patrones temporales que permitan mejorar la precisión de las predicciones, utilizando datos históricos y variables meteorológicas.
- Realizar pruebas comparativas para identificar el modelo de pronóstico de la velocidad del viento basado en algoritmos de inteligencia artificial que mejor se adapte a las condiciones específicas de la CDMX.
- Comparar el desempeño de los modelos de redes neuronales recurrentes con el método ARIMA, evaluar su precisión y eficacia mediante métricas como RMSE y MAE.

1.3 Metodología de Solución

La metodología para el pronóstico de la velocidad del viento en entornos urbanos mediante Inteligencia Artificial se propuso para obtener información exacta sobre cuánto viento hay en las ciudades y saber si es aprovechable como energía. Este proceso se realizó con el análisis de series de tiempo y modelos de aprendizaje automático que permitieron procesar los datos históricos. La metodología de solución se compone de 4 fases principales:

Fase 1: Construcción del conjunto de datos

- Recolección y organización de datos
- Preprocesamiento de datos

Fase 2: Desarrollo y entrenamiento de modelos

- Entrenamiento de modelos de Redes Neuronales Recurrentes
- Ajuste de hiperparámetros

Fase 3: Selección y validación del modelo final

- Selección del modelo final
- Validación del modelo final

Fase 4: Análisis comparativo y presentación de resultados

- Evaluación de precisión

- Pruebas de desempeño
- Comparación y análisis de modelos

1.4 Estructura de la tesis

El presente documento se estructura en seis capítulos, anexos y referencias.

- El Capítulo 2 presenta los fundamentos teóricos necesarios para entender esta investigación. Esta sección incluye la explicación sobre el comportamiento del viento en entornos urbanos y el funcionamiento de los algoritmos de Redes Neuronales Recurrentes utilizados para el pronóstico.
- El Capítulo 3 contiene la revisión de los trabajos reportados en la literatura que sirvieron como base y antecedentes para este estudio.
- El Capítulo 4 detalla el proceso implementado para el desarrollo del modelo predictivo de la velocidad del viento. La metodología abarca la recolección de los datos, el preprocesamiento de las series de tiempo, el entrenamiento algorítmico y el proceso de optimización de hiperparámetros.
- El Capítulo 5 abarca la validación del modelo seleccionado con un nuevo conjunto de datos. Este apartado presenta los resultados obtenidos y analiza la precisión paramétrica del sistema para la evaluación del recurso eólico.
- El Capítulo 6 presenta las conclusiones derivadas de este proyecto, los trabajos futuros propuestos y los productos académicos generados a partir de la investigación.

Capítulo 2. Marco teórico

Capítulo 2. Marco teórico

En este capítulo se presentan los fundamentos teóricos que sustentan esta investigación y que permiten comprender la relevancia del enfoque adoptado. En primer lugar, se abordan los aspectos relacionados con la evaluación del recurso eólico en entornos urbanos, analizando la capa límite, la rugosidad del microclima y el cálculo del potencial energético. Posteriormente, se introducen los conceptos de la inteligencia artificial y el análisis de series de tiempo, detallando los principios del aprendizaje automático y la arquitectura de las redes neuronales recurrentes (LSTM, por sus siglas en inglés) utilizadas para el pronóstico. Finalmente, se definen las métricas estadísticas de evaluación que permitirán medir el desempeño y validar la precisión de los modelos computacionales desarrollados.

2.1 El recurso eólico en entornos urbanos

La evaluación del recurso eólico en grandes áreas urbanas se lleva a cabo para determinar la viabilidad de generar electricidad en espacios complejos con alta densidad de obstáculos. Dicha evaluación se logra mediante metodologías de modelado que analizan cómo interactúa el flujo de aire con la geometría de los edificios, permitiendo estimar la velocidad media del viento y la densidad de potencia con un alto grado de precisión para validar el potencial energético de la ciudad (Simões & Rodrigues, 2016).

La capa límite urbana

La capa límite urbana se define como la porción inferior de la atmósfera cuyas características micrometeorológicas y cinemáticas están directamente influenciadas por la morfología de la ciudad y las actividades antrópicas. Su estructura vertical altera el flujo natural del aire y modifica drásticamente el perfil de la velocidad del viento a diferentes alturas, tal como se representa en la Figura 2.2.




Figura 2.1 Diferentes escalas de los procesos atmosféricos en áreas urbanas, ilustrando la capa límite urbana (UBL) y la capa del dosel urbano (UCL). Fuente: Adaptado de Oke (1997) y Piringer et al. (2002).

Desde la perspectiva de la medición y el modelado, el análisis de esta capa requiere la diferenciación de sus escalas espaciales. La atmósfera urbana se subdivide principalmente en la capa del dosel urbano (*Urban Canopy Layer*), donde el flujo del aire está dominado por la fricción de edificios individuales a nivel de calle, y la subcapa de rugosidad superior, donde los flujos turbulentos se mezclan. El conocimiento de su estructura es un factor físico indispensable para determinar la representatividad de los instrumentos de medición meteorológica y para que los modelos de pronóstico computacional logren procesar la incertidumbre del microclima (Grimmond, 2006; Rotach et al., 2005).

Rugosidad y turbulencia en el microclima

La rugosidad superficial y la turbulencia constituyen los factores físicos fundamentales que rigen la dinámica del flujo de aire a nivel local en el microclima urbano. La rugosidad, determinada por la geometría, densidad y distribución de los obstáculos físicos (edificios e infraestructura), genera una fricción mecánica que provoca la desaceleración del viento. Por su parte, la turbulencia representa las fluctuaciones y los vórtices derivados de esta interacción con la morfología de la ciudad. La cuantificación de estos fenómenos define el grado de inestabilidad climática, estableciendo los patrones dinámicos que los algoritmos de inteligencia artificial deben procesar para lograr predicciones precisas en estos entornos (Kurppa et al., 2020).

Cálculo del potencial energético (AEP)

El potencial energético eólico se define como la cuantificación de la energía cinética que puede ser extraída del viento en una ubicación específica. Su cálculo se fundamenta en la ecuación de potencia aerodinámica, la cual establece una relación de proporcionalidad directa con la densidad del aire, el área de barrido de la turbina y, de manera crítica, con el cubo de la velocidad del viento ajustada por la morfología urbana, tal como se expresa en la Ecuación:

$$P = \frac{1}{2} \rho A v^3$$

La relación cúbica de la velocidad del viento en esta ecuación provoca que cualquier subestimación de las ráfagas afecte el cálculo de la energía disponible, subrayando la importancia de optimizar el pronóstico mediante la red LSTM.

2.2 Inteligencia artificial y series de tiempo

La inteligencia artificial y el análisis de series de tiempo constituyen la base tecnológica y matemática para el modelado de variables climáticas complejas. La integración de estas áreas permite extraer patrones a partir de registros históricos para generar pronósticos precisos. En esta sección se establecen los fundamentos teóricos del aprendizaje automático, la estructura de los datos secuenciales y la arquitectura de las redes neuronales recurrentes, proporcionando el sustento matemático necesario para el procesamiento de la velocidad del viento.

Fundamentos del aprendizaje automático

El aprendizaje automático (*Machine Learning*) se define como un subconjunto de la inteligencia artificial que se centra en utilizar conjuntos de datos, que pueden ser limitados o extensos, y algoritmos escalables (Burkov, 2019). En el ámbito de la evaluación del recurso eólico, se utiliza para desarrollar modelos computacionales capaces de identificar relaciones no lineales sin depender de ecuaciones físicas preprogramadas. Los algoritmos representativos utilizados para el pronóstico de la velocidad del viento incluyen Máquinas de Soporte Vectorial para Regresión (SVR), Bosques Aleatorios (*Random Forest*), K-Vecinos más Cercanos (KNN) y arquitecturas de aprendizaje profundo como las redes neuronales recurrentes (RNN) y LSTM (Tyass et al., 2023;

Liu et al., 2025). La selección de la variante LSTM para el desarrollo de este trabajo obedece a su capacidad para procesar la memoria secuencial.

Teoría de series de tiempo

Una serie de tiempo se define como una sucesión de observaciones cuantitativas ordenadas cronológicamente en intervalos regulares. Su estructura describe la evolución de una variable en el tiempo, donde cada dato tiene una dependencia estadística de sus valores pasados, lo que se conoce como autocorrelación. El análisis de estas series establece la base para que los algoritmos computacionales aprendan el comportamiento temporal de la velocidad del viento en entornos urbanos y minimicen el error en el pronóstico (Tyass et al., 2023). Los registros históricos capturados por los anemómetros se estructuran bajo este principio como vectores de entrada para entrenar la memoria interna de la red neuronal desarrollada.

Arquitectura de Redes Neuronales Recurrentes (LSTM)

Las redes con Memoria a Corto y Largo Plazo (LSTM) son una arquitectura de redes neuronales recurrentes diseñada específicamente para procesar secuencias temporales extensas y resolver el problema matemático del desvanecimiento del gradiente. Su estructura interna utiliza un estado de celda y un sistema de compuertas que regulan el flujo de información, tal como se ilustra en la Figura 2.2.




Figura 2.2 Diagrama de bloques de una celda LSTM. Fuente: Olah (2015).

El estado de la celda (C_t) actúa como la línea principal de transmisión de información a lo largo del tiempo. Su modificación se determina mediante las siguientes compuertas matemáticas:

Compuerta de olvido (Forget Gate):

Esta compuerta define qué información del estado anterior (C_{t-1}) se descarta. Se calcula mediante una función sigmoide (σ) que evalúa la entrada actual (x_t) y el estado oculto previo (h_{t-1}), como se muestra en la Ecuación:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Donde W_f representa la matriz de pesos y b_f el sesgo de la red.

Compuerta de entrada (Input Gate):

Esta compuerta determina la nueva información que se almacenará en la celda. Utiliza una capa sigmoide para decidir los valores a actualizar (i_t) y una capa tangente hiperbólica para generar los valores candidatos ($\tilde{C}_t$), representados en las Ecuaciones:

$$\begin{aligned} i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tan(W_c \cdot [h_{t-1}, x_t] + b_c) \end{aligned}$$

Actualización del estado de la celda:

Este proceso consolida la memoria del sistema. Se realiza multiplicando el estado anterior por la compuerta de olvido y sumando la nueva información de la compuerta de entrada, de acuerdo con la Ecuación:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Compuerta de salida (Output Gate):

Esta compuerta define el estado oculto resultante (h_t) que se transfiere al siguiente paso. Filtra el estado de la celda mediante una función $\tanh$ y lo multiplica por una compuerta sigmoide (o_t), según las Ecuaciones:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$
$$h_t = o_t * \tanh(C_t)$$

La combinación de la Inteligencia Artificial (IA) y el análisis de series de tiempo es la base principal de este trabajo. La comprensión de este problema requiere considerar que el viento urbano cambia constantemente, ya que los edificios y la infraestructura obstruyen el paso del aire y generan turbulencia. El estudio de este comportamiento se realiza mediante el registro secuencial de la velocidad del viento, estructurando la información en series de tiempo. La naturaleza de estas variaciones locales limita la capacidad de los métodos estadísticos tradicionales para calcular con precisión la dinámica futura del flujo de aire. La Inteligencia Artificial surge como una solución necesaria ante esta limitante. La implementación de algoritmos diseñados específicamente para el aprendizaje de datos temporales permite identificar patrones climáticos que son imperceptibles mediante el análisis convencional. Las compuertas internas de estas redes neuronales resultan esenciales en este proceso al actuar como filtros inteligentes de información. El mecanismo de dichas compuertas decide qué datos del viento pasado deben recordarse para el pronóstico y qué variaciones abruptas deben descartarse por ser simple ruido o turbulencia. La integración de la inteligencia artificial con las series de tiempo constituye la herramienta central de esta investigación, proporcionando la exactitud requerida en el pronóstico del viento urbano para evaluar objetivamente su viabilidad en la generación de energía limpia.

2.3 Métricas de evaluación

La evaluación del desempeño predictivo de los modelos de aprendizaje automático requiere el uso de métricas estadísticas que cuantifiquen la discrepancia entre los valores pronosticados por el algoritmo y las observaciones reales del viento. Para este propósito, se definen matemáticamente los indicadores de error que permitirán validar la precisión de la red neuronal.

Error Cuadrático Medio (MSE)

El Error Cuadrático Medio (MSE, por sus siglas en inglés) se define como el promedio de las diferencias individuales al cuadrado entre los valores predichos y los valores observados. Esta métrica penaliza de forma cuadrática los errores de gran magnitud, característica fundamental en el pronóstico eólico para detectar y ajustar ráfagas atípicas mal calculadas por el modelo. Su representación se expresa en la Ecuación:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

Donde n representa el número total de observaciones en la serie de tiempo, y_i es el valor real de la velocidad del viento, y $\hat{y}_i$ es el valor pronosticado por el modelo computacional.

Error Absoluto Medio (MAE)

El Error Absoluto Medio (MAE, por sus siglas en inglés) se define como el promedio de las diferencias absolutas entre las predicciones y las observaciones. A diferencia del MSE, esta métrica proporciona una medición lineal y una interpretación directa del error en las mismas unidades de la variable de estudio (metros por segundo), evaluando la precisión general del modelo sin magnificar el impacto de los valores extremos, tal como se describe en la Ecuación:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

Raíz del Error Cuadrático Medio (RMSE)

La Raíz del Error Cuadrático Medio (RMSE, por sus siglas en inglés) se define como la raíz cuadrada del promedio de los errores cuadráticos. Matemáticamente, esta métrica conserva la penalización a las desviaciones extremas establecida por el MSE, pero aporta la ventaja analítica de reportar el margen de error en las mismas unidades físicas de la variable original (metros por segundo). Esta característica facilita la interpretación directa de la precisión del pronóstico eólico, según se describe en la Ecuación:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Error Porcentual

El Error Porcentual se define como la diferencia relativa entre el valor pronosticado y el valor observado, expresada como una fracción de este último. Esta métrica adimensional permite evaluar la magnitud y la dirección de la desviación en un punto específico de la serie de tiempo. La conservación del signo matemático permite que el Error Porcentual determine si el algoritmo tiende a sobreestimar (valores positivos) o subestimar (valores negativos) la velocidad real del viento, de acuerdo con la Ecuación:

$$Precisión = 100\% - MAPE$$

Error Porcentual Absoluto Medio (MAPE)

El Error Porcentual Absoluto Medio (MAPE, por sus siglas en inglés) representa el promedio general de las desviaciones porcentuales absolutas a lo largo de toda la secuencia de datos. Este índice constituye un indicador fundamental para la validación algorítmica, ya que proporciona una medida global del rendimiento del modelo en términos de porcentaje. Esta estandarización permite comparar la precisión de la red LSTM frente a otras arquitecturas predictivas, independientemente de la escala de medición o la magnitud del viento, como se formaliza en la Ecuación:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

La presente investigación emplea estas métricas estadísticas como una herramienta directa para evaluar los resultados, estableciendo un criterio para seleccionar el diseño predictivo con mayor precisión. Los valores obtenidos permitirán cuantificar el desempeño del modelo estadístico tradicional (ARIMA) frente a la arquitectura de aprendizaje profundo propuesta (LSTM). El

análisis detallado de su comportamiento en los siguientes capítulos determinará cuál de las arquitecturas es la indicada para procesar los datos de este entorno urbano. La aplicación simultánea de diversas métricas permite identificar si el sistema predictivo presenta desviaciones constantes o si el margen de error incrementa exclusivamente durante las ráfagas extremas. Esta evaluación cuantitativa constituye la evidencia matemática que demostrará la confiabilidad de la Inteligencia Artificial en el pronóstico del viento urbano, respaldando la viabilidad técnica para la futura instalación de aerogeneradores.

Capítulo 3. Estado del arte

Capítulo 3. Estado del arte

El estado del arte clasifica el pronóstico de la velocidad del viento como el elemento principal en la gestión de energías renovables. Las variaciones continuas del recurso eólico nos obligan a la transición de estimaciones físicas de formas tradicionales hacia modelos matemáticos y computacionales. La literatura divide estos enfoques metodológicos en tres categorías principales.

- **Pronóstico de velocidad del viento basado en algoritmos ARIMA:** Esta categoría agrupa trabajos de modelos estadísticos tradicionales, utilizado habitualmente como línea base de rendimiento.
- **Pronóstico de velocidad del viento basado en algoritmos con redes neuronales:** Esta clasificación abarca los estudios impulsados por datos que emplean inteligencia artificial, diseñados para procesar la no linealidad de las series eólicas.
- **Pronóstico de velocidad del viento basado en métodos híbridos:** Esta sección contiene trabajos que combinan técnicas de modelos de preprocesamiento de señales con modelos estadísticos o de inteligencia artificial.

El análisis de estas investigaciones describe de manera general los objetivos planteados, las estrategias metodológicas implementadas y los principales hallazgos en el ámbito del pronóstico eólico.

3.1 Pronóstico de velocidad del viento basado en algoritmos ARIMA

La presente sección agrupa las investigaciones de la metodología clásica para el análisis de series temporales. La estructura de los modelos ARIMA define la relación lineal entre las observaciones pasadas y futuras para generar un pronóstico que sea continuo (Box y Jenkins, 1970). La aplicación de estos algoritmos en la evaluación del recurso eólico urbano depende de la estacionariedad de los datos. Esta característica motiva el análisis de los siguientes trabajos, los cuales documentan la eficacia y las restricciones de la estadística tradicional frente a la inestabilidad meteorológica.

Pronóstico de la velocidad del viento a corto plazo utilizando el modelo ARIMA

En el trabajo de investigación de Grigonytė y Butkevičiūtė (2016) se evaluó el desempeño del método ARIMA para predicciones a corto plazo bajo condiciones meteorológicas estables. El análisis empleó registros horarios de viento en Letonia para evaluar periodos de un mes, dos semanas y tres días. Los resultados obtenidos de este trabajo, evaluados con los indicadores MAPE, RMSE y MAE (alcanzando en invierno un RMSE de 1.6227 y un MAE de 1.2293 a dos horas), tuvieron una pérdida de precisión durante la transición de las estaciones de invierno a la primavera, donde la inexactitud empeoró en un 43 % y el MAE aumentó en aproximadamente 1 m/s. Las fluctuaciones repentinas alteraron el patrón del viento, superando la capacidad de adaptación de la fórmula estadística tradicional. La conclusión de este estudio establece la necesidad de implementar modelos híbridos para poder procesar estas series temporales.

ARIMA frente a redes neuronales para el pronóstico de la velocidad del viento

En el trabajo de investigación de Palomares-Salas et al. (2009) se comparó el rendimiento del modelo estadístico ARIMA frente a redes neuronales, demostrando en el estudio que ARIMA requiere tiempos de procesamiento menores para mantener la precisión en intervalos cortos. La metodología procesó los historiales de datos provenientes de Andalucía, España, mediante intervalos operativos de 10 minutos, para evaluar las diferentes estructuras estadísticas como, por ejemplo: ARIMA (2,0,0), ARIMA (2,2,0) y ARIMA (0,2,1). El cálculo de las métricas de error reveló un desempeño superior de ARIMA en los intervalos temporales más reducidos; específicamente, el modelo ARIMA (2,0,0) alcanzó un RMSE de 0.57, un coeficiente de correlación de 0.97 y un Índice de Acuerdo de 0.98 para un horizonte de 10 minutos. Esta baja latencia posiciona a los modelos autorregresivos como una herramienta útil para los sistemas de control.

Pronóstico de la velocidad y dirección del viento para la generación de energía eólica mediante el modelo ARIMA

La investigación presentada por (Yatiana et al., s.f.) implementó el algoritmo ARIMA para predecir la velocidad del viento en parques eólicos, alcanzando márgenes de error menores al 5%. El objetivo principal de este trabajo consistió en predecir simultáneamente la velocidad y la

dirección del viento. Esta predicción dual busca poder incrementar la confiabilidad técnica de los sistemas y facilitar la programación de suministro a la red eléctrica. La metodología abarcó la recopilación de datos durante varios días, su promedio estadístico y el cálculo de parámetros autorregresivos mediante un análisis de correlación. La comparación entre las proyecciones del modelo y los registros reales demostraron márgenes de errores menores al 16% en el pronóstico de la dirección del viento.

Modelado de series temporales de la velocidad del viento basado en ARIMA con descomposición de frecuencia

El estudio desarrollado por (Yunus et al. 2016) integró técnicas de descomposición de frecuencias en un modelo ARIMA para simular historiales climáticos en zonas marítimas carentes de sensores físicos. La escasez de instrumentación en estas áreas motivó el desarrollo de un procedimiento para separar la serie de datos en componentes de alta y baja frecuencia previo a la etapa de modelado. La validación de esta metodología utilizó los datos recolectados durante un año continuo en el Mar Báltico. La arquitectura del modelo empleó la configuración ARIMA (6,0,0) para mapear las dinámicas de alta frecuencia y la configuración ARIMA (0,1,6) para procesar las variaciones de baja frecuencia.

Pronóstico de la velocidad del viento con un día de anticipación utilizando modelos f-ARIMA

El trabajo de investigación de Kavasseri y Seetharaman (2009) implementó el algoritmo ARIMA fraccional (f-ARIMA) reportando una disminución del 42% en el error cuadrático medio. La integración de este modelo propone una mejora en el pronóstico a corto plazo frente a un método estadístico tradicional ARIMA, específicamente en el horizonte de 24 a 48 horas. La justificación teórica que propone el autor radica en la capacidad del modelo f-ARIMA para capturar las correlaciones de largo alcance presentes en la dinámica climática. La metodología procesó los historiales provenientes de cuatro ubicaciones geográficas en Dakota mediante el ajuste de los parámetros de integración matemática con valores fraccionados.

Modelado de la velocidad del viento mediante procesos ARIMA anidados

El estudio publicado por Sim et al. (2019) evaluó un modelo ARIMA anidado que fue capaz de predecir ráfagas extremas e incrementos abruptos en intervalos de 15 minutos. La naturaleza asimétrica del viento, comúnmente modelada bajo la distribución de Weibull, causó la recolección de registros provenientes de la plataforma marítima FINO1 durante 20 meses continuos. El preprocesamiento de esta base de datos aplicó una transformación matemática paramétrica para forzar el ajuste de las mediciones hacia una curva de distribución normal, facilitando la etapa de evaluación estadística.

Pronóstico de la velocidad del viento marino a corto plazo mediante SARIMA: una comparación frente a GRU y LSTM

El estudio presentado por Liu et al. (s.f.) comparó el rendimiento del modelo estadístico SARIMA frente a las arquitecturas profundas LSTM y GRU en entornos marinos, reportando una disminución del sobreajuste computacional. El objetivo de la investigación consistió en construir un Modelo Autorregresivo Integrado de Media Móvil Estacional (SARIMA) parametrizado para las condiciones aerodinámicas de las zonas marinas (offshore). La metodología aplicó una técnica de búsqueda en rejilla (grid search) sobre registros meteorológicos históricos de Escocia para determinar la configuración paramétrica. El análisis de resultados demostró que SARIMA obtuvo mejores métricas de precisión en comparación con los modelos de inteligencia artificial evaluados. Las arquitecturas LSTM experimentaron un sobreajuste al intentar mapear el ruido en secuencias temporales cortas.

3.2 Pronóstico de velocidad del viento basado en algoritmos con redes neuronales

La presente sección agrupa los estudios de investigación orientados hacia enfoques de pronóstico basados en redes neuronales. La arquitectura de estos algoritmos, a diferencia de los modelos tradicionales, omite la suposición de una tendencia lineal en los datos. La estructura matemática de estas redes neuronales opera bajo el principio de aproximadores de funciones universales. Esta característica permite el mapeo de las relaciones complejas, no lineales y

multidimensionales en entornos urbanos. El proceso de entrenamiento computacional extrae patrones ocultos del recurso eólico directamente de los registros históricos.

Pronóstico del viento mediante redes neuronales

El estudio publicado por More y Deo (2003) reportó que las Redes Neuronales redujeron el error a un rango de 4.3% a 6.3% en entornos costeros, obteniendo un rendimiento superior al modelo ARIMA. El objetivo de esta investigación consistió en evaluar el desempeño de la Inteligencia artificial para identificar dinámicas del viento sin el uso de ecuaciones físicas de fluidos. La metodología analizó los registros históricos recopilados durante 12 años en la India. El diseño experimental integró el entrenamiento de algoritmos recurrentes y prealimentados mediante técnicas de minimización de error, específicamente la retropropagación y de correlación. La conclusión principal establece que el cálculo impulsado por datos (data-driven) resulta ser mejor frente al modelado físico termodinámico convencional para la predicción de ráfagas en la costa.

Pronóstico de la velocidad y dirección del viento mediante redes neuronales artificiales

El trabajo de investigación desarrollado por Pino Diez et al. (s.f.) implementó la Teoría de la Resonancia Adaptativa (ART) para la depuración de datos climáticos, reportando un incremento del 30 % en la exactitud de las redes neuronales frente a la estadística tradicional. El propósito de este estudio orientó su aplicación hacia la optimización de la generación de energía eólica en parques generadores mediante una comparativa directa con el modelo ARIMA. El diseño metodológico enfocó el análisis en la fase de preprocesamiento de la información. Los investigadores aplicaron el algoritmo ART como un filtro de clasificación para seleccionar patrones de viento representativos y eliminar el ruido de los sensores previo a la etapa de entrenamiento. La evaluación del sistema alcanzó un alto rendimiento predictivo. La retención de información permite al algoritmo asimilar las ráfagas extremas sin la dilución estadística originada por los largos periodos de calma atmosférica.

Análisis comparativo de los modelos predictivos ARIMA y LSTM y su eficacia para el pronóstico de la velocidad del viento

El estudio desarrollado por Elsaraiti y Merabet (2021) comparó el rendimiento de la arquitectura profunda LSTM frente a un modelo tradicional ARIMA demostrando la capacidad de las compuertas de los modelos LSTM para procesar la no linealidad del clima urbano. El objetivo principal de esta investigación consistió en evaluar ambas metodologías bajo condiciones operativas idénticas. La metodología empleó registros históricos de viento muestreados a intervalos de una hora en la región de Halifax para el entrenamiento de los algoritmos. La evaluación del desempeño algorítmico mediante las métricas de error RMSE y MAE demostró un rendimiento superior de la red LSTM.

Pronóstico de la velocidad y potencia del viento a largo plazo utilizando modelos de redes neuronales recurrentes locales

La investigación presentada por Barbounis et al. (2006) evaluó el uso de Redes Neuronales para la generación de pronósticos en horizontes temporales de hasta 72 horas. El propósito de este trabajo consistió en desarrollar modelos orientados a la proyección a largo plazo para superar las limitaciones de la estadística predictiva clásica. El diseño metodológico empleó registros históricos de un parque eólico en Grecia para probar diferentes configuraciones algorítmicas. La arquitectura de estos modelos integra mecanismos de retroalimentación interna para procesar el estado meteorológico previo. El análisis de los resultados determinó que las arquitecturas de retroalimentación local obtienen un mejor desempeño en comparación con la capacidad estática de las redes prealimentadas (feed-forward).

Revisión del pronóstico de la velocidad y potencia del viento con redes neuronales profundas

El artículo publicado por Wang et al. (2021) analizó la capacidad de las arquitecturas de aprendizaje profundo para procesar datos faltantes y mejorar las métricas predictivas de los modelos estadísticos tradicionales. El objetivo de esta investigación consistió en examinar los métodos mediante los cuales las Redes Neuronales Profundas (DNN) resuelven los problemas técnicos del monitoreo meteorológico. La metodología de estos algoritmos se clasifica en cuatro

fases: limpieza de datos, extracción matemática de características, entrenamiento de relaciones y optimización de hiperparámetros. La evaluación de este tipo de arquitecturas como LSTM, GRU y CNN demostró que los algoritmos profundos incrementan la exactitud matemática en comparación con los modelos convencionales. Este tipo de modelos computacionales permite la reconstrucción de los datos faltantes generados por el congelamiento de anemómetros o fallos de telemetría durante condiciones climáticas adversas.

Pronóstico de la velocidad del viento a largo plazo y reconocimiento general de patrones mediante redes neuronales

La investigación desarrollada por Azad et al. (2014) propuso una investigación entre una red NARX y arquitecturas multicapa para proyectar el recurso eólico anual, reportando un error absoluto de 0.6 m/s. El propósito de este trabajo se enfocó en el diseño de un modelo algorítmico capaz de identificar el comportamiento del viento a lo largo de un ciclo anual. El modelo propuesto proporciona métricas de diseño orientadas a la planeación de nuevos parques eólicos. La integración computacional de estos algoritmos disminuyó los márgenes de error en proyecciones temporales a largo plazo.

Revisión de los métodos de pronóstico de la potencia y velocidad del viento con diferentes horizontes temporales

El artículo publicado por Giebel et al. (2011) mostró el desempeño de las redes neuronales artificiales frente a los métodos estadísticos en los horizontes de predicción a corto y mediano plazo. Esta investigación clasificó las estrategias de pronóstico según su horizonte temporal para evaluar su eficacia. El documento revisó más de cien estudios para comparar algoritmos físicos, modelos ARIMA y arquitecturas MLP, RNN y LSTM. La conclusión de este trabajo señala que la no linealidad del recurso eólico disminuye la precisión de los modelos estadísticos tradicionales. El artículo demostró que para el entrenamiento de redes neuronales se requiere la incorporación de variables meteorológicas exógenas, como la temperatura y la presión.

Pronóstico de la velocidad del viento utilizando redes neuronales profundas con selección de características

El trabajo de investigación desarrollado por Liu et al. (2020) implementó variables climáticas mediante Información Mutua (MI) y Autoencoders para reducir el sobreajuste y la carga computacional de las redes LSTM. El diseño algorítmico de este modelo integró técnicas de selección orientadas a descartar los datos meteorológicos redundantes. La metodología empleó un Autoencoder de Reducción de Ruido Apilado (SDAE) para procesar los datos crudos y generar secuencias depuradas como entrada para la red LSTM.

Modelo de predicción de intervalos mediante redes convolucionales temporales para el pronóstico de la velocidad del viento

La investigación publicada por Gan et al. (2020) evaluó el uso de Redes Convolucionales Temporales (TCN, por sus siglas en inglés) para la generación de intervalos de predicción aleatorios. El desarrollo de este modelo calcula un rango paramétrico de probabilidad eólica en lugar de emitir una estimación de un valor que es único. El modelo TCN redujo la amplitud en un 1.78% frente a LSTM, 2.18% frente a GRU, y 8.65% frente a RNN, donde un valor menor indica una mayor calidad. El TCN obtuvo un valor de 0.4311, superando a LSTM (0.4385), GRU (0.4405) y RNN (0.4712). Según los autores, esto representó una mejora del 1.72%, 2.13% y 8.51% sobre LSTM, GRU y RNN, respectivamente.

Predicción de la velocidad del viento utilizando un modelo ARIMA univariado y un modelo NARX multivariado

El estudio desarrollado por Cadenas et al. (2016) comparó el desempeño a corto plazo de una red de inteligencia artificial multivariada NARX frente al modelo estadístico ARIMA. En la evaluación del rendimiento en la estación de La Mata, el modelo NARX obtuvo un MAE de 0.86 y un MSE de 1.35, superando los valores de 0.91 y 1.51 obtenidos por ARIMA, lo que representó una mejora del 5.5% y 10.6% respectivamente. De igual forma, con los datos de Metepec, el modelo NARX alcanzó un MSE de 0.34 frente al 0.44 de ARIMA, logrando mejoras del 2.3% en el MAE y del 12.8% en el MSE. El modelo NARX incorpora variables meteorológicas

adicionales, como la presión barométrica, la temperatura del aire, la dirección del viento y la radiación solar o humedad relativa.

Estudio comparativo de ARIMA y RNN para el pronóstico de la velocidad del viento a corto plazo

El trabajo de investigación de Shivani y Sandhu (s.f.) evaluó el desempeño del algoritmo LSTM frente al modelo ARIMA para la identificación de dependencias temporales y la anticipación de ráfagas de viento en el horizonte temporal a corto plazo. La metodología de este estudio procesó series de datos meteorológicos recolectadas a intervalos horarios de diez minutos. El sector eléctrico optimiza el despacho económico de energía y minimiza la dependencia o el uso de plantas de energía convencionales al contar con un modelo de predicción efectivo.

3.3 Pronóstico de velocidad del viento basado en métodos híbridos

La actual sección agrupa las investigaciones fundamentadas en la implementación de métodos híbridos para el pronóstico del recurso eólico. El teorema matemático de "No Free Lunch" establece que ningún algoritmo individual posee un rendimiento óptimo universal para todas las condiciones meteorológicas (Wolpert & Macready, 1997). Los enfoques híbridos integran metodologías de filtrado y procesamiento de señales con la capacidad predictiva de la inteligencia artificial o la estadística tradicional. La arquitectura combinada de estos sistemas permite la compensación paramétrica de las debilidades operativas de cada modelo individual. La fusión de estas tecnologías proporciona una estructura computacional estable para procesar las ráfagas de viento complejas y la fricción aerodinámica generada en entornos urbanos.

Método ARIMA recursivo basado en EMD para predecir la velocidad del viento en sistemas ferroviarios de alerta de vientos fuertes

El trabajo de investigación desarrollado por Liu et al. (2015) evaluó la implementación del modelo híbrido EMD-ARIMA como un sistema de alerta ferroviaria en tiempo real mediante la reducción de los tiempos de cálculo asociados a las redes neuronales. El diseño de este algoritmo establece parámetros operativos de seguridad para la infraestructura de transporte de alta velocidad. El modelo estadístico ARIMA procesó cada onda de manera individual para generar el

cálculo predictivo final. La evaluación de desempeño analizó el modelo algorítmico en horizontes predictivos de uno, tres y cinco pasos. El modelo híbrido demostró reducir los errores de predicción entre un 50 % y un 83 %.

Modelos de pronóstico de la velocidad del viento utilizando transformadas wavelet, paquetes wavelet, series temporales y redes neuronales artificiales

El estudio publicado por Liu et al. (2013) evaluó el filtrado de turbulencias eólicas mediante la Transformada Wavelet, reportando una reducción del 20 % en el error RMSE de las redes neuronales. El diseño de esta arquitectura combinó técnicas de procesamiento de señales con aprendizaje profundo para disminuir la inestabilidad de predicción de las ráfagas de viento. La metodología descompuso las frecuencias de las fluctuaciones mediante el análisis de paquetes Wavelet para separar el ruido estadístico. La función matemática Wavelet demostró hacer más fácil la captura simultánea del dominio de la frecuencia y su localización exacta en el tiempo.

Pronóstico de la velocidad del viento en tres diferentes regiones de México utilizando un modelo híbrido ARIMA-ANN

La investigación desarrollada por Cadenas y Rivera (2010) implementó un sistema secuencial compuesto por el modelo ARIMA y una red neuronal artificial para incrementar la precisión mediante la corrección de errores estadísticos. El diseño del sistema híbrido contempló la evaluación del algoritmo en tres regiones de la orografía mexicana: Isla de Cedros, Cerro de la Virgen y Holbox. La arquitectura del modelo trabajó bajo el principio matemático del modelado de residuos. Esta técnica teórica asume que una serie de tiempo contiene un componente lineal y un componente no lineal. El primer modelo matemático calcula la tendencia principal de los datos. El segundo algoritmo procesa exclusivamente las diferencias o errores resultantes de esa primera predicción. La evaluación estadística del sistema demostró que los modelos híbridos predicen las velocidades del viento con mayor exactitud que los modelos ARIMA y ANN operando por separado en los tres sitios examinados. El análisis comparativo de la región de Holbox registró el hallazgo cuantitativo más notable, donde la arquitectura híbrida minimizó el Error Cuadrático Medio (MSE) a un valor de 0.0089, en contraste con los errores de 0.6457 y 0.7687 obtenidos por los métodos analíticos individuales.

Comparación de dos nuevos métodos híbridos ARIMA-ANN y ARIMA-Kalman para la predicción de la velocidad del viento

El trabajo de investigación desarrollado por Liu et al. (2012) evaluó el rendimiento de dos estrategias híbridas, demostrando que la integración algorítmica de ARIMA y el Filtro de Kalman disminuyó los márgenes de error MAE y MSE en un 68.04 % y 69.08 % respectivamente para predicciones de un paso en comparación con el modelo estadístico individual. La metodología experimental procesó las series de datos no estacionarios provenientes de los anemómetros de un parque eólico ubicado en China. El diseño del primer modelo híbrido utilizó ARIMA para determinar la estructura de los parámetros de la red neuronal artificial y la configuración del segundo enfoque empleó el modelo ARIMA para inicializar las ecuaciones de estado y de medición del Filtro de Kalman. El análisis comparativo de los resultados demostró que la arquitectura ARIMA-Kalman posee un rendimiento predictivo superior al del modelo ARIMA-ANN.

Un modelo híbrido para el pronóstico de la velocidad del viento y la generación de energía eólica

El estudio publicado por Chang et al. (s.f.) propuso una arquitectura en serie compuesta por un modelo ARIMA y una Red Neuronal de Función de Base Radial (RBFNN, por sus siglas en inglés), reportando una reducción del error porcentual (MAPE) al 2.365 %. El objetivo de esta investigación consistió en desarrollar un modelo secuencial para reducir las fluctuaciones de la velocidad del viento. La etapa inicial de la metodología procesó los datos eólicos con el algoritmo ARIMA para modelar y extraer la tendencia lineal de la serie temporal. El componente no lineal funcionó posteriormente como dato de entrada para la arquitectura RBFNN. La capacidad predictiva de este sistema híbrido depende de las funciones de activación gaussianas dentro de la red.

Mejoras en los pronósticos de la velocidad del viento para fines de predicción de energía eólica mediante el filtro de Kalman

El estudio publicado por Louka et al. (2008) evaluó la aplicación del Filtro de Kalman como un método de post-procesamiento en predicciones numéricas del clima para la eliminación de errores

sistemáticos de una red neuronal difusa. El objetivo de este artículo consistió en mitigar el sesgo estadístico presente en los pronósticos de la velocidad del viento generados por los Modelos de Predicción Meteorológica Numérica (NWP). La metodología implementó un algoritmo de Kalman para procesar y corregir las salidas de los modelos atmosféricos. El Filtro de Kalman corrige la asimetría de los datos meteorológicos previos a la etapa de aprendizaje computacional.

Modelos autorregresivos lineales y no lineales para el pronóstico de la velocidad del viento a corto plazo

El estudio publicado por Lydia et al. (2016) evaluó la conexión de técnicas analíticas de minería de datos con modelos estadísticos ARMAX para el pronóstico de la velocidad del viento a corto plazo. El objetivo de la investigación consistió en generar predicciones en intervalos de diez minutos hasta alcanzar un horizonte temporal de una hora. La validación experimental procesó registros meteorológicos provenientes de estaciones ubicadas en España e India. El diseño del sistema evaluó la integración de múltiples variables exógenas, concluyendo que la dirección del viento proporciona la mayor precisión predictiva, en contraste con el bajo rendimiento aportado por los parámetros de temperatura y radiación solar.

Pronóstico inteligente multipaso de la velocidad del viento basado en aprendizaje profundo

El trabajo de investigación desarrollado por Liu et al. (2019) propuso un modelo híbrido de predicción a corto plazo conformado por el Análisis de Espectro Singular (SSA, por sus siglas en inglés), una red convolucional-recurrente (CNNGRU, por sus siglas en inglés) y la Regresión de Vectores de Soporte (SVR, por sus siglas en inglés). El diseño de esta arquitectura secuencial procesa las características intermitentes y fluctuantes de la velocidad del viento. La primera etapa empleó el algoritmo SSA para descomponer la serie de tiempo en un componente de tendencia principal y múltiples componentes de detalle. La segunda fase implementó la red profunda CNNGRU para calcular el pronóstico del componente de tendencia. Las capas convolucionales (CNN) del algoritmo extraen las características ocultas de los datos para transferir la información hacia las unidades recurrentes (GRU). La unión de estos tres algoritmos registró un tiempo de ejecución computacional menor a los tres minutos durante las pruebas experimentales.

Pronóstico de la velocidad del viento mediante un ensamble de aprendizaje no lineal de predicción de series temporales de aprendizaje profundo y optimización extrema

El estudio publicado por Chen et al. (2018) propuso un nuevo modelo (EnsemLSTM). El objetivo de esta investigación consistió en desarrollar un sistema predictivo para compensar la débil capacidad de generalización y robustez de los aprendizajes profundos individuales. La arquitectura del modelo integró un clúster de múltiples redes LSTM configuradas con diversas capas ocultas y neuronas para procesar la información de las series temporales de la velocidad del viento. El diseño experimental validó el sistema utilizando registros meteorológicos provenientes de un parque eólico ubicado en Mongolia Interior, China, para generar pronósticos en horizontes de diez minutos y una hora. El análisis del primer caso de estudio, correspondiente a la predicción a diez minutos, registró para el modelo EnsemLSTM un Error Absoluto Medio (MAE) de 0.5746, un Error Cuadrático Medio (RMSE) de 0.7552 y un Error Porcentual Absoluto Medio (MAPE) de 5.4167 %. La evaluación del segundo escenario, enfocado en la predicción a una hora, reportó un MAE de 1.1410, un RMSE de 1.5335 y un MAPE de 17.1076 %.

Pronóstico de la velocidad del viento a mediano plazo mediante modelos híbridos en Xinjiang, China

El estudio desarrollado por Wang et al. (2015) presentó un método predictivo a mediano plazo fundamentado en el ajuste estacional para optimizar el rendimiento de las Redes Neuronales Recurrentes de Elman (ERNN, por sus siglas en ingles). El objetivo de esta investigación consistió en desarrollar modelos de predicción para la operación y planificación de granjas eólicas ubicadas en tres sitios diferentes de la región de Xinjiang, China. La arquitectura de la red ERNN utilizó unidades de contexto para procesar los componentes de tendencia aislados y modelar las características dinámicas del viento. Las evaluaciones experimentales demostraron que los modelos híbridos registraron promedios de Error Absoluto Medio (MAE) de 1.1080 y 1.1374, Error Cuadrático Medio (MSE) de 1.9362 y 1.9978, y Error Porcentual Absoluto Medio (MAPE) de 15.3227 % y 15.5311 % respectivamente. Estos resultados superan la exactitud de la red ERNN convencional, la cual promedió un MAE de 1.9249, un MSE de 5.8833 y un MAPE de 26.1570 % al operar sin técnicas de preprocesamiento de datos.

Pronóstico diario de la velocidad del viento mediante un modelo híbrido KF-ANN basado en ARIMA

El estudio desarrollado por Shukur y Lee (2015) propuso un modelo híbrido estructurado mediante el algoritmo ARIMA, el Filtro de Kalman y una Red Neuronal Artificial para el pronóstico de la velocidad diaria del viento. El objetivo de esta investigación consistió en desarrollar una arquitectura secuencial para procesar la no linealidad y la incertidumbre de los registros eólicos. La metodología implementó inicialmente el modelo ARIMA para determinar la estructura de las variables de entrada requeridas. El diseño experimental validó el sistema utilizando series de datos meteorológicos provenientes de Irak y Malasia. El análisis de la fase de prueba en la región de Irak registró un Error Porcentual Absoluto Medio (MAPE) de 137.51 % para el modelo ARIMA, 118.25 % para la red ANN, 43.95 % para el ensamble ARIMA-KF y 36.17 % para el modelo híbrido completo KF-ANN. La evaluación estadística en la región de Malasia reportó índices MAPE de 19.27 %, 18.17 %, 17.20 % y 11.29 % para las mismas configuraciones, respectivamente.

3.4 Conclusiones del estado del arte

La conclusión del estado del arte determinó que los modelos de aprendizaje profundo, particularmente las arquitecturas LSTM y los métodos híbridos, superaron a las técnicas estadísticas tradicionales en la predicción de series temporales de viento urbano. La revisión de estos estudios demostró que la transición hacia enfoques *data-driven* permitió procesar de mejor manera la variabilidad y la naturaleza estocástica del microclima, resolviendo las limitaciones lineales de algoritmos clásicos como ARIMA al descubrir patrones secuenciales ocultos.

La implementación de estas arquitecturas, que en diversos trabajos integraron filtros de reducción de ruido y descomposiciones de frecuencia, facilitó la extracción de conocimiento útil frente a series meteorológicas inestables. Las investigaciones analizadas evidenciaron que el uso de ANN y modelos híbridos contribuyó a la reducción de las métricas de error, destacando mejoras en el RMSE y el MAE. El análisis de los datos demostró que los modelos de redes (como LSTM) y las aproximaciones híbridas resultaron ser una mejor opción para el pronóstico de estos horizontes a corto, mediano y largo plazo en entornos urbanos.

La revisión de la literatura justificó el uso de las Redes Neuronales Recurrentes para esta investigación. El análisis de los datos demostró que estos modelos de inteligencia artificial tienen capacidades técnicas para trabajar con grandes volúmenes de datos, los cuales resultan ser más útiles para el pronóstico de las series temporales de la velocidad del viento en entornos urbanos.

Capítulo 4. Modelo de pronóstico propuesto

Capítulo 4. Modelo de pronóstico propuesto

La metodología empleada para pronosticar la velocidad del viento permitió desarrollar un modelo basado en redes LSTM a partir de la selección de variables meteorológicas relevantes. En este capítulo se describieron las etapas llevadas a cabo, descritas en cuatro fases principales: primero, la construcción del conjunto de datos (que abarca la recolección y organización de datos, y el preprocesamiento de datos); segundo, el desarrollo y entrenamiento de modelos (incluyendo el entrenamiento de modelos de Redes Neuronales Recurrentes y el ajuste de hiperparámetros); tercero, la selección y validación del modelo final (compuesta por la selección del modelo final y la validación del modelo final); y por último, el análisis comparativo y presentación de resultados (donde se integran la evaluación de precisión, las pruebas de desempeño, y la comparación y análisis de modelos).

4.1 Introducción a la metodología

La metodología implementada para el desarrollo del modelo de pronóstico se organizó en cuatro fases principales, como se muestra en la Figura 4.1. Las fases señaladas abarcan desde la construcción del conjunto de datos hasta la presentación de los resultados.

Metodología de solución




Figura 4.1 Metodología implementada para el desarrollo del modelo de pronóstico de la velocidad del viento

4.2 Fase 1: Construcción del conjunto de datos

En esta fase se recopilaron y analizaron datos históricos provenientes de distintas estaciones meteorológicas del Valle de México y de algunas zonas de la Ciudad de México. A partir de la revisión de los registros de velocidad del viento disponibles, se seleccionó el municipio de Nezahualcóyotl para realizar el estudio. Después, los datos fueron preparados mediante la eliminación o corrección de valores faltantes, la revisión de valores atípicos y la normalización de las variables consideradas. Finalmente, la información se dividió en conjuntos de entrenamiento y prueba, los cuales se utilizaron para el desarrollo y evaluación del modelo predictivo.

Recolección y selección de datos

La recolección y selección de datos se realizó a partir de los registros meteorológicos disponibles en la Red Automática de Monitoreo Atmosférico (RAMA). La información fue obtenida mediante el portal oficial de calidad del aire de la Ciudad de México (Figura 4.2), el cual proporciona acceso a archivos históricos con mediciones horarias de variables meteorológicas y otros parámetros ambientales. La decisión de utilizar esta fuente se tomó debido a que ofrece registros obtenidos por estaciones ubicadas en la zona de interés, lo que permitió trabajar con información asociada a las condiciones observadas localmente. El origen de estos datos se consideró más adecuado para los objetivos del presente estudio que el uso de bases de datos derivadas de modelos de reanálisis.




Figura 4.2 Interfaz del portal de la RAMA donde se obtuvieron los datos.

La selección de la estación de monitoreo más adecuada para el estudio se realizó analizando los registros disponibles de 72 estaciones de la red. La Figura 4.3 muestra la revisión de la cantidad de datos faltantes en cada una de ellas con el fin de evaluar su disponibilidad de información. El límite de 20 % de valores nulos se estableció como criterio de selección y, con base en este análisis, se eligió la estación NEZWPS, ubicada en Nezahualcóyotl, ya que registró un 7.60 % de datos faltantes en la variable de velocidad del viento durante el periodo considerado.




Figura 4.3 Cantidad de datos faltantes por estación de monitoreo (ordenado de mayor a menor completitud).

Para definir las variables de entrada del modelo, se analizó la correlación entre los distintos parámetros meteorológicos disponibles en la base de datos de Nezahualcóyotl. Como se muestra en la Figura 4.4, la temperatura y la humedad relativa presentaron una relación inversa importante. Considerando este comportamiento, se optó por trabajar únicamente con la velocidad del viento y la temperatura, dejando fuera la humedad relativa. De esta manera, se buscó evitar el uso de variables con información similar y simplificar el conjunto de datos empleado durante el entrenamiento del modelo.




Figura 4.4 Matriz de correlación entre variables meteorológicas

El análisis inicial revisó la información recopilada en la estación de Nezahualcóyotl, la cual estuvo conformada por 8,776 registros horarios. La Tabla 4.1 detalla los datos faltantes identificados en algunas de las variables analizadas durante esta revisión. La velocidad del viento presentó 670 valores nulos, mientras que la temperatura registró 145 valores faltantes. El conocimiento de estas características del conjunto de datos permitió definir las actividades de preprocesamiento necesarias antes de utilizar la información para el entrenamiento del modelo.

Tabla 4.1 Análisis inicial del conjunto de datos meteorológicos

Variable	Total de registros	Datos faltantes (NA)	Porcentaje de datos faltantes
Fecha	8,776	0	0.00%
Hora	8,776	0	0.00%
Velocidad del viento (m/s)	8,776	670	7.63%
Temperatura (°C)	8,776	145	1.65%

Después de completar la selección de variables y la revisión de los registros disponibles, se conformó una base de datos con 8,776 observaciones horarias de velocidad del viento y temperatura. Esta información se utilizó para las etapas de preprocesamiento y entrenamiento del modelo LSTM. De esta manera, el desarrollo del modelo se llevó a cabo utilizando los datos obtenidos de la estación seleccionada y las variables definidas durante el análisis previo.

Preprocesamiento y Análisis Exploratorio de la Serie Temporal Cruda

El Preprocesamiento y Análisis Exploratorio de la Serie Temporal Cruda identificó 670 registros con valores nulos (NA) en las variables meteorológicas analizadas. La presencia de estos datos faltantes hizo necesario aplicar un proceso de preprocesamiento antes de utilizar la información para el entrenamiento de la red LSTM. Debido a que este tipo de modelos emplea secuencias temporales para aprender patrones en los datos, se consideró conveniente tratar los registros incompletos previamente, con el fin de trabajar con una base de datos más adecuada para las etapas posteriores del análisis.

Durante el proceso de limpieza de la información se encontraron varios registros con el valor -99 en la base de datos de la estación Nezahualcóyotl. Este valor fue considerado como un dato no disponible, por lo que se reemplazó por valores nulos (NaN o NA) en las variables de velocidad del viento y temperatura. Este procedimiento permitió identificar con mayor claridad los datos faltantes presentes en la serie temporal. Posteriormente, dichos registros fueron tratados mediante las técnicas de imputación definidas para el estudio antes de utilizar la información en el entrenamiento del modelo.

Después del proceso de depuración de los datos, se realizó un análisis descriptivo de la velocidad del viento, debido a que esta variable constituye el principal objeto de estudio. Los cálculos estadísticos, como se observa en la Tabla 4.2, mostraron que el primer cuartil (Q1) fue de 1.40 m/s, la mediana (Q2) de 2.10 m/s y el tercer cuartil (Q3) de 3.10 m/s. A partir de estos valores puede observarse que la mayor parte de los registros se concentra en velocidades relativamente bajas. Además, tres cuartas partes de las mediciones registradas durante el periodo de estudio presentaron velocidades inferiores a 3.10 m/s.

Tabla 4.2 Resumen estadístico de la velocidad del viento.

Métrica estadística	Valor (m/s)	Descripción física
Mínimo	0.10 m/s	Límite inferior registrado (Calma casi absoluta)
Primer Cuartil (Q1)	1.40 m/s	El 25 % de los datos es menor a este valor
Mediana (Q2)	2.10 m/s	Punto medio de la distribución de velocidades
Media (Promedio)	2.37 m/s	Promedio aritmético general de la serie temporal
Tercer Cuartil (Q3)	3.10 m/s	El 75 % de los datos es menor a este valor
Desviación Estándar	± 1.33 m/s	Margen de dispersión y volatilidad del viento
Máximo	8.40 m/s	Ráfaga más fuerte registrada (Valor atípico legítimo)

Para conocer mejor el comportamiento de la velocidad del viento, se utilizaron diagramas de caja (boxplots), los cuales permitieron identificar valores alejados de la distribución principal de los datos. La velocidad media registrada fue de 2.37 m/s, con una desviación estándar de ± 1.33 m/s, mientras que la velocidad máxima alcanzó los 8.40 m/s. Debido a la presencia de estos valores extremos, se realizó una revisión de su comportamiento dentro de la serie temporal y se consideraron durante las etapas de preprocesamiento previas al entrenamiento de la red neuronal.

La información obtenida durante el análisis descriptivo permitió definir la estrategia de preprocesamiento utilizada en este trabajo. Considerando las características observadas en la serie temporal, se decidió conservar los valores extremos identificados y aplicar métodos de imputación para tratar los datos faltantes, en lugar de eliminar los registros incompletos. Una vez realizado este procedimiento, se obtuvo una base de datos continua que fue utilizada en el entrenamiento de la red LSTM, empleando la velocidad del viento como variable principal y la temperatura como variable de apoyo.

La gráfica de la serie temporal de velocidad del viento para todo el año 2024, mostrada en la Figura 4.5, permitió observar la existencia de datos faltantes distribuidos en diferentes momentos del periodo analizado. Los registros aparecen como interrupciones dentro de la secuencia de datos. El modelo LSTM trabaja con información ordenada temporalmente, por lo que se decidió aplicar un tratamiento a los valores faltantes para mantener la estructura de la serie. Las técnicas de imputación se utilizaron por esta razón, en lugar de eliminar los registros incompletos de forma directa.




Figura 4.5 Serie Temporal de la Velocidad del Viento con Datos Crudos.

El acercamiento a distintas secciones de la serie temporal, mostrado en la Figura 4.6, se realizó para examinar con mayor detalle los datos faltantes. Las gráficas permitieron observar espacios sin registros entre algunas mediciones, lo que evidenció la presencia de interrupciones en la información disponible. Las características observadas motivaron la decisión de aplicar un método de reconstrucción de datos antes de utilizar la serie en el entrenamiento de la red LSTM. El procedimiento buscó completar los registros faltantes y mantener la estructura general de la serie temporal para las etapas posteriores del análisis.




Figura 4.6 Análisis detallado de las discontinuidades / Zoom de la Serie Temporal Cruda

Reconstrucción de datos mediante interpolación lineal y ruido controlado

La reconstrucción de datos mediante interpolación lineal y ruido controlado se utilizó para tratar los datos faltantes mediante un método combinado con ruido gaussiano. Se decidió trabajar con esta estrategia en lugar de eliminar los registros incompletos, ya que permitía conservar la secuencia temporal de los datos. El procedimiento consistió en estimar los valores faltantes a partir de los registros cercanos y añadir una pequeña variación aleatoria controlada. Una vez aplicado este proceso, se obtuvo una serie temporal completa que pudo utilizarse para el entrenamiento y evaluación del modelo.

Después de aplicar el método de reconstrucción, se realizó una revisión de los segmentos donde originalmente existían datos faltantes. En la Figura 4.7 puede observarse cómo estos espacios fueron completados a partir de la interpolación y el ruido gaussiano utilizados en el proceso. De manera general, la serie reconstruida mantuvo una transición continua entre los registros disponibles, lo que permitió contar con una secuencia completa para las etapas posteriores del entrenamiento del modelo.



Figura 4.7 Zoom de la Serie Temporal reconstruida con interpolación y ruido

Después de completar el proceso de reconstrucción de datos, se revisó nuevamente la serie temporal de velocidad del viento. Como se observa en la Figura 4.8, la información correspondiente a todo el periodo de estudio pudo representarse de manera continua utilizando los 8,776 registros disponibles. En comparación con la serie original, ya no se observaron datos

faltantes en el conjunto utilizado para el análisis. A partir de este punto, se dio por finalizada la etapa de limpieza y se procedió con la normalización de las variables para su uso en el modelo.




Figura 4.8 Serie Temporal de la Velocidad del Viento / Dataset Reconstruido).

Una vez completada la limpieza de los datos, se normalizaron las variables de velocidad del viento y temperatura utilizando el método Min-Max. Con este procedimiento, todos los valores fueron transformados a un rango entre 0 y 1. La normalización se realizó porque ambas variables tenían escalas de medición diferentes, por lo que era conveniente llevarlas a un mismo rango antes de utilizarlas en el modelo. El conjunto de datos normalizado fue el que se empleó posteriormente durante el entrenamiento de la red LSTM.

La base de datos definitiva para el entrenamiento del modelo se obtuvo una vez finalizados los procesos de reconstrucción de datos y normalización. El conjunto, como se resume en la Tabla 4.3, quedó integrado por las variables fecha, hora, velocidad del viento y temperatura, ya que la humedad relativa fue descartada durante la etapa de selección de variables. El trabajo total se realizó con 8,776 registros y no se identificaron valores faltantes en las variables utilizadas. El conjunto de datos resultante sirvió como entrada para las siguientes fases de entrenamiento y evaluación de la red LSTM.

Tabla 4.3 Resumen del conjunto de datos final.

Variable	Total de registros	Datos faltantes (NA)	Porcentaje de datos faltantes	Compleitud de los datos
Fecha	8,776	0	0.00%	100.00%
Hora	8,776	0	0.00%	100.00%
Velocidad del viento (m/s)	8,776	0	0.00%	100.00%
Temperatura (°C)	8,776	0	0.00%	100.00%

Después de finalizar el preprocesamiento de los datos, la información se dividió en conjuntos de entrenamiento y prueba. Para realizar esta separación se mantuvo el orden temporal de los registros, ya que se trabajó con una serie de tiempo. El primer grupo de datos se utilizó para entrenar la red LSTM y ajustar sus parámetros, mientras que el segundo se reservó para evaluar el comportamiento del modelo una vez concluido el entrenamiento. Esta división permitió comparar las predicciones obtenidas con datos que no formaron parte del proceso de aprendizaje.

4.3 Fase 2: Desarrollo y entrenamiento de modelo

La Fase 2, centrada en el desarrollo y entrenamiento de modelos, consideró distintas configuraciones de redes LSTM para analizar las relaciones temporales y las variaciones características de la velocidad del viento. Durante esta etapa, el diseño de la arquitectura computacional incluyó la definición del número de capas ocultas, la cantidad de neuronas y las funciones de activación utilizadas para procesar las secuencias de datos. El proceso de entrenamiento contempló el ajuste gradual de hiperparámetros, tomando en cuenta aspectos como la tasa de aprendizaje, el tamaño de lote y el número de épocas. Como resultado, el modelo fue identificando patrones repetitivos y cambios presentes en el comportamiento del recurso eólico a partir de los datos históricos, sin emplear reglas físicas definidas previamente.

Diseño y configuración de la arquitectura de aprendizaje profundo

La segunda fase metodológica, enfocada en el desarrollo del modelo, dio lugar a una arquitectura basada en Redes Neuronales Recurrentes (LSTM), la cual alcanzó una precisión base del 81.04 %. Esta etapa consideró la evaluación de diferentes configuraciones estructurales para procesar de manera conjunta las secuencias históricas de velocidad del viento y temperatura. El propósito de este diseño consistió en establecer una red capaz de aprovechar la información

disponible y reconocer los patrones no lineales presentes en las ráfagas de viento registradas en la zona urbana de estudio.

El entrenamiento de los modelos base incluyó la comparación entre una arquitectura con estructura tipo embudo y configuraciones de una sola capa. Los resultados obtenidos durante las pruebas iniciales mostraron diferencias en el desempeño de ambos enfoques, donde la configuración de una única capa LSTM presentó limitaciones para la tarea de pronóstico. Por esta razón, se empleó una arquitectura compuesta por dos capas LSTM conectadas de manera secuencial, con 128 neuronas en la primera capa y 64 en la segunda. La organización de esta estructura permitió un procesamiento gradual de la información, donde la salida generada por la primera capa fue utilizada como entrada para la segunda. Posteriormente, la información obtenida se procesó mediante una capa densa de 32 neuronas con función de activación ReLU antes de generar la predicción final.

La configuración de los parámetros de compilación estuvo orientada a favorecer un proceso de entrenamiento estable y a reducir la posibilidad de sobreajuste. Para ello, se utilizó el optimizador Adam y se seleccionó el Error Cuadrático Medio (MSE) como función de pérdida. Además, se incorporó una capa de regularización Dropout con una tasa de 0.2 después de cada bloque LSTM. La inclusión de este mecanismo contribuyó a disminuir la dependencia de ciertas neuronas durante el entrenamiento y favoreció la capacidad del modelo para trabajar con datos que no formaron parte del conjunto de entrenamiento.

El primer experimento de entrenamiento sirvió como referencia inicial para evaluar el desempeño del modelo, alcanzando una precisión del 78.77 % mediante una arquitectura de baja complejidad. El propósito de analizar el comportamiento de una configuración básica en la tarea de pronóstico requirió el uso de una red alimentada únicamente con dos variables de entrada: velocidad del viento y temperatura. La arquitectura estuvo compuesta por una sola capa LSTM de 64 neuronas con función de activación ReLU, conectada directamente a una capa densa de salida. La configuración del entrenamiento incluyó el optimizador Adam, la función de pérdida de Error Cuadrático Medio (MSE) y un total de 20 épocas.

La evaluación del modelo simple permitió identificar algunas limitaciones asociadas al uso de una arquitectura de una sola capa para la tarea de pronóstico. El análisis del conjunto de pruebas

correspondiente al 20 % de los datos determinó que la red obtuvo un Error Porcentual Absoluto Medio (MAPE) de 21.23 % y un Error Absoluto Medio (MAE) de 0.392 m/s, como se detalla en la Tabla 4.4. Los resultados observados en la gráfica de predicción, ilustrada en la Figura 4.9, mostraron un seguimiento aceptable de la tendencia general de la velocidad del viento. Las diferencias entre los valores reales y los estimados se apreciaron claramente en varios de los picos máximos y mínimos de las ráfagas. Las observaciones motivaron la evaluación de arquitecturas con un mayor número de capas en las siguientes etapas del estudio.




Figura 4.9 Comparativa de la Velocidad del Viento Real vs. Predicción del Modelo LSTM Simple.

Tabla 4.4 Métricas de Evaluación del Modelo LSTM Simple.

Métrica	Descripción	Valor
MAE	Error Absoluto Medio	0.392 m/s
RMSE	Raíz del Error Cuadrático Medio	0.530 m/s
MAPE	Error Porcentual Absoluto Medio	21.23%
Precisión	(100 - MAPE)	78.77%

Desarrollo de la arquitectura de aprendizaje profundo

El desarrollo de la arquitectura de aprendizaje profundo en esta etapa resultó en un diseño de red neuronal, ilustrado en la Figura 4.10, que alcanzó una precisión del 81.04 %, con resultados de error detallados en la Tabla 4.5, superior a la obtenida por el modelo de una sola capa evaluado previamente. La red empleada para el análisis del comportamiento del viento en el entorno urbano fue alimentada con dos variables climáticas: velocidad del viento y temperatura, conservando el esquema de entrada correspondiente a las 24 horas anteriores.

Las pruebas realizadas evaluaron diferentes configuraciones de la red. La evaluación consideró inicialmente una arquitectura con 64 neuronas; posteriormente, se implementó una estructura compuesta por dos capas LSTM conectadas de forma secuencial. La primera capa estuvo integrada por 128 neuronas y la segunda por 64, permitiendo un procesamiento gradual de la información generada a partir de las series temporales. Las configuraciones evaluadas utilizaron las mismas variables de entrada, por lo que las diferencias observadas en el desempeño estuvieron asociadas principalmente a la estructura interna de la red.

La configuración seleccionada incorporó una capa de Dropout con una tasa de 0.2 después de cada bloque LSTM. El propósito de este mecanismo fue reducir la dependencia de determinadas conexiones durante el entrenamiento y favorecer la capacidad de generalización del modelo. La información obtenida se procesó posteriormente mediante una capa densa de 32 neuronas con función de activación ReLU antes de generar la predicción final. La compilación del modelo se realizó utilizando el optimizador Adam y la función de pérdida de Error Cuadrático Medio (MSE), considerando un total de 20 épocas de entrenamiento.




Figura 4.10 Comparativa de la Velocidad del Viento Real vs. Predicción del Modelo LSTM final.

Tabla 4.5 Métricas de Evaluación del Modelo LSTM Profundo.

Métrica	Descripción	Valor
MAE	Error Absoluto Medio	0.400 m/s
RMSE	Raíz del Error Cuadrático Medio	0.550 m/s
MAPE	Error Porcentual Absoluto Medio	18.96%
Precisión	(100 - MAPE)	81.04%

Experimentos y optimización de hiperparámetros

El ajuste final de los parámetros incluyó una comparación entre la arquitectura de tipo Embudo Profundo y los modelos generados mediante técnicas de búsqueda automática. Con el propósito de evaluar diferentes alternativas de configuración, se implementó inicialmente un proceso de Optimización Bayesiana capaz de explorar distintas combinaciones de hiperparámetros. Los resultados obtenidos mostraron que algunas de las configuraciones propuestas alcanzaban errores bajos durante el entrenamiento; sin embargo, su desempeño presentó variaciones al ser evaluadas con datos no utilizados en el aprendizaje.

A partir de estas observaciones, el proceso de ajuste se enfocó en la arquitectura de Embudo Profundo, sometiéndola a diferentes escenarios de evaluación mediante la modificación de parámetros como la tasa de Dropout y el número de épocas de entrenamiento. Este procedimiento permitió analizar el comportamiento del modelo ante distintas configuraciones y seleccionar los parámetros que ofrecieron resultados más consistentes durante las pruebas realizadas.

La ejecución de las pruebas, como se muestra en la Figura 4.11, consideró tres configuraciones diferentes con el propósito de analizar el comportamiento del modelo bajo distintas condiciones de entrenamiento. La primera configuración utilizó una tasa de Dropout de 0.3 y un entrenamiento de 10 épocas. La segunda configuración redujo la tasa de Dropout a 0.1 y aumentó el entrenamiento a 15 épocas. La tercera configuración empleó una tasa de Dropout de 0.2 y amplió el entrenamiento a 20 épocas.

Hiperparámetro	Valor Seleccionado
Arquitectura	LSTM Profunda (128→64→32)
Neuronas Capa 1	128
Neuronas Capa 2	64
Neuronas Capa Densa	32 (Activación ReLU)
Tasa de Dropout	0.3
Optimizador	Adam
Épocas / Batch Size	10 / 32
Variables de Entrada	2 (Velocidad, Temperatura)

Hiperparámetro	Valor Seleccionado
Arquitectura	LSTM Profunda (128→64→32)
Neuronas Capa 1	128
Neuronas Capa 2	64
Neuronas Capa Densa	32 (Activación ReLU)
Tasa de Dropout	0.1
Optimizador	Adam
Épocas / Batch Size	15 / 32
Variables de Entrada	2 (Velocidad, Temperatura)

Hiperparámetro	Valor Seleccionado
Arquitectura	LSTM Profunda (128→64→32)
Neuronas Capa 1	128
Neuronas Capa 2	64
Neuronas Capa Densa	32 (Activación ReLU)
Tasa de Dropout	0.2
Optimizador	Adam
Épocas / Batch Size	20 / 32
Variables de Entrada	2 (Velocidad, Temperatura)

Figura 4.11 Comparativa de las 3 configuraciones de Hiperparámetros probadas.

La selección de la configuración final se realizó a partir de los resultados obtenidos en los tres escenarios evaluados durante la etapa experimental. La tercera configuración analizada presentó los resultados más favorables para la tarea de pronóstico. La configuración mencionada, resumida en la Tabla 4.6, utilizó una tasa de Dropout de 0.2, las variables de velocidad del viento y temperatura como entradas, un entrenamiento de 20 épocas y un tamaño de lote (batch size) de 32 muestras.

La arquitectura resultante quedó conformada por dos capas LSTM de 128 y 64 neuronas, seguidas por una capa densa de 32 neuronas. La fase de desarrollo del modelo concluyó con esta configuración definida y dio inicio a la etapa de validación, en la cual su desempeño fue evaluado utilizando datos que no participaron en el proceso de entrenamiento.

Tabla 4.6 Hiperparámetros seleccionados para el Modelo Definitivo.

Hiperparámetro	Valor seleccionado
Arquitectura	LSTM Profunda (128 → 64 → 32)
Neuronas Capa 1	128
Neuronas Capa 2	64
Neuronas Capa Densa	32 (Activación ReLU)
Tasa de Dropout	0.2 (en ambas capas recurrentes)
Optimizador	Adam
Épocas / Batch Size	20 / 32
Variables de Entrada	2 (Velocidad, Temperatura)

4.4 Fase 3: Selección y validación del modelo final

La Fase 3, dedicada a la selección y validación del modelo final, comprendió la evaluación de las arquitecturas entrenadas mediante datos que no participaron en el proceso de aprendizaje. Durante esta etapa se definieron criterios de comparación relacionados con el desempeño del modelo, la estabilidad observada durante el entrenamiento y su comportamiento frente a nuevos conjuntos de datos.

Las pruebas realizadas permitieron comparar distintas configuraciones y analizar sus resultados bajo las mismas condiciones de evaluación. A partir de este proceso, se seleccionó la arquitectura que presentó el comportamiento más consistente entre precisión y capacidad de respuesta ante datos no utilizados durante el entrenamiento. Con ello, se estableció el modelo que sería empleado en las etapas posteriores de validación y análisis de resultados.

Validación de estabilidad y consistencia operativa

La validación técnica del modelo final incluyó la evaluación de su desempeño mediante pruebas repetidas, en las cuales se obtuvo una precisión promedio del 79.77 %. El propósito de esta etapa fue analizar la consistencia de los resultados obtenidos y verificar el comportamiento del modelo bajo diferentes ejecuciones de entrenamiento. El proceso de evaluación incluyó la revisión de la evolución del error durante el entrenamiento y la realización de múltiples corridas independientes de la red. Los resultados obtenidos permitieron observar un comportamiento similar entre las distintas ejecuciones, aportando información adicional sobre la estabilidad del modelo y su desempeño frente a datos utilizados durante la validación.

El análisis de las curvas de aprendizaje permitió observar el comportamiento del error de entrenamiento y del error de validación a lo largo del proceso de entrenamiento. La función de pérdida presentó una tendencia descendente durante las 20 épocas consideradas en el estudio hasta alcanzar valores relativamente estables en las etapas finales. Los resultados mostrados en la gráfica de la Figura 4.12 evidenciaron una diferencia reducida entre las curvas de entrenamiento y validación, sin cambios bruscos que sugirieran problemas importantes de ajuste durante el aprendizaje. Las observaciones indican que el modelo logró mantener un desempeño similar tanto en los datos utilizados para el entrenamiento como en los empleados para la validación.




Figura 4.12 Evolución de la Pérdida del Nuevo Modelo.

La prueba de consistencia operativa incluyó la evaluación del modelo mediante 10 entrenamientos independientes, cuyos resultados se presentan en la Tabla 4.7, obteniéndose una desviación estándar de ± 0.85 % en los valores de precisión. Los pesos de la red neuronal se inicializan de forma aleatoria al inicio de cada entrenamiento, por lo que es común observar diferencias en los resultados entre distintas ejecuciones del mismo modelo. Los resultados obtenidos mostraron una variación reducida entre los ensayos realizados, con valores de precisión cercanos al 80 % en las diferentes ejecuciones. El comportamiento observado aportó información sobre la estabilidad de la arquitectura seleccionada y respaldó su utilización en la generación de los pronósticos desarrollados durante la investigación. La configuración final estuvo compuesta por dos capas LSTM de 128 y 64 neuronas, seguidas por una capa densa de 32 neuronas.

Tabla 4.7 Resultados de precisión para las 10 corridas independientes del modelo.

Número de corrida	Precisión
1	81.04
2	80.73
3	80.57
4	80.41
5	79.86
6	79.58
7	79.16
8	79.16
9	78.69
10	78.47

Con los resultados de esta prueba, se dio por concluida la fase metodológica de diseño y entrenamiento. La arquitectura profunda demostró tener la capacidad para procesar el comportamiento del viento urbano sin caer en la memorización de los datos de entrenamiento. Al consolidar un modelo predictivo estable y matemáticamente validado, el siguiente paso de la investigación consistió en someter esta red neuronal a una comparación directa contra el método tradicional ARIMA. Los detalles de esta prueba final, ejecutada con el conjunto de datos independiente del mes de enero, se explican a continuación en el Capítulo 5.

Capítulo 5. Análisis comparativo y presentación de resultados

Capítulo 5. Análisis comparativo y presentación de resultados

5.1 Estructuración de las pruebas comparativas

La estructuración de las pruebas comparativas demostró que la red neuronal LSTM registró una precisión final del 80.71 % frente al 78.98 % del modelo ARIMA en el escenario de evaluación. Para garantizar la igualdad del experimento, el modelo estadístico de referencia se entrenó procesando exactamente el mismo conjunto de datos históricos (80 % de la muestra original) que fue empleado para ajustar los pesos de la inteligencia artificial. Este equilibrio en el volumen de información inicial aseguró que cualquier diferencia en el rendimiento predictivo se debiera a la capacidad algorítmica de cada arquitectura para asimilar la dinámica del recurso eólico, y no a una ventaja en la cantidad de datos suministrados.

La primera etapa de validación registró los resultados preliminares de la arquitectura de aprendizaje profundo tras evaluar el desempeño de ambos algoritmos utilizando el 20 % restante del conjunto base. El 20 % restante del conjunto base se utilizó para ejecutar proyecciones simultáneas con el fin de determinar cómo reaccionaba cada modelo ante datos que pertenecían a la misma distribución temporal del entrenamiento, pero que se habían mantenido ocultos para los algoritmos. Los resultados de esta fase intermedia sirvieron para establecer las métricas de error y evidenciar la respuesta del enfoque estadístico lineal al intentar seguir los cambios bruscos de velocidad del viento en la zona urbana.

La evaluación con datos nuevos validó la capacidad de generalización de la red LSTM al analizar un conjunto completamente distinto y aislado, correspondiente a 745 instancias horarias del mes de enero de 2025. Este procedimiento obligó a la red neuronal y al modelo ARIMA a procesar información meteorológica que ninguno de los dos modelos había analizado previamente. La ejecución de esta validación externa sirvió para descartar que los algoritmos solo estuvieran memorizando la información (sobreajuste) y comprobó cómo operaría el modelo propuesto frente a condiciones climáticas reales para el pronóstico del viento en entornos urbanos.

5.2 Análisis de resultados en el conjunto de validación (20 %)

El análisis de resultados en el conjunto de validación, como se muestra en la Figura 5.1, determinó que la arquitectura de aprendizaje profundo LSTM registró una métrica de error menor frente al algoritmo estadístico ARIMA durante el procesamiento de los datos ocultos. La fase de la investigación se ejecutó después de la etapa de entrenamiento, utilizando el último bloque de la base de datos original que había sido segmentado y reservado. El objetivo de esta prueba fue confirmar que los pesos ajustados durante las 20 épocas de la red neuronal asimilaron el comportamiento del viento urbano, y comparar este resultado directamente contra los coeficientes calculados por el modelo autorregresivo bajo las mismas condiciones atmosféricas.

La revisión visual de las gráficas mostró que la red neuronal LSTM se acopló a las fluctuaciones del viento en el entorno urbano, mientras que el modelo estadístico mostró una trayectoria menos pronunciada ante los picos de velocidad. La comparación gráfica de las predicciones de ambas metodologías frente a las mediciones reales de este 20 % de validación permitió observar que la línea correspondiente a la inteligencia artificial reflejó los cambios de velocidad. La naturaleza lineal del modelo ARIMA provocó que las proyecciones fueran mucho más planas y estables, sin alcanzar los puntos más altos y bajos registrados por los anemómetros.




Figura 5.1 Comportamiento predictivo en el conjunto de validación (20 %): LSTM vs ARIMA

La revisión de las gráficas de barras, como se observa en la Figura 5.2, mostró que la arquitectura propuesta presentó métricas de error menores en comparación con el modelo ARIMA. La comparación del error absoluto y el error cuadrático medio en este bloque de validación

demostró que las barras de la arquitectura LSTM se mantuvieron por debajo de las generadas por el algoritmo estadístico. La diferencia indica que la red neuronal no solo memorizó los datos exactos con todo y las pequeñas alteraciones de los sensores. El modelo, en lugar de eso, logró aprender el comportamiento real del viento en el entorno urbano, lo que le permitió adaptarse a los cambios y hacer predicciones con menos errores.




Figura 5.2 Comparativa de errores predictivos en la fase de validación: LSTM vs ARIMA

La revisión de los pronósticos preliminares indicó que la red LSTM estaba lista para una prueba externa con datos nuevos, al lograr interpretar las variables meteorológicas con menores errores que el modelo de referencia. Los resultados de las gráficas permitieron avanzar a la evaluación final utilizando el conjunto de datos independiente correspondiente al mes de enero de 2025.

5.3 Análisis de errores en la prueba independiente (enero 2025)

El Análisis de errores en la prueba con el conjunto de datos exclusivo del mes de enero de 2025 mostró que la red neuronal LSTM alcanzó una precisión del 80.71 % frente al 78.98 % del modelo estadístico ARIMA durante 745 horas consecutivas. La evaluación se basó en el cálculo de métricas de desempeño sobre este bloque de información, lo que permitió comprobar que la red no memorizó los patrones, sino que aprendió a generalizar la información ante condiciones

climáticas reales no analizadas previamente. Los resultados confirmaron que el uso de redes neuronales profundas reduce los errores en el pronóstico del viento en el entorno urbano, proporcionando valores menores que los métodos convencionales.

La evaluación mediante el Error Absoluto Medio (MAE) mostró que la arquitectura LSTM registró una desviación de 0.4787 m/s, frente al valor de 0.5217 m/s obtenido por el modelo ARIMA. Esta métrica indicó que en promedio las predicciones de la red neuronal estuvieron más cerca de la velocidad real del viento medida por los anemómetros. Esta reducción en el MAE permite una planificación más precisa de la energía.

La Raíz del Error Cuadrático Medio (RMSE) mostró un valor de 0.6607 m/s para la red LSTM, frente al 0.7083 m/s del modelo ARIMA como se muestra en la tabla 5.1. El menor valor obtenido por la red neuronal es relevante porque esta métrica le da más peso a los errores grandes. Este resultado indicó que la red LSTM logró adaptarse a los cambios bruscos del viento en el entorno urbano, reduciendo los errores que el modelo estadístico no logró procesar. La disminución de estos errores permite obtener un pronóstico más confiable para proteger la infraestructura eléctrica.

Tabla 5.1 Comparativa de métricas ARIMA vs LSTM fase de pruebas

Métrica estadística	Modelo ARIMA (Línea Base)	Modelo LSTM (Propuesto)	Unidad de medida
MAE	0.5217	0.4787	m/s
RMSE	0.7083	0.6607	m/s
MAPE	21.02%	19.29%	%
Precisión Total	78.98%	80.71%	%

El Error Porcentual Absoluto Medio (MAPE) registró un margen de error del 19.29 % para la red neuronal frente al 21.02 % del algoritmo tradicional. El valor del MAPE que está por debajo del 20 % en Ciudad Nezahualcóyotl es relevante, considerando que la rugosidad del terreno y los obstáculos urbanos suelen incrementar este error en los modelos convencionales. Esta métrica porcentual indicó que se mantuvo una precisión constante a pesar de la variabilidad de las velocidades registradas durante las 745 horas del mes de enero.

5.4 Análisis gráfico del comportamiento predictivo

El análisis gráfico del comportamiento predictivo mostrado en la Figura 5.3 evidenció que la red neuronal LSTM se adaptó a las variaciones continuas del viento. El modelo estadístico ARIMA siguió la tendencia general, pero trazó una trayectoria menos pronunciada que no logró alcanzar los puntos más altos y bajos de las mediciones. El diseño de este algoritmo tiende a calcular promedios. La característica mencionada le impidió registrar la magnitud de los cambios rápidos, manteniéndose en valores más cercanos al centro de los datos en lugar de los extremos reales.




Figura 5.3 Comportamiento predictivo en la prueba independiente (Enero 2025): LSTM vs ARIMA.

La observación de los eventos mostró que la red neuronal anticipó variaciones del viento no detectadas por el modelo clásico. La curva de la arquitectura LSTM logró seguir las mediciones reales de los anemómetros durante los periodos de mayor inestabilidad. La trayectoria del modelo ARIMA trazó pendientes bajas y subestimó la velocidad del flujo de aire. Las diferencias en las gráficas indicaron que el modelo propuesto procesó el comportamiento del viento, adaptándose a los cambios rápidos en las mediciones de las velocidades del viento.

5.5 Análisis de la distribución de errores de pronóstico

El Análisis de la distribución de errores de pronóstico mostró que las diferencias de la red neuronal LSTM se concentraron en valores cercanos a cero, en comparación con la dispersión del modelo ARIMA. El cálculo de las diferencias entre las mediciones de los sensores y las

predicciones durante las 745 horas de enero de 2025 indicó que la inteligencia artificial registró menos desviaciones. La concentración de estos errores en valores reducidos confirmó que la red profunda procesó adecuadamente las variables climáticas. El modelo demostró su capacidad para adaptarse a la inestabilidad del viento en entornos urbanos.

La revisión de los histogramas de error indicó que el modelo estadístico ARIMA registró fallos de mayor dispersión al no tener un diseño para procesar los cambios rápidos del clima urbano. La dependencia de este algoritmo tradicional en funciones matemáticas lineales provocó que sus predicciones se mantuvieran cerca de los valores promedio. La gráfica del modelo estadístico mostró errores amplios ante las ráfagas. La red neuronal LSTM actualizó su información interna para adaptarse a la inestabilidad del viento. Los errores de la arquitectura profunda se mantuvieron en rangos menores, demostrando su capacidad para asimilar las variaciones. La Figura 5.4 resume este comportamiento, ilustrando cómo la red neuronal obtuvo valores inferiores tanto en el Error Absoluto Medio como en la Raíz del Error Cuadrático Medio frente al modelo estadístico.




Figura 5.4 Gráfica comparativa de la distribución de errores de pronóstico (LSTM vs ARIMA).

5.6 Desempeño predictivo en escenarios independientes

La evaluación del desempeño predictivo con el conjunto de datos exclusivo del mes de enero de 2025 mostró que la red neuronal LSTM alcanzó una precisión del 80.71 % frente al 78.98 % del modelo ARIMA. La arquitectura multivariada de la inteligencia artificial sustentó este resultado al correlacionar las variaciones de temperatura con los cambios en la velocidad del viento dentro del entorno urbano. El modelo estadístico ARIMA operó bajo una restricción univariada dependiente del historial lineal de una sola variable, limitando su capacidad para registrar los picos máximos. La topología de la red neuronal procesó de manera simultánea el vector térmico adicional. El análisis conjunto de estas variables permitió extraer las relaciones que anteceden a los incrementos bruscos de magnitud, anticipando el comportamiento eólico sin recurrir a ecuaciones físicas adicionales.

La evaluación de los distintos conjuntos de datos mostró la estabilidad del proceso de aprendizaje profundo. La fase de validación interna (20 %) registró para el modelo LSTM un Error Absoluto Medio (MAE) de 0.40, un RMSE de 0.55 y una precisión global del 81.04 %. El modelo estadístico ARIMA obtuvo en esta misma etapa un MAE de 0.43, un RMSE de 0.59 y una precisión del 79.90 %. La prueba exclusiva del mes de enero de 2025 reportó para la red neuronal un MAE de 0.4787 m/s, un RMSE de 0.6607 m/s y una precisión del 80.71 %. El algoritmo tradicional presentó en esta evaluación final un MAE de 0.5217 m/s, un RMSE de 0.7083 m/s y una precisión del 78.98 %. El comportamiento de estos índices indicó que la red de 128-64-32 neuronas evitó el sobreajuste o la memorización de los datos. La arquitectura asimiló la dinámica temporal que rige el flujo de aire en la zona de estudio. Los resultados confirmaron que el modelo desarrollado posee la capacidad de generalización requerida para operar como una herramienta de pronóstico eólico confiable, adaptándose a los retos de los entornos urbanos y la turbulencia generada por los edificios.

Capítulo 6. Conclusiones y trabajos futuros

Capítulo 6. Conclusiones y trabajos futuros

En este capítulo se explican las conclusiones de este trabajo de investigación, resaltando los hallazgos más relevantes, las aportaciones en el área de ciencias computacionales y las limitaciones enfrentadas durante el modelado eólico. Además, se describen las líneas futuras de investigación y los productos académicos obtenidos del desarrollo de esta tesis de maestría.

6.1. Conclusiones

La descripción del caso de estudio y la ejecución de los casos de prueba descritos en el capítulo 5 permiten concluir el cumplimiento del objetivo de esta investigación. Este proyecto planteó desarrollar un modelo de pronóstico de velocidad del viento para evaluar el recurso eólico en entornos urbanos, utilizando series temporales y algoritmos de inteligencia artificial. La implementación de esta metodología atiende al problema descrito como la limitación de los modelos estadísticos convencionales para capturar la naturaleza no lineal y predecir con exactitud las fluctuaciones de la velocidad del viento.

Las conclusiones derivadas de este trabajo de investigación confirmaron la superioridad de la arquitectura de aprendizaje profundo LSTM sobre los modelos estadísticos convencionales al reducir el error porcentual absoluto medio (MAPE) a un 19.29 % en un entorno urbano denso. Esta tesis tuvo como objetivo desarrollar un modelo de inteligencia artificial capaz de pronosticar la velocidad del viento en Ciudad Nezahualcóyotl, integrando variables meteorológicas exógenas para capturar la naturaleza no lineal de la atmósfera. Para ello, se implementó una metodología que incluyó la reconstrucción de series temporales mediante interpolación con ruido gaussiano, el diseño de una arquitectura de "embudo profundo" y una evaluación comparativa rigurosa frente al algoritmo ARIMA.

El modelo LSTM registró una precisión del 80.71 % y un Error Absoluto Medio (MAE) de 0.4787 m/s durante la fase de prueba. El modelo estadístico ARIMA obtuvo una precisión del 78.98 %. Este algoritmo tradicional mostró limitaciones para registrar los cambios rápidos y las ráfagas características del entorno urbano. El análisis comparativo indicó que el desempeño de la

red neuronal se fundamentó en su capacidad multivariada. El modelo ARIMA operó basándose en el historial unilineal del viento. La topología de 128-64-32 neuronas procesó de manera simultánea las variables térmicas y cinemáticas (temperatura y velocidad). Esta integración de datos permitió anticipar las fluctuaciones del recurso eólico frente a la turbulencia generada por los edificios.

La integración de variables exógenas disminuyó la incertidumbre en el pronóstico. El procesamiento de estos datos permitió que la inteligencia artificial identificara patrones climáticos no registrados por la estadística lineal. Las limitaciones de este trabajo comprenden la complejidad de la rugosidad urbana y el uso de técnicas de imputación para corregir los registros faltantes en la base de datos original. Los resultados obtenidos demostraron que el modelo propuesto funciona como una herramienta técnica para complementar la evaluación preliminar del potencial energético. El desempeño de la red neuronal confirma su viabilidad para la predicción de la velocidad del viento en entornos urbanos.

6.2. Trabajos futuros

Los trabajos futuros se orientarán a la integración de variables climáticas adicionales, como la presión barométrica y la radiación solar, con el objetivo de robustecer la capacidad de respuesta del modelo ante frentes fríos y cambios térmicos extremos. Se propone explorar arquitecturas híbridas que combinen Redes Convolucionales (CNN) con capas LSTM para capturar tanto la dependencia espacial de los edificios como la dependencia temporal del viento, buscando reducir el margen de error en horizontes de predicción mayores a 24 horas.

La expansión del conjunto de datos representará otra línea de investigación prioritaria, incorporando mediciones de diferentes estaciones meteorológicas en la Zona Metropolitana del Valle de México para validar la transferibilidad del modelo a otras áreas urbanas con distintas configuraciones de rugosidad. Finalmente, se sugiere la implementación del algoritmo desarrollado en hardware embebido de bajo costo, lo que permitiría evaluar su desempeño en tiempo real como motor de control para el frenado y orientación de pequeños aerogeneradores urbanos, optimizando así la extracción de energía limpia en entornos habitacionales.

Productos derivados de la investigación

Como resultado del desarrollo de esta tesis, se generaron diversos productos académicos que contribuyeron a la difusión del conocimiento sobre los hallazgos obtenidos, reflejando el trabajo realizado y su aplicación en el ámbito de la Inteligencia Artificial orientada a la predicción meteorológica urbana. A continuación, se describen los principales productos y participaciones derivados de esta investigación.

Artículos de Congreso

- Flores Gómez, W., Claudio Pachecano, L., Estrada Esquivel, H., & Martínez Rebollar, A. (2025). *Challenges in the construction of a dataset for urban wind speed forecasting*. Artículo de congreso en el área de Inteligencia Artificial. 5.º Congreso Internacional de Tecnología y Ciencia Aplicada (CITCA). Centro Nacional de Investigación y Desarrollo Tecnológico, Cuernavaca, Morelos.

Participación en Eventos Académicos

- **Miembro del Equipo Organizador:** Participación activa en la organización del 5.º Congreso Internacional de Tecnología y Ciencia Aplicada (CITCA), celebrado en el Centro Nacional de Investigación y Desarrollo Tecnológico del 26 al 28 de noviembre de 2025.

Actividades de Divulgación y Transferencia de Conocimiento

- Flores Gomez, W. (2026). *Curso-Taller: Uso Ético y Responsable de la Inteligencia Artificial en la Educación*. Curso impartido a la comunidad estudiantil en la Telesecundaria "Pascual Ortiz Rubio". Acteopan, Puebla.

Referencias

- Albeladi, K., Zafar, B., & Mueen, A. (2023). Time Series Forecasting using LSTM and ARIMA. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 14(1). <https://doi.org/10.14569/IJACSA.2023.0140133>
- Azad, H. B., Mekhilef, S., & Ganapathy, V. G. (2014). Long-Term Wind Speed Forecasting and General Pattern Recognition Using Neural Networks. *IEEE Transactions on Sustainable Energy*, 5(2), 546-553. <https://doi.org/10.1109/TSTE.2014.2300150>
- Barbounis, T. G., Theocharis, J. B., Alexiadis, M. C., & Dokopoulos, P. S. (2006). Long-Term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models. *IEEE Transactions on Energy Conversion*, 21(1), 273-284. <https://doi.org/10.1109/TEC.2005.847954>
- Berzal, F. (2018). *Redes Neuronales y Deep Learning*. EUG Editorial Universidad de Granada.
- Box, G. E. P., & Jenkins, G. M. (1970). *Time series analysis: Forecasting and control*. Holden-Day.
- Budanko, M., & Guzović, Z. (2024). Design Methodology and Economic Impact of Small-Scale HAWT Systems for Urban Distributed Energy Generation. *Machines*, 12(12), 886. <https://doi.org/10.3390/machines12120886>
- Burkov, A. (2019). *The Hundred-Page Machine Learning Book*. Andriy Burkov.
- Cadenas, E., & Rivera, W. (2010). Wind speed forecasting in three different regions of Mexico using a hybrid ARIMA-ANN model. *Renewable Energy*, 35(12), 2732-2738. <https://doi.org/10.1016/j.renene.2010.04.015>
- Cadenas, E., Rivera, W., Campos-Amezcu, R., & Heard, C. (2016). Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model. *Energies*, 9(2), 109. <https://doi.org/10.3390/en9020109>
- Chang, G. W., Lu, H. J., Hsu, L. Y., & Chen, Y. Y. (2016). A hybrid model for forecasting wind speed and wind power generation. 2016 IEEE Power and Energy Society General Meeting (PESGM), 1-5. <https://doi.org/10.1109/PESGM.2016.7742039>
- Chen, J., Zeng, G. Q., Lu, W., Zheng, D. W., & Bi, Q. P. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. *Energy Conversion and Management*, 165, 681-695. <https://doi.org/10.1016/j.enconman.2018.03.098>
- Elsaraiti, M., & Merabet, A. (2021). A Comparative Analysis of the ARIMA and LSTM Predictive Models and Their Effectiveness for Predicting Wind Speed. *Energies*, 14(20), 6782. <https://doi.org/10.3390/en14206782>
- Gan, Z., Li, C., Hu, J., Sun, Z., & Chen, J. (2020). Temporal Convolutional Networks Interval Prediction Model for Wind Speed Forecasting. *IEEE Internet of Things Journal*, 7(10), 10398-10408. <https://doi.org/10.1109/JIOT.2020.3000676>

- Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M., & Draxl, C. (2011). The state-of-the-art in short-term prediction of wind power: A literature overview. ANEMOS.plus.
- Grigonytė, E., & Butkevičiūtė, J. (2016). Short-term wind speed forecasting using ARIMA model. *Energetika*, 62(1-2). <https://doi.org/10.6001/energetika.v62i1-2.3313>
- Grimmond, C. S. B. (2006). Progress in measuring and modelling the urban energy balance. *Applied Climatology*, 26, 3-22.
- Kavasseri, R. G., & Seetharaman, K. (2009). Day-ahead wind speed forecasting using f-ARIMA models. *Renewable Energy*, 34(5), 1388-1393. <https://doi.org/10.1016/j.renene.2008.09.006>
- Kurppa, M., Hellsten, A., Auvinen, M., Rasch, S., Vesala, T., & Järvi, L. (2020). Sensitivity of urban wind and turbulence to buildings and vegetation. *Atmospheric Chemistry and Physics*, 20(23), 15005-15026. <https://doi.org/10.5194/acp-20-15005-2020>
- Liu, D., Wang, H., Zhang, J., Lv, J., He, B., Zhao, C., & Yu, G. (2025). Deep Learning Algorithms for Wind Speed Prediction in Complex Terrain Using Meteorological Data. *Atmosphere*, 17(1), 28. <https://doi.org/10.3390/atmos17010028>
- Liu, H., Tian, H., & Li, Y. (2012). Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*, 98, 415-424. <https://doi.org/10.1016/j.apenergy.2012.04.053>
- Liu, H., Tian, H., Pan, D., & Li, Y. (2013). Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks. *Applied Energy*, 107, 191-208. <https://doi.org/10.1016/j.apenergy.2013.02.002>
- Liu, H., Tian, H., & Li, Y. (2015). An EMD-recursive ARIMA method to predict wind speed for railway strong wind warning system. *Journal of Wind Engineering and Industrial Aerodynamics*, 141, 27-38. <https://doi.org/10.1016/j.jweia.2015.02.004>
- Liu, H., Mi, X., Li, Y., Duan, Z., & Xu, Y. (2019). Smart wind speed deep learning based multi-step forecasting model using singular spectrum analysis, convolutional Gated Recurrent Unit network and Support Vector Regression. *Renewable Energy*, 143, 842-854. <https://doi.org/10.1016/j.renene.2019.05.039>
- Liu, H., Chen, C., & Li, Y. (2020). Wind speed forecasting using deep neural network with feature selection. *Energies*, 13(1), 87. <https://doi.org/10.3390/en13010087>
- Liu, X., Lin, Z., & Feng, Z. (2021). Short-term offshore wind speed forecast by seasonal ARIMA - A comparison against GRU and LSTM. *Energy*, 227(C), 120492. <https://doi.org/10.1016/j.energy.2021.120492>
- Liu, Y., Yigitcanlar, T., Guaralda, M., Degirmenci, K., Liu, A., & Kane, M. (2022). Leveraging the Opportunities of Wind for Cities through Urban Planning and Design: A PRISMA Review. *Sustainability*, 14(18), 11665. <https://doi.org/10.3390/su141811665>

- Louka, P., Galanis, G., Siebert, N., Kariniotakis, G., Katsafados, P., Pytharoulis, I., & Kallos, G. (2008). Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering. *Journal of Wind Engineering and Industrial Aerodynamics*, 96(12), 2348-2362. <https://doi.org/10.1016/j.jweia.2008.03.013>
- Lydia, M., Kumar, S. S., Selvakumar, A. I., & Kumar, G. E. P. (2016). Linear and non-linear autoregressive models for short-term wind speed forecasting. *Energy Conversion and Management*, 112, 115-124. <https://doi.org/10.1016/j.enconman.2016.01.007>
- More, A., & Deo, M. C. (2003). Forecasting wind with neural networks. *Marine Structures*, 16(1), 35-49. [https://doi.org/10.1016/S0951-8339\(02\)00062-8](https://doi.org/10.1016/S0951-8339(02)00062-8)
- Oke, T. R. (1997). Urban climates and global environmental change. *Applied Climatology*, 53, 273-287.
- Palomares-Salas, J. C., De la Rosa, J. J., Ramiro, J. G., Melgar, J., Aguera, A., & Moreno, A. (2009). ARIMA vs. Neural networks for wind speed forecasting. *2009 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications*, 129-133. <https://doi.org/10.1109/CIMSA.2009.5069932>
- Pino Díez, R., Parreño Fernández, J., Priore Moreno, P., & Gómez Gómez, A. (2004). Pronóstico de la Velocidad y Dirección del Viento mediante Redes Neuronales Artificiales. VIII Congreso de Ingeniería de Organización, 905-914.
- Piringer, M., Grimmond, C. S. B., Joffre, S. M., Mestayer, P., Middleton, D. R., Rotach, M. W., Baklanov, A., De Ridder, K., Ferreira, J., Guilloteau, E., Karppinen, A., Martilli, A., Masson, V., & Tombrou, M. (2002). Investigating the surface energy balance in urban areas—Recent advances and challenges. *Water, Air, and Soil Pollution: Focus*, 2(5), 1-14.
- Potter, C. W., Lew, D., McCaa, J., Cheng, S., Eilers, S., & Makarburti, G. (2008). Creating the dataset for the western wind and solar integration study (U.S.A.). *Wind Engineering*, 32(4), 325-338.
- Rotach, M. W., Vogt, R., Bernhofer, C., Batchvarova, G., Christen, A., Clappier, A., Feddersen, B., Gryning, S. E., Martilli, A., Mayer, H., Mitev, V., Parlow, E., Richner, H., Roth, M., Roulet, Y. A., Ruffieux, D., Salmond, J. A., Schatzmann, M., Voogt, J. A., ... & van Gorsel, E. (2005). BUBBLE - an urban boundary layer meteorology project. *Theoretical and Applied Climatology*, 81(3), 231-261. <https://doi.org/10.1007/s00704-004-0117-9>
- Shivani, S., & Sandhu, K. S. (2019). A Comparative Study of ARIMA and RNN for Short Term Wind Speed Forecasting. *2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, 1-7. <https://doi.org/10.1109/ICCCNT45670.2019.8944466>
- Shukur, O. B., & Lee, M. H. (2015). Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renewable Energy*, 76, 637-647. <https://doi.org/10.1016/j.renene.2014.11.084>
- Sim, S.-K., Maass, P., & Lind, P. G. (2019). Wind speed modeling by nested ARIMA processes. *Energies*, 12(1), 69. <https://doi.org/10.3390/en12010069>
- Simões, T., & Estanqueiro, A. (2016). A new methodology for urban wind resource assessment. *Renewable Energy*, 89, 598-605. <https://doi.org/10.1016/j.renene.2015.12.008>

- Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. 2010 North American Power Symposium (NAPS), 1-8. <https://doi.org/10.1109/NAPS.2010.5619586>
- Stathopoulos, T., Alrawashdeh, H., Al-Quraan, A., Blocken, B., Dilimulati, A., Paraschivoiu, M., & Pilay, P. (2018). Urban wind energy: Some views on potential and challenge. *Journal of Wind Engineering and Industrial Aerodynamics*, 179, 146-157. <https://doi.org/10.1016/j.jweia.2018.05.018>
- Tyass, I., et al. (2023). Wind Speed Prediction Based on Statistical and Deep Learning Models. *International Journal of Renewable Energy Development*, 12(6).
- Wang, J., Qin, S., Zhou, Q., & Jiang, H. (2015). Medium-term wind speeds forecasting utilizing hybrid models for three different sites in Xinjiang, China. *Renewable Energy*, 76, 91-101. <https://doi.org/10.1016/j.renene.2014.11.017>
- Wang, J.-W., Yang, H.-J., & Kim, J.-J. (2020). Wind speed estimation in urban areas based on the relationships between background wind speeds and morphological parameters. *Journal of Wind Engineering and Industrial Aerodynamics*, 205, 104324. <https://doi.org/10.1016/j.jweia.2020.104324>
- Wang, Y., Zou, R., Liu, F., Zhang, L., & Liu, Q. (2021). A review of wind speed and wind power forecasting with deep neural networks. *Applied Energy*, 304, 117766. <https://doi.org/10.1016/j.apenergy.2021.117766>
- Wolpert, D. H., & Macready, W. G. (1997). Autodisimilitud: Una medida empírica de complejidad. *Documento de trabajo del Instituto Santa Fe*, 97-12.
- World Bank. (2021). Sustainable Cities: Creating Greener and More Resilient Urban Spaces. Recuperado de: <https://www.worldbank.org>
- Yatiana, E., Rajakaruna, S., & Bandara, A. (2017). Wind Speed and Direction Forecasting for Wind Power Generation Using ARIMA Model. 2017 Australasian Universities Power Engineering Conference (AUPEC), 1-6. <https://doi.org/10.1109/AUPEC.2017.8282494>
- Yunus, K., Thiringer, T., & Chen, P. (2015). ARIMA-Based Frequency-Decomposed Modeling of Wind Speed Time Series. *IEEE Transactions on Power Systems*, 31(4), 2546-2556. <https://doi.org/10.1109/TPWRS.2015.2468586>
- Zheng, Y., & Li, Y. (2020). Calculation of wind power potential in urban environments. *Energy Reports*, 6, 1190-1196. <https://doi.org/10.1016/j.egyr.2020.11.005>