



TECNOLÓGICO  
NACIONAL DE MÉXICO

TECNOLÓGICO NACIONAL DE MÉXICO  
CAMPUS AGUASCALIENTES



CONAHCYT  
CONSEJO NACIONAL DE HUMANIDADES  
CIENCIAS Y TECNOLOGÍAS

---

DISEÑO DE MODELOS DE *MACHINE LEARNING* DE DINÁMICA DEL VIENTO PARA ANÁLISIS DE LA  
SUSTENTABILIDAD URBANA EN AGUASCALIENTES

# TESIS

PARA OBTENER EL GRADO DE:

**MAESTRA EN CIENCIAS EN INGENIERÍA AMBIENTAL**

PRESENTA:

**ANDREA DEL PILAR AGUILAR BURKE**

DIRECTOR DE TESIS:

**DR. PABLO TENOCH RODRÍGUEZ GONZÁLEZ**

CO-DIRECTOR DE TESIS:

**DR. HÉCTOR ANTONIO OLMOS GUERRERO**

MIEMBRO DEL COMITÉ DE TESIS:

**DR. JAVIER GERSON ZAPIAIN SALINAS**

ENERO DE 2025



**Instituto Tecnológico de Aguascalientes**  
División de Estudios de Posgrado e Investigación

Aguascalientes, Ags, 10/enero/2025  
Oficio No. DEPI 006/2025  
Asunto: Autorización impresión tesis

**C. ANDREA DEL PILAR AGUILAR BURKE**  
**PRESENTE**

Los abajo firmantes, Miembros del Jurado para Examen de Grado de Maestría, hacemos **constar** que, habiendo revisado el Trabajo de Tesis desarrollado por Usted, bajo el título: **"Diseño de modelos de Machine Learning de dinámica del viento para análisis de la sustentabilidad urbana en Aguascalientes"**, hemos dictaminado que éste es de aceptarse, por lo que se autoriza su impresión.

**ATENTAMENTE**


*Excelencia en Educación Tecnológica®*  
*Ingenio, Cultura y Saber, que conducen a la Excelencia®*

  
**DR. PABLO TENOCH RODRÍGUEZ GONZÁLEZ**

  
**DR. HÉCTOR ANTONIO OLMOS GUERRERO**

  
**DR. JAVIER GERSON ZAPIAIN SALINAS**

ccp. Archivo  
JFLH/yevo





**Instituto Tecnológico de Aguascalientes**

División de Estudios de Posgrado e Investigación

Aguascalientes, Ags., 14/enero/2025

Asunto: Autorización de uso de derechos

**ANDREA DEL PILAR AGUILAR BURKE**, mayor de edad, con domicilio ubicado en Av. Siglo XXI No.222, Fracc. Ojo Caliente II, en mi calidad de titular y autor de la tesis denominada "**DISEÑO DE MODELOS DE MACHINE LEARNING DE DINÁMICA DEL VIENTO PARA ANÁLISIS DE LA SUSTENTABILIDAD URBANA EN AGUASCALIENTES**" quien para todos los fines del presente documento se denominará **EL AUTOR Y/O TITULAR**, suscribo el presente documento de autorización de uso de derechos patrimoniales de autor a favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes el cual se registrá por las cláusulas siguientes:

**PRIMERA – AUTORIZACIÓN:** **EL AUTOR Y/O TITULAR**, mediante el presente documento autoriza la utilización de los derechos patrimoniales de autor al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, de la tesis denominada "**DISEÑO DE MODELOS DE MACHINE LEARNING DE DINÁMICA DEL VIENTO PARA ANÁLISIS DE LA SUSTENTABILIDAD URBANA EN AGUASCALIENTES**", a través del Repositorio Institucional del Tecnológico Nacional de México (en lo sucesivo TecNM) y en el Repositorio Nacional, que puede ser consultado en la liga electrónica: ([www.repositorionacionalcti.mx/](http://www.repositorionacionalcti.mx/)).

**SEGUNDA – OBJETO:** Por medio del presente escrito, **EL AUTOR Y/O TITULAR** autoriza al Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes, a través del Repositorio Institucional del TecNM y en el Repositorio Nacional para que de conformidad con la Ley Federal del Derecho de Autor y la Ley de la Propiedad Industrial, use los derechos del documento antes referido, con fines exclusivamente académicos.

**TERCERA – TERRITORIO:** Los derechos aquí autorizados se dan sin limitación geográfica o territorial alguna.

**CUARTA – ALCANCE:** La presente autorización se da tanto para formato o soporte material, y se extiende a la utilización en medio óptico, magnético, electrónico, en red, mensajes de datos o similar conocido o por conocer, del ejemplar o número respectivo de la publicación.

**QUINTA – EXCLUSIVIDAD:** La autorización de uso aquí establecida no implica exclusividad en favor del Tecnológico Nacional de México/Instituto Tecnológico de Aguascalientes. Por lo tanto, **EL AUTOR Y/O TITULAR** en su carácter de autor de la obra objeto del presente documento se reserva el derecho de publicar directamente, u otorgar a cualquier tercero, autorizaciones de uso similares o en los mismos términos aquí acordados.



**2025**  
Año de  
La Mujer  
Indígena

Av. Adolfo López Mateos #1801. Fracc. Bona Gens  
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127  
e-mail: [jefatura.depi@aguascalientes.tecnm.mx](mailto:jefatura.depi@aguascalientes.tecnm.mx)  
[tecnm.mx](http://tecnm.mx) | [www.aguascalientes.tecnm.mx](http://www.aguascalientes.tecnm.mx)



Instituto Tecnológico  
de Aguascalientes



ESPACIO  
100%  
LIBRE DE  
PLÁSTICOS  
DE UN SOLO USO



Norma Mexicana en Igualdad Laboral y No Discriminación



ABET



**SEXTA – DERECHOS MORALES (Créditos y mención):** La Autorización de los derechos antes mencionados no implica la cesión de los derechos morales sobre los mismos por cuanto en conformidad con lo establecido en los artículos 18, 19, 20, 21, 22 y 23 de la Ley Federal de Derechos de Autor, dada la cuenta que estos derechos son inalienables, imprescriptibles, irrenunciables e inembargables. Por lo tanto, los mencionados derechos seguirán radicados en cabeza de EL AUTOR Y/O TITULAR, y siempre deberá mencionarse su nombre cuando se utilice la obra.

**SÉPTIMA – AUTORÍA: EL AUTOR Y/O TITULAR,** declara y ratifica que el material objeto de la presente fue realizada por él o por ella sin violar o usurpar derechos de Propiedad Intelectual de terceros.

**ATENTAMENTE**

*Excelencia en Educación Tecnológica®*

*Ingenio, Cultura y Saber, que conducen a la Excelencia*

**Vo.Bo.**

**ANDREA DEL PILAR AGUILAR BURKE**  
**AUTOR DE LA TESIS**

**DR. PABLO TENOCH RODRÍGUEZ GONZÁLEZ**  
**DIRECTOR DE LA TESIS**

ccp. Archivo



**2025**  
Año de  
**La Mujer  
Indígena**

Av. Adolfo López Mateos #1801. Fracc. Bona Gens  
C.P. 20256 Aguascalientes, Ags. Tel. 449 910 5002 ext. 127  
e-mail: [jefatura.depi@aguascalientes.tecnm.mx](mailto:jefatura.depi@aguascalientes.tecnm.mx)  
[tecnm.mx](http://tecnm.mx) | [www.aguascalientes.tecnm.mx](http://www.aguascalientes.tecnm.mx)



A mis queridos padres, Alberto Aguilar y Alma Burke...

## **DEDICATORIA**

Cuyo apoyo y amor han sido fundamentales en cada etapa de mi camino académico. A mi papá, aunque ya no está físicamente, su presencia permanece iluminando cada uno de mis logros. Esta tesis es un homenaje a su memoria, y agradezco profundamente por enseñarme que los únicos límites son los que uno mismo se impone.

Para ustedes, con todo mi amor y eterna gratitud.

**Andrea Aguilar.**

## **AGRADECIMIENTOS**

A los doctores Pablo Tenoch Rodríguez González, Héctor Antonio Olmos Guerrero y Javier Gerson Zapiain Salinas, quienes, con su gran conocimiento y guía constante, han sido pilares fundamentales en el desarrollo y culminación de este proyecto. Sus enseñanzas han sido invaluablemente enriquecedoras para mi formación personal y profesional, toda mi admiración y respeto hacia ustedes.

Quiero agradecer al Consejo Nacional de Humanidades, Ciencia y Tecnología (CONAHCYT) por la oportunidad que me brindaron al financiar mis estudios de maestría. Su apoyo no solo hizo posible mi formación académica, sino que también fortaleció mi compromiso con la investigación científica.

Expreso mi más sincero agradecimiento al Dr. Víctor Manuel Rodríguez Moreno, responsable del Laboratorio Nacional de Modelaje y Sensores Remotos (LNMySR), así como a la Mtra. Evelyn Galván Cárdenas, por su valioso apoyo al proporcionarme los datos históricos de las diecisiete estaciones de monitoreo del Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP). Estos datos fueron esenciales para el avance y éxito de este proyecto.

A mis queridos hermanos, Alex y Gus, quienes siempre me han apoyado de manera incondicional y me han motivado a continuar preparándome.

A mi compañero de aventuras y confidente, Julio, quien ha sido mi apoyo constante. Sus palabras de aliento, amor y comprensión me ayudaron a perseverar hasta el final, a superar los desafíos y a celebrar los logros juntos.

A mis amigos más cercanos, quienes han permanecido en mi vida a lo largo de esta travesía académica. Las risas y momentos que compartimos hicieron de este proyecto una mejor experiencia.

Por último y no menos importante, a dios, por darme el privilegio de concluir esta etapa.

## RESUMEN

La dinámica del viento, que considera tanto a la velocidad como a la dirección, es fundamental para la sustentabilidad urbana, y su impacto se extiende a múltiples áreas, que van más allá de la calidad del aire. Estos factores influyen en la producción de energía eólica, el diseño de edificaciones, la seguridad en construcciones y la gestión de incendios. El viento puede concentrar o dispersar contaminantes, influir en la eficiencia de la energía eólica y determinar la ventilación natural en los edificios. Por ello, comprender la dinámica del viento es esencial para promover la sustentabilidad urbana y determinar la calidad del aire. Sin embargo, la variabilidad cercana y la falta de precisión en las mediciones de las estaciones meteorológicas dificultan su análisis.

Para abordar esos desafíos, esta tesis propone el diseño de modelos de *Machine Learning* para pronóstico de la dinámica del viento. Para ello, se emplearon Redes Neuronal Recurrentes de tipo regresor, incorporando tanto un modelo temporal, basado en datos de la estación de monitoreo de la RUOA (RNV y RND), como modelos espacio-temporales, desarrollados con datos de 17 estaciones de monitoreo del INIFAP (RNV-ET y RND-ET). En el primer modelo, las variables consideradas incluyeron parámetros temporales, como el día del año y la hora, junto con otras variables adicionales como el estado previo y la temperatura. En contraste, para los modelos posteriores se descartó la temperatura y se incorporaron la latitud y la longitud como parámetros de entrada. Para mejorar la precisión en la predicción, se implementó una herramienta predictiva-correctiva, como lo son los Filtros de Kalman (FK). El coeficiente de determinación del modelo RNV aumentó de 0.47 a 0.88, y el del modelo RND de 0.28 a 0.83. Por su parte, los modelos RNV-ET y RND-ET mejoraron de 0.83 a 0.97 y de 0.28 a 0.90, respectivamente.

Adicionalmente, con el objetivo de analizar la dinámica geoespacial del viento se utilizaron herramientas de Sistema de Información Geográfica (SIG). También, se integró el método de Interpolación por Distancia Inversa Ponderada (*IDW*), lo que permitió obtener una representación detallada de la distribución del viento en puntos con ausencia de información, representándolo en mapas de contorno y vectores del viento. Este proceso también se utilizó para calcular la densidad promedio del viento en la ciudad de Aguascalientes, identificando dos áreas específicas al norte y noroeste con un alto potencial eólico.

## ÍNDICE DE CONTENIDO

|                                                                                        |            |
|----------------------------------------------------------------------------------------|------------|
| <b>DEDICATORIA.....</b>                                                                | <b>I</b>   |
| <b>AGRADECIMIENTOS .....</b>                                                           | <b>II</b>  |
| <b>RESUMEN.....</b>                                                                    | <b>III</b> |
| <br>                                                                                   |            |
| CAPÍTULO I. INTRODUCCIÓN .....                                                         | 1          |
| 1.1    OBJETIVOS .....                                                                 | 4          |
| CAPÍTULO II. MARCO TEÓRICO .....                                                       | 5          |
| 2.1 Dinámica del viento .....                                                          | 5          |
| 2.2 Contaminación del aire .....                                                       | 5          |
| 2.3 Sustentabilidad urbana .....                                                       | 6          |
| 2.4 Monitoreo de parámetros meteorológicos .....                                       | 7          |
| 2.5 Estaciones meteorológicas.....                                                     | 9          |
| 2.6 Densidad de potencia eólica.....                                                   | 9          |
| 2.7 Análisis Exploratorio de Datos .....                                               | 10         |
| 2.8 Inteligencia Artificial y Aprendizaje Automático .....                             | 12         |
| 2.9 Redes Neuronales.....                                                              | 12         |
| 2.9.1 Arquitectura de las Redes Neuronales.....                                        | 12         |
| 2.9.2 Tipos de Redes Neuronales.....                                                   | 13         |
| 2.10 Filtro de Kalman .....                                                            | 15         |
| 2.11 Sistemas de Información Geográfica.....                                           | 17         |
| 2.12 Distancia inversa ponderada .....                                                 | 18         |
| CAPÍTULO III. METODOLOGÍA .....                                                        | 20         |
| 3.1 Recolección de datos de estaciones meteorológicas .....                            | 20         |
| 3.2 Filtrado de las bases de datos .....                                               | 22         |
| 3.3 Análisis Exploratorio de Datos.....                                                | 23         |
| 3.4 Diseño de modelo de RNN para pronósticos de velocidad y dirección del viento ..... | 24         |
| 3.4.1 Diseño de modelo de RNN temporal.....                                            | 24         |
| 3.4.2 Diseño de modelo de RNN espacio-temporal .....                                   | 26         |
| 3.5 Análisis de residuales de los modelos espacio-temporales.....                      | 28         |

|                                                                                                                                 |    |
|---------------------------------------------------------------------------------------------------------------------------------|----|
| 3.6 Acoplamiento de Filtro de Kalman a modelos RNN.....                                                                         | 28 |
| 3.6.1 Acoplamiento de Filtro de Kalman a RNN temporal utilizando datos de la RUOA .....                                         | 29 |
| 3.6.2 Acoplamiento de Filtro de Kalman a RNN espacio-temporal utilizando datos del INIFAP                                       | 30 |
| 3.7 Definición de las fronteras del sistema .....                                                                               | 31 |
| 3.8 Evaluación espacio-temporal del modelo de RNV-ET y RND-ET .....                                                             | 31 |
| 3.9 Acoplamiento de RNN e IDW para la generación de pronósticos espacio-temporales de<br>velocidad y dirección del viento ..... | 32 |
| 3.10 Caso de estudio.....                                                                                                       | 33 |
| CAPÍTULO IV. RESULTADOS .....                                                                                                   | 35 |
| 4.1 Recolección de datos de estaciones meteorológicas .....                                                                     | 35 |
| 4.2 Filtrado de las bases de datos .....                                                                                        | 35 |
| 4.3 Análisis Exploratorio de Datos .....                                                                                        | 36 |
| 4.3.1 Análisis Exploratorio de Datos de la RUOA .....                                                                           | 36 |
| 4.3.2 Análisis Exploratorio de Datos del INIFAP .....                                                                           | 39 |
| 4.4 Diseño de modelo de RNN para pronósticos de velocidad y dirección del viento .....                                          | 43 |
| 4.4.1 Diseño de modelo de RNN temporal.....                                                                                     | 43 |
| 4.4.2 Diseño de modelo de RNN espacio-temporal .....                                                                            | 47 |
| 4.5 Análisis de residuales de los modelos espacio-temporales .....                                                              | 51 |
| 4.6 Acoplamiento de Filtro de Kalman a modelos RNN.....                                                                         | 53 |
| 4.6.1 Acoplamiento de Filtro de Kalman a RNN temporal utilizando datos de la RUOA .....                                         | 53 |
| 4.6.2 Acoplamiento de Filtro de Kalman a RNN espacio-temporal utilizando datos del INIFAP                                       | 55 |
| 4.7 Definición de las fronteras del sistema .....                                                                               | 59 |
| 4.8 Evaluación espacio-temporal del modelo de RNV-ET y RND-ET .....                                                             | 60 |
| 4.9 Acoplamiento de RNN e IDW para la generación de pronósticos espacio-temporales de<br>velocidad y dirección del viento ..... | 61 |
| 4.10 Caso de estudio.....                                                                                                       | 63 |
| CAPÍTULO V. CONCLUSIONES .....                                                                                                  | 66 |
| REFERENCIAS .....                                                                                                               | 68 |
| ANEXOS .....                                                                                                                    | 76 |
| Anexo A.....                                                                                                                    | 76 |
| Anexo B.....                                                                                                                    | 77 |

## ÍNDICE DE TABLAS Y FIGURAS

|                                                                                                                                                                            |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Tabla 2.1. Parámetros meteorológicos que suelen ser medidos en las estaciones de monitoreo .....                                                                           | 9  |
| Figura 2.1. Monitoreo de parámetros meteorológicos.....                                                                                                                    | 8  |
| Figura 2.2. Capas de una RNA.....                                                                                                                                          | 13 |
| Figura 2.3. Esquema de la arquitectura de una RNA <i>Feedforward</i> [44].....                                                                                             | 14 |
| Figura 2.4. Esquema del funcionamiento del FK. ....                                                                                                                        | 17 |
| Figura 2.5. Esquema del uso de SIG. ....                                                                                                                                   | 18 |
| Figura 3.1. Metodología. ....                                                                                                                                              | 20 |
| Figura 3.2. Ubicación geoespacial de la estación de monitoreo de la RUOA. ....                                                                                             | 21 |
| Figura 3.3. Distribución geoespacial de las 17 estaciones del INIFAP en el estado de Aguascalientes.<br>.....                                                              | 22 |
| Figura 3.4. Esquema del modelo RNV.....                                                                                                                                    | 25 |
| Figura 3.5. Esquema del modelo RND. ....                                                                                                                                   | 26 |
| Figura 3.6. Esquema del modelo RNV-ET.....                                                                                                                                 | 27 |
| Figura 3.7. Esquema del modelo RND-ET.....                                                                                                                                 | 28 |
| Figura 3.8. Acoplado de FK a un modelo de RNN.....                                                                                                                         | 30 |
| Figura 4.1. Diagramas de distribución de velocidad del viento, a) Histograma, b) Diagrama de cajas.<br>.....                                                               | 37 |
| Figura 4.2. Diagramas de distribución de dirección del viento, a) Histograma, b) Rosa de los vientos.<br>.....                                                             | 38 |
| Figura 4.3. Gráficos de análisis de series temporales, a) ACF de la velocidad del viento, b) ACF de la<br>dirección, c) PACF de la velocidad, d) PACF de la dirección..... | 39 |
| Figura 4.4. Diagramas de distribución de velocidad del viento, a) Histograma, b) Diagrama de cajas.<br>.....                                                               | 40 |
| Figura 4.5. Diagramas de distribución de dirección del viento a) Histograma y b) Rosa de los vientos<br>.....                                                              | 41 |
| Figura 4.6. Gráficos de análisis de series temporales, a) ACF de la velocidad del viento, b) ACF de la<br>dirección, c) PACF de la velocidad, d) PACF de la dirección..... | 42 |
| Figura 4.7. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento del modelo<br>RNV para los conjuntos de entrenamiento y validación. ....          | 43 |
| Figura 4.8. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento del modelo<br>RND para los conjuntos de entrenamiento y validación.....           | 44 |
| Figura 4.9. Distribución de los residuales de velocidad del viento a lo largo de la variable respuesta de<br>predicciones.....                                             | 45 |
| Figura 4.10. Distribución de los residuales de dirección del viento a lo largo de la variable respuesta<br>de predicciones.....                                            | 45 |
| Figura 4.11. Comportamiento del modelo RNV en el tiempo.....                                                                                                               | 46 |
| Figura 4.12. Comportamiento del modelo RND en el tiempo.....                                                                                                               | 46 |

|                                                                                                                                                      |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 4.13. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento y validación del modelo RNV-ET.....                        | 47 |
| Figura 4.14. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento y validación del modelo RND-ET.....                        | 48 |
| Figura 4.15. Comparación entre los valores reales y predichos por el modelo RNV-ET.....                                                              | 49 |
| Figura 4.16. Comparación entre los valores reales y predichos por el modelo RND-ET. ....                                                             | 49 |
| Figura 4.17. Comparación de la respuesta del modelo RNV-ET con respecto a datos reales de prueba. ....                                               | 50 |
| Figura 4.18. Comparación de la respuesta del modelo RND-ET con respecto a datos reales de prueba. ....                                               | 51 |
| Figura 4.19. Distribución de los residuales de velocidad del viento en función de las predicciones, modelo RNV-ET.....                               | 52 |
| Figura 4.20. Distribución de los residuales de dirección del viento en función de las predicciones, modelo RND-ET.....                               | 52 |
| Figura 4.21. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RNV, a) Ganancia de Kalman y b) Covarianza de Kalman. ....    | 53 |
| Figura 4.22. Evolución temporal del modelo RNV, junto con una comparación de su desempeño con el modelo RNV-FK.....                                  | 54 |
| Figura 4.23. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RND, a) Ganancia de Kalman y b) Covarianza de Kalman. ....    | 54 |
| Figura 4.24. Evolución temporal del modelo RNV, junto con una comparación de su desempeño con el modelo RND-FK.....                                  | 55 |
| Figura 4.25. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RNV-ET, a) Ganancia de Kalman y b) Covarianza de Kalman. .... | 56 |
| Figura 4.26. Evolución temporal del modelo RNV-ET, junto con una comparación de su desempeño con el modelo RNV-ET-FK.....                            | 56 |
| Figura 4.27. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RND-ET, a) Ganancia de Kalman y b) Covarianza de Kalman. .... | 57 |
| Figura 4.28. Evolución temporal del modelo RND-ET, junto con una comparación de su desempeño con el modelo RND-ET-FK. ....                           | 58 |
| Figura 4.29. Polígono de delimitación de las estaciones del INIFAP con coordenadas extremas. ....                                                    | 59 |
| Figura 4.30. Mapa de contorno de velocidad del viento.....                                                                                           | 60 |
| Figura 4.31. Mapa de vectores de magnitud y dirección del viento. ....                                                                               | 61 |
| Figura 4.32. Mapa del modelo RNE-IDW, a) RNE-IDW a las 8 horas, b) RNE-IDW a las 16 horas, c) RNE-IDW a las 24 horas.....                            | 62 |
| Figura 4.33. Mapa de contorno de la densidad promedio del viento por hora en el estado de Aguascalientes.....                                        | 64 |

# CAPÍTULO I

## INTRODUCCIÓN

La dinámica del viento, que considera tanto su velocidad como su dirección, es un componente clave en la interacción entre la atmósfera y el entorno urbano. El viento no solo regula el intercambio de aire y temperatura en las ciudades, sino que también participa directamente en la dispersión de contaminantes y la calidad del aire [1]. En el contexto de la sustentabilidad urbana, comprender cómo se mueve el aire permite mejorar la ventilación natural y la planificación urbana, reduciendo los niveles de contaminación. Así, la dinámica del viento es fundamental para diseñar ciudades más saludables y sostenibles [2].

En ese sentido, la contaminación del aire es un desafío ambiental que afecta directamente la calidad del aire, generando problemas de morbilidad y mortalidad en humanos y dañando el medio ambiente, siendo considerada como una de las principales prioridades mundiales en salud [3]. Por ello, durante años se ha mantenido un interés por vigilar y mejorar la calidad del aire para preservar la salud pública, minimizar los impactos ambientales y cumplir con las regulaciones en materia de aire, dado que, los criterios medioambientales son los que mejor reflejan la calidad de vida en una sociedad [4], [5].

No obstante, la influencia del viento va más allá de la calidad del aire y tiene un impacto considerable en la sustentabilidad urbana [6]. En ciudades como Aguascalientes, la dinámica del viento presenta un desafío en el contexto de la transición de un modelo de ciudad horizontal a uno vertical. Este impacto implica una densificación de la población y un uso más eficiente del suelo, lo que puede generar beneficios en términos de infraestructura y servicios.

Se considera que la velocidad del viento no solo afecta el transporte de partículas por convección, sino que también influye significativamente en la dispersión de contaminantes atmosféricos y otros elementos en el entorno urbano [7]. Entre estos aspectos se encuentran la producción de energía eólica, en donde la velocidad del viento es fundamental para determinar el potencial de generación de energía a través de turbinas eólicas, contribuyendo a fuentes de energía renovable y sostenible [8]. También, en el diseño de edificaciones, toda vez que el viento influye en la forma y orientación de los

edificios para maximizar la ventilación natural, reducir la necesidad de climatización artificial y mejorar la eficiencia energética; de manera que un buen diseño puede aprovechar las corrientes de aire, reduciendo la huella de carbono y mejorando el confort de los habitantes [9].

Asimismo, la velocidad y dirección del viento son fundamentales para garantizar la estabilidad estructural de los edificios, especialmente en zonas expuestas a fuertes vientos o huracanes [10]. Además, el viento también es un factor crítico en la propagación del fuego, especialmente en áreas urbanas o forestales cercanas. Al conocer su dinámica permite predecir la orientación de los incendios, mejorar las estrategias de evacuación y recursos para su control [11].

Diversos estudios han encontrado que el conocimiento de la dinámica del viento es fundamental tanto en arquitectura como en el urbanismo, ya que influye significativamente en los niveles de confort y salud humana. Por lo tanto, ha sido considerado lograr un equilibrio en el diseño urbano con variables climáticas y territoriales de cada lugar [12]. Además, al aprovechar los beneficios del entorno natural, como la luz y la ventilación naturales en ciudades grandes, se busca mejorar la calidad de los entornos urbanos, estableciendo un sistema de evaluación de la ventilación del aire para lograr un entorno macroeólico aceptable [13].

Por ello, se han empleado diversas técnicas de modelado matemático para pronosticar la dinámica del viento para análisis de la calidad del aire y la sustentabilidad urbana [14]. Se ha observado que las Redes Neuronales Artificiales (RNA) y otros tipos de modelos, como los Modelos Autorregresivos Integrados de Medias Móviles (ARIMA) [15], han mejorado la precisión en el pronóstico de parámetros meteorológicos y la concentración de contaminantes en comparación con métodos tradicionales. Estos modelos han demostrado ser efectivos para manejar datos complejos y no lineales. Mientras tanto, otros modelos, como el de Regresión Lineal Múltiple (RLM), han mostrado limitaciones en la estimación precisa de concentraciones de contaminantes [16]. Además, modelos eulerianos y métodos numéricos avanzados, como el *Weather Research and Forecasting Model with Chemistry* (WRF-Chem), han destacado por su capacidad para integrar múltiples parámetros y pronósticos de la calidad del aire, identificando áreas de alto riesgo [17]. El uso de técnicas como el método clasificador Gamma y los modelos de dispersión de tipo Gaussiano, han mostrado efectividad en el pronóstico de concentraciones de contaminantes en un punto espacial específico [18], [19].

Actualmente, uno de los principales desafíos es la alta variabilidad del viento a escalas pequeñas, cambiando de manera significativa en distancias cortas dentro de la ciudad de Aguascalientes. Este

comportamiento es influenciado por factores locales como la topografía, la disposición de las edificaciones, y la vegetación urbana. Asimismo, las estaciones de monitoreo suelen estar dispersas y, en muchos casos, son insuficientes para cubrir toda la extensión urbana de manera adecuada. Esta escasez de estaciones, junto con la forma en que se reportan los datos (generalmente en intervalos amplios o de manera poco detallada), resulta en una significativa ausencia de información, particularmente en áreas donde los cambios en el viento son más drásticos debido a las características locales. La falta de datos detallados en puntos geográficos específicos, así como la alta variabilidad del viento en microclimas específicos dentro de la ciudad, impide una mejor comprensión de la dinámica del viento a pequeña escala, lo cual es un problema para la toma de decisiones en áreas como el diseño urbano, la gestión de recursos y la planificación ambiental.

Debido a ello, este proyecto se centra en utilizar técnicas de *Machine Learning* (ML). En particular, se emplearon las RNA para el pronóstico de los parámetros meteorológicos de velocidad y dirección del viento, ya que han demostrado una mejora en la precisión de los modelos meteorológicos, en comparación con otros métodos tradicionales y tienen la capacidad para modelar sistemas altamente no lineales y caóticos [20], [21].

Los modelos de RNA pueden presentar dificultades en la precisión de los pronósticos. Sin embargo, existen herramientas predictivas-correctivas, como son los Filtros de Kalman (FK), los cuales son utilizados ampliamente en sistemas de seguimientos de señales, como la estabilización de aeronaves, el seguimiento de objetos en movimiento y la previsión meteorológica [22]. Estas herramientas, debido a su capacidad para manejar incertidumbres, permiten realizar ajustes en las salidas de los modelos, lo que contribuye a obtener resultados más precisos en las predicciones [23].

Por lo tanto, este proyecto propone combinar el uso de RNA con FK. Aunque no se han utilizado previamente para la modelación de la dinámica del viento, han demostrado su potencial para mejorar significativamente la calidad de los pronósticos de velocidad y dirección del viento.

En la actualidad, el acceso y entendimiento de la información es fundamental, especialmente en el análisis del viento. En este contexto, el uso de Sistemas de Información Geográfica (SIG) se convierte en una herramienta clave, ya que permite mapear y visualizar patrones de viento en diversas áreas, siendo especialmente útil en aplicaciones en enlaces de comunicaciones [24], planificación urbana y diseño de parques eólicos. Los SIG se utilizan comúnmente para analizar el uso del suelo, gestionar recursos hídricos y planificar emergencias, además de mapear zonas de riesgo [25].

Sin embargo, para obtener una visualización más detallada, es necesario contar con datos precisos en múltiples puntos geográficos. Aquí es donde técnicas como la interpolación *Inverse Distance Weighting (IDW)* permiten estimar valores en áreas donde existe una ausencia de datos, como en zonas sin estaciones de monitoreo, mejorando así la representación espacial del viento. Cabe señalar que este tipo de técnicas tienen una presencia significativa en el mapeo de la calidad del aire [26], en la estimación de variables del suelo como la humedad y la composición química [27], así como en el análisis de la distribución de enfermedades en poblaciones a partir de casos reportados [28].

Con base en los desafíos identificados, este proyecto propone integrar diversas herramientas de modelado para abordar la dinámica del viento en la ciudad de Aguascalientes. Se utilizarán técnicas de RNA para pronosticar la velocidad y dirección del viento, combinadas con FK para mejorar la precisión de los pronósticos. Además, la interpolación *IDW* permitirá estimar valores en áreas sin estaciones de monitoreo en conjunto con los SIG, brindando una representación espacial más completa de la dinámica del viento.

## **1.1 OBJETIVOS**

### **1.1.1 Objetivo General**

Diseñar modelos de *ML* para pronóstico de la dinámica de la velocidad y la dirección del viento a partir de bases de datos de la ciudad de Aguascalientes.

### **1.1.2 Objetivos Específicos**

- Analizar la dinámica del viento a partir de bases de datos históricas de la ciudad de Aguascalientes.
- Obtener modelos predictivos basados en RNA.
- Ampliar los modelos predictivos temporales hacia espacio-temporales.
- Incrementar la precisión de los pronósticos mediante la aplicación de técnicas avanzadas de corrección, como el FK.
- Acoplar las técnicas de interpolación *IDW* a los modelos predictivos espacio-temporales.

# CAPÍTULO II

## MARCO TEÓRICO

### 2.1 Dinámica del viento

El viento se describe como el desplazamiento del aire causado por las variaciones en la presión atmosférica entre dos ubicaciones, así como por la rotación de la Tierra. Estas diferencias de presión surgen debido a las variaciones de temperatura en esos puntos, lo que produce diferencias en la densidad del aire. El aire se mueve para equilibrar estas diferencias, generando así el viento [29].

La dinámica del viento es esencial para comprender los procesos atmosféricos y climáticos, es analizada a partir de algunos parámetros meteorológicos medidos por una estación de monitoreo. Entre estos parámetros se encuentran la velocidad y la dirección del viento. La velocidad del viento se encarga de la intensidad del movimiento del aire, mientras que la dirección indica el origen del viento. Ambos parámetros proporcionan una perspectiva amplia sobre cómo el viento interactúa con otros elementos meteorológicos, por lo que comprender la dinámica del viento es necesario por su influencia en fenómenos atmosféricos, como la concentración y dispersión de contaminantes y la formación de patrones climáticos [30], lo que impacta directamente en la sustentabilidad urbana [31].

### 2.2 Contaminación del aire

La contaminación del aire, influenciada por la dinámica del viento, se complica en áreas donde las corrientes de aire son limitadas o donde las condiciones meteorológicas provocan una mayor concentración de contaminantes[2]. Esta contaminación ocurre cuando el entorno se ve afectado por la presencia de cualquier agente químico, físico o biológico en concentraciones altas; siendo nociva para la salud humana, la flora, la fauna y bienes de cualquier naturaleza [32]. Entre los principales contaminantes se encuentran la materia particulada, el monóxido de carbono (CO), el ozono (O<sub>3</sub>), el dióxido de nitrógeno (NO<sub>2</sub>), el dióxido de azufre (SO<sub>2</sub>) y Partículas Suspendidas Totales (PST). Dado que es considerada una amenaza para la salud pública, durante años se ha mantenido una vigilancia constante de los contaminantes a través de diversas redes de monitoreo [33].

La contaminación del aire tiene un impacto significativo en la sociedad, afectando la salud humana al provocar enfermedades respiratorias como el asma, cardiovasculares, cáncer de pulmón y efectos en el desarrollo cognitivo. En el ámbito ambiental, contribuye al cambio climático, la acidificación de ecosistemas y el daño a la vegetación. Mientras que, a nivel económico incrementa los costos de atención médica, causa deterioro en infraestructuras e impacta a la agricultura [34].

La relación de la salud del ser humano con la contaminación del aire y sus efectos depende de las características físicas y químicas de los contaminantes, así como a la anatomía, fisiología, patrón de respiración y actividades que realiza la persona. Sin embargo, se deben de considerar los problemas en el sistema respiratorio debido a que al ingresar partículas gruesas y finas se afectan las vías respiratorias superiores y las más pequeñas, alvéolos y nariz, respectivamente. Por lo que, se considera que los mecanismos de defensa particulares del sistema respiratorio son alterados por los diferentes contaminantes del aire, siendo que, los niños se encuentran más susceptibles que los adultos por sus condiciones biológicas a cualquier efecto en la salud respiratoria [35], [36].

Por otro lado, en lo ambiental afecta a la flora y la fauna ocasionando la destrucción de la biodiversidad, lo que genera un aumento considerable en la extinción de algunas especies, enfermedades infecciosas y cambios en la cadena alimentaria. Así mismo, las sustancias químicas presentes en el suelo distorsionan los procesos de desarrollo de diversas especies vegetales. Además, las diferentes actividades industriales y de transporte destruyen bosques, lo que provoca la erosión del suelo y dificulta la absorción de nutrientes y agua necesaria para el desarrollo de las plantas [37].

## **2.3 Sustentabilidad urbana**

La idea de sustentabilidad surgió como una respuesta a la crisis del sistema global que se hizo evidente tras la revolución industrial del siglo XX. Esta crisis reveló problemas económicos, sociales, ambientales y urbanos que transformaron el mundo de una manera indescrptible. Al enfrentarse a una amenaza de posible crisis que podría poner en peligro tanto a la humanidad como al entorno natural, nació una nueva era, la revolución de la sustentabilidad [38]. Entonces, de acuerdo con el Informe de la Comisión Mundial sobre el Medio Ambiente y el Desarrollo, conocido como informe Brundtland, la sustentabilidad se define como la capacidad de “satisfacer las necesidades actuales sin comprometer

la capacidad de las futuras generaciones para satisfacer sus propias necesidades” [39]. Esta definición destaca la importancia de lograr un equilibrio entre los ámbitos social, económico y ambiental [40].

En este contexto, la sustentabilidad urbana es la encargada de lograr este equilibrio en el ámbito de las ciudades y áreas urbanas. Las ciudades son centros de una población elevada con un consumo excesivo de recursos y una alta generación de desechos. Por ello, la sustentabilidad urbana se enfoca en reducir el impacto ambiental al implementar prácticas que permitan disminuir la huella de carbono, gestionar los recursos con eficiencia y preservar los espacios verdes [41]. También, fomenta el desarrollo sostenible a través de la construcción de edificaciones y la planificación urbana de tal manera que se disminuya el uso de recursos y energía, utilizando tecnologías limpias y materiales sostenibles. Finalmente, busca mejorar la calidad de vida asegurando que las áreas urbanas sean accesibles, saludables y seguras, creando ciudades respetuosas con el medio ambiente [42].


El desarrollo sustentable puede enfocarse en los parámetros meteorológicos de la velocidad y dirección del viento, ya que estos desempeñan un papel importante en la ventilación natural de los espacios, la dispersión de los contaminantes y la eficiencia energética de los edificios. Además, comprender la dinámica del viento permite planificar el diseño urbano para mejorar la calidad del aire, optimizar el uso de recursos energéticos y contribuir a la creación de entornos urbanos más sostenibles y resilientes, incluyendo su aplicación en la generación de energía eólica, estudios de impacto ambiental y la gestión de riesgos como los incendios [42].

## **2.4 Monitoreo de parámetros meteorológicos**

El análisis de los parámetros meteorológicos es indispensable para modelar el transporte de los contaminantes del aire, por lo que su estudio es fundamental para interpretar adecuadamente la evolución de la concentración de contaminantes en la atmósfera. El monitoreo atmosférico no solo mide los valores de los parámetros meteorológicos y de calidad del aire en una zona de estudio, sino que también facilita el análisis de las concentraciones y comportamientos de los contaminantes. Esto permite advertir a la población sobre la calidad del aire y las condiciones meteorológicas adversas [43], [44].

El monitoreo de parámetros meteorológicos es un proceso de análisis del comportamiento atmosférico. Este monitoreo es realizado a través de equipos e instrumentos especializados que miden

variables como la velocidad y dirección del viento, la temperatura, la humedad y la presión atmosférica. Estos equipos e instrumentos forman parte de las estaciones meteorológicas, las cuales conforman unidades de observación localizadas en diferentes sitios. A su vez, un conjunto de estas estaciones forma una red meteorológica, diseñada para abarcar una mayor área y proporcionar datos representativos del entorno. De tal manera que, estas redes son operadas por medio de sistemas de monitoreo, los cuales integran y procesan la información para aplicaciones específicas, como pronóstico del tiempo, estudios climáticos y análisis de la calidad del aire [45]. Tal como se muestra en la Figura 2.1.



*Figura 2.1 Monitoreo de parámetros meteorológicos.*

En México, varios sistemas y redes de monitoreo se encargan de la medición y el análisis de parámetros meteorológicos, proporcionando información esencial para la previsión del clima, la gestión de recursos naturales y la protección civil. Entre los principales se encuentra el Servicio Meteorológico Nacional (SMN) [46], que opera una red de estaciones meteorológicas como la Comisión Nacional del Agua (CONAGUA) [47] con un sistema de monitoreo y alerta temprana.

Además, universidades y centros de investigación, como la Universidad Nacional Autónoma de México (UNAM), contribuyen en esta área por medio de sistemas especializados como la Red Universitaria de Observatorios Atmosféricos (RUOA) [48]. Mientras que, el Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias (INIFAP) desempeña un papel fundamental al monitorear las condiciones ambientales y evaluar su impacto en la agricultura, contribuyendo al desarrollo rural sustentable [49].

## 2.5 Estaciones meteorológicas

Las estaciones meteorológicas permiten recopilar datos relacionados a las condiciones climáticas en coordenadas específicas a partir de un conjunto de instrumentos y sensores. Estos sistemas permiten medir parámetros meteorológicos en tiempo real, tanto a nivel local como regional [50].

Las estaciones meteorológicas tradicionales requieren la presencia de un observador capacitado para recopilar y transmitir la información meteorológica. Mientras que, las estaciones automáticas están diseñadas para recolectar datos en ubicaciones remotas y transmitirlos de forma automática. Los instrumentos meteorológicos pueden ser de tipo medidor o registrador, pero lo ideal siempre será que el dispositivo mida los datos de forma precisa [50].

La información recopilada facilita el análisis de patrones climáticos, lo que a su vez permite realizar pronósticos a corto y largo plazo. En la Tabla 2.1. Se muestran algunos de los parámetros meteorológicos típicos que se incluyen en las estaciones de monitoreo, junto con los instrumentos utilizados para su medición y las unidades de medida comúnmente empleadas [43], [44], [51].

*Tabla 2.1. Parámetros meteorológicos que suelen ser medidos en las estaciones de monitoreo.*

| Parámetro meteorológico          | Instrumento de medición | Unidad de medida                                                                 |
|----------------------------------|-------------------------|----------------------------------------------------------------------------------|
| Radiación solar                  | Piranómetro             | W/m <sup>2</sup>                                                                 |
| Temperatura                      | Termómetro              | °C, °F, K                                                                        |
| Presión atmosférica              | Barómetro               | mmHg, Pa, atm                                                                    |
| Humedad relativa                 | Higrómetro              | % $\left( \frac{\text{Humedad absoluta}}{\text{Cantidad de saturación}} \right)$ |
| Precipitación pluvial            | Pluviómetro             | mm, L/m <sup>2</sup> , L/h                                                       |
| Velocidad y dirección del viento | Anemómetro              | m/s, km/h                                                                        |

El anemómetro es el dispositivo utilizado para medir tanto la velocidad como la dirección del viento. Cuenta con un sensor, denominado veleta, el cual determina la dirección desde la que sopla el viento; mientras que el otro, compuesto por tres semiesferas ligeras, mide la velocidad del viento al girar [50].

## 2.6 Densidad de potencia eólica

La densidad de potencia eólica (*PD*) es una medida que permite representar la cantidad de energía que el viento puede generar por unidad de área, generalmente expresada en vatios por metro

cuadrado,  $(W/m^2)$ . Esto es esencial para evaluar el potencial eólico de una región, dado que permite conocer cuánta energía se puede generar a partir del viento en una ubicación específica. Además, es clave en el diseño y la ubicación de parques eólicos, maximizando la conversión de energía cinética del viento en electricidad. Se calcula según la Ecuación 1 [52].

$$PD = \frac{1}{2} \rho v^3 \quad (\text{Ec.1})$$

Donde  $\rho$  representa la densidad del aire ( $\rho = 1.225 \frac{kg}{m^3}$ , valor correspondiente a condiciones estándar de presión (1atm) y temperatura (15°C) a nivel del mar [53]), y  $v$  es la velocidad del viento.

## 2.7 Análisis Exploratorio de Datos

Algunos campos de la ciencia almacenan su información en diferentes bases de datos electrónicas y para tomar decisiones informadas basadas en estos datos, es fundamental realizar un análisis adecuado de los mismos. En este sentido, se aplica la minería de datos, que implica un proceso de análisis sistemático. Una de las principales etapas clave en la minería de datos es el Análisis Exploratorio de Datos (EDA), el cual permite visualizar y comprender la información recopilada, y generar hipótesis para análisis posteriores [54].

Entre los componentes esenciales del EDA se encuentran la síntesis de datos, el análisis estadístico y la visualización [54]. Para comprender la estructura y características de los datos previo a la aplicación de modelos o análisis más complejos se utilizan componentes clave que permiten resumir y mostrar esta información [54]. Uno de estos componentes es la media  $\bar{x}$  (Ecuación 2), que representa el promedio de los datos y proporciona una idea del valor central del conjunto.

$$\bar{x} = \frac{\sum_{i=1}^N x_i}{N} \quad (\text{Ec. 2})$$

Donde  $x_i$  representa cada valor individual del conjunto de datos, mientras que  $N$  es el número total de observaciones.

Por otro lado, la mediana  $M$  (Ecuación 3) permite identificar la tendencia central, considerando el valor que se encuentra en medio de los datos ordenados, lo cual es especialmente útil para mitigar el impacto de valores atípicos.

$$M = \begin{cases} x_{(n+1)/2}, & \text{si } N \text{ es impar} \\ \frac{x_{(n/2)} + x_{(n/2+1)}}{2}, & \text{si } N \text{ es par} \end{cases} \quad (\text{Ec. 3})$$

La desviación estándar  $\sigma$  es otra medida importante que indica cómo se dispersan los datos alrededor de la media como se muestra en la Ecuación 4, lo que permite evaluar la variabilidad del conjunto [55].

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (\text{Ec. 4})$$

Para visualizar la distribución de los datos, se utilizan los histogramas, que son gráficos de barras que muestran cuántos datos se encuentran en los diferentes rangos, esta representación facilita la identificación de patrones en la distribución. En el ámbito meteorológico, el conjunto de distribución de frecuencias conocido como rosa de los vientos permite observar la velocidad y dirección del viento, mostrando una visualización clara de su comportamiento [55].

En el análisis de series temporales, se utilizan la Función de Autocorrelación (*ACF*) y la Función de Autocorrelación Parcial (*PACF*). La *ACF* (Ecuación 5) mide la correlación de un conjunto de datos consigo mismo, utilizando la covarianza entre un dato en el tiempo  $t(X_t)$  y su valor en un tiempo previo ( $X_{t-k}$ ). Esto permite identificar patrones cíclicos en los datos.

$$ACF(k) = \frac{Cov(X_t, X_{t-k})}{\sigma^2} \quad (\text{Ec. 5})$$

En contraste, la *PACF* (Ecuación 6) también examina correlaciones en diferentes retrasos  $k$ , pero elimina el efecto de las correlaciones en retrasos anteriores. Esto proporciona un entendimiento más claro de las relaciones directas entre las observaciones, sin la influencia de otras correlaciones previas [56].

$$PACF(k) = Cov(X_t, X_{t-k} | X_{t-1}, \dots, X_{t-(k-1)}) \quad (\text{Ec. 6})$$

## 2.8 Inteligencia Artificial y Aprendizaje Automático

La Inteligencia Artificial (IA) es la capacidad de las máquinas para simular la inteligencia humana, como el aprendizaje y la toma de decisiones, procesando grandes cantidades de datos, *Big Data*, identificando patrones y tendencias [57]. Dentro de la IA, el aprendizaje automático (*Machine Learning*, *ML*) se ha destacado por permitir que los sistemas mejoren su rendimiento con el tiempo, sin necesidad de una programación explícita. A través de algoritmos, el *ML* puede predecir situaciones basadas en datos históricos y patrones de entrada. Existen diversas ramas dentro del *ML*, tales como el aprendizaje supervisado, que utiliza datos etiquetados para entrenar modelos, el aprendizaje no supervisado, que busca patrones en datos no etiquetados, y el aprendizaje por refuerzo, que permite que los modelos aprendan mediante pruebas y errores, adaptándose a diferentes entornos y condiciones [58], [59], [60].

Dentro del *ML* se emplean diversos modelos que permiten procesar y analizar grandes cantidades de datos. Los modelos de previsión estiman nuevos datos a partir de datos históricos, mientras que los modelos de clasificación organizan la información en categorías predefinidas. Por otro lado, los modelos de *clustering* agrupan datos similares según sus características y los modelos de regresión generan tendencias a partir de las relaciones entre las variables. Un modelo avanzado de *ML* son las RNA, las cuales imitan el funcionamiento del cerebro humano, permitiendo identificar patrones en conjuntos de datos complejos [58].

## 2.9 Redes Neuronales Artificiales

Las RNA son especialmente útiles para identificar patrones en sistemas altamente no lineales o complejos. Inspiradas en el cerebro humano, las RNA están formadas por neuronas interconectadas organizadas en capas, lo que permite que las máquinas procesen datos de manera similar a los seres humanos [61]. Junto con otros algoritmos, como los genéticos, las RNA son comúnmente utilizadas en el pronóstico de parámetros meteorológicos y la calidad del aire [62], [63].

### 2.9.1 Arquitectura de las Redes Neuronales Artificiales

Las neuronas en una RNA se organizan en unidades estructurales llamadas capas. Dentro de cada capa, las neuronas se agrupan en conjuntos neuronales, y suelen ser del mismo tipo. Una RNA está

formada por una o más capas, como se muestra en la Figura 2.2. Existen tres tipos principales de capas como lo son la capa de entrada, compuesta por neuronas que reciben información o señales del entorno; la capa de salida formada por neuronas que generan la respuesta de la red; y la capa oculta, en la cual las neuronas no están directamente conectadas con el entorno. La salida  $a_i$  de un nodo  $i$  (una neurona específica dentro de la red) en una RNA se describe mediante la Ecuación 7 [64], [65].

$$a_i = f \left( \sum_{j=1}^n w_{ij} x_j + b_i \right) \quad (\text{Ec. 7})$$

Donde la ecuación es una sumatoria de las  $n$  entradas  $x_j$  multiplicadas por un peso  $w_{ij}$ , que representa la conexión entre la neurona de entrada  $j$  y la neurona  $i$ . Además, se considera un sesgo  $b_i$  que ajusta la salida de la neurona. Esta sumatoria constituye el argumento de una función de activación  $f$ , la cual determina la activación de la neurona y, por lo tanto, la respuesta de la RNA [64], [65].




Figura 2.2. Capas de una RNA.


### 2.9.2 Tipos de Redes Neuronales

Se destacan varios tipos de Redes Neuronales, siendo las RNA la forma más básica y versátil. Este tipo de red también se conoce como *Vanilla Neural Networks*, *Feedforward Neural Networks (FNN)* o Perceptrón. Además de las RNA, existen las Redes Neuronales Convolucionales (*CNN*), diseñadas

para el procesamiento de imágenes y la detección de patrones. Por otro lado, las Redes Neuronales Recurrentes (*RNN*) son ideales para trabajar con secuencias de datos, como texto o series temporales. También, existen otras variantes como las Redes Generativas Antagónicas (*GAN*) que generan nuevos datos, y las Redes de Memoria a Largo y Corto Plazo (*LSTM*), que mejoran la capacidad de recordar información a lo largo de secuencias largas [66] [67].

En este sentido, las *FNN* son un tipo de red neuronal caracterizada por una estructura dirigida, como se muestra en la Figura 2.3, en la cual la información fluye en una sola dirección desde la capa de entrada hacia la capa de salida, sin ciclos ni bucles. En este modelo, a cada nodo  $i$  se le asigna una variable de estado, y cada conexión entre los nodos  $i$  y  $j$  está asociada a un peso que modula la influencia de la entrada en el nodo  $i$ . Además, cada nodo  $i$  tiene un umbral propio que genera la activación del nodo [64].

Para cada nodo  $i$ , se define una función de activación que depende de los pesos de sus conexiones, del umbral y de los estados de los nodos  $j$  conectados a él. Esta función determina el nuevo estado del nodo  $i$  y, en consecuencia, afecta la transmisión de la información por medio de la red. Las *FNN* son utilizadas en diversas aplicaciones, desde la clasificación hasta la regresión, debido a su capacidad para modelar datos complejos [64], [68].



2.3 Esquema de la arquitectura de una RNA Feedforward [68].

## 2.10 Filtro de Kalman

El problema de filtrado busca desarrollar un algoritmo para estimar una variable afectada por ruidos y errores, aislándolos para obtener un estimador mejor. Un avance significativo en este campo fue el FK, propuesto por Rudolf Kalman en 1960 en su trabajo <<A New Approach to Linear Filtering and Prediction Problems>>. Este algoritmo estima variables a partir de datos medidos en dos pasos, el primero predice el estado del sistema y, el segundo, incorpora las observaciones corregidas. El objetivo es lograr un estimador óptimo en términos del Error Cuadrático Medio (MSE), procesando todas las medidas disponibles, independientemente de su precisión, utilizando el conocimiento del sistema y la descripción del ruido y errores. Al ser un proceso recursivo se pueden incorporar las observaciones nuevas sin tener que reformular todo el algoritmo [65].

Entre las principales aplicaciones del FK se encuentran el seguimiento de objetos (*Tracking*), la estimación de canales en sistemas de comunicación inalámbrica, la visión por computadora, la estimación y predicción de series temporales financieras, el diseño de sistemas de control dinámicos, la estimación de la dinámica de sistemas biológicos y la mejora de predicciones meteorológicas a partir de datos de satélites y estaciones meteorológicas [65]. El FK tiene una aplicación importante en las RNA, donde se utiliza para mejorar la estimación y el seguimiento de estados en sistemas dinámicos, optimizando el aprendizaje y la estabilidad del modelo. A continuación, se describe cómo el FK realiza este proceso por medio de las etapas de predicción y corrección. Las ecuaciones que sustentan este algoritmo se consideran desde la Ecuación 9 hasta la Ecuación 13 [69].

### 1. Predicción

La primera etapa del FK es la predicción, donde se estima el estado futuro del sistema y su incertidumbre asociada. La predicción del estado en el tiempo  $k$ , basado en los datos del tiempo  $k - 1$ , se expresa como la Ecuación 9. En donde,  $x_k|_{k-1}$  representa el estado estimado del sistema en  $k$  y esta estimación inicial proviene del producto de la matriz de transición de estados ( $F_{k-1}$ ) con el estado previo del sistema ( $\hat{x}_{k-1}$ ), más la suma del producto de la matriz de control ( $B_k$ ) y el vector de entradas de control ( $u_k$ )[69].

$$x_k|_{k-1} = F_{k-1}\hat{x}_{k-1} + B_k u_k \quad (\text{Ec. 9})$$

Mientras que, la predicción de la incertidumbre asociada al estado estimado se realiza a través de la matriz de covarianza (Ecuación 10). En esta ecuación,  $P_{k|k-1}$  es la matriz que describe la varianza y las correlaciones del error del estado estimado. El término  $P_{k-1|k-1}$  es la covarianza de la estimación del estado en el tiempo  $k - 1$ , mientras que  $Q_{k-1}$  representa la covarianza del ruido del proceso [69].

$$P_{k|k-1} = F_{k-1}P_{k-1|k-1}F_{k-1}^T + Q_{k-1} \quad (\text{Ec. 10})$$

## 2. Corrección

La siguiente etapa es la corrección, donde el FK ajusta las predicciones a partir de las observaciones reales ( $z_k$ ) disponibles en el instante  $k$ . La Ecuación 11 corresponde a la ganancia de Kalman ( $K_k$ ), en donde se determina cuánto influirá la observación en la corrección de la predicción. Aquí  $K_k$  es una matriz que evalúa la confianza en la predicción con respecto a la confianza en las observaciones. La matriz  $H_k$  conecta el estado real del sistema con las mediciones observadas, mientras que  $R_k$  describe la incertidumbre en las observaciones. De tal manera que, la combinación de estos términos permite ajustar el estado estimado [69].

$$K_k = P_{k|k-1}H_k^T(H_kP_{k|k-1}H_k^T + R_k)^{-1} \quad (\text{Ec. 11})$$

Después, la Ecuación 12 corresponde al estado corregido ( $\hat{x}_{k|k}$ ), en donde se ajusta la predicción inicial con base en la observación y  $K_k$ . Para obtener el estado corregido es necesario sumar la predicción inicial y una corrección proporcional al error de predicción. Este error mide la diferencia entre  $z_k$  y la predicción observada.

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - (\hat{x}_{k|k-1})) \quad (\text{Ec. 12})$$

Después, la matriz de covarianza del error actualizado se calcula para reflejar la reducción de incertidumbre tras la incorporación de las observaciones. En la Ecuación 13,  $P_{k|k}$  describe la nueva incertidumbre, ajustada después de incorporar las observaciones. En donde, la matriz identidad  $I$  asegura que las correcciones no excedan las predicciones iniciales.

$$P_{k|k} = (I - H_kK_k)P_{k|k-1} \quad (\text{Ec. 13})$$

Finalmente, una vez que se calcula la covarianza, esta estimación en la salida será la entrada al sistema que se desea corregir,  $\hat{x}_{k|k}$ . A continuación, en la Figura 2.4, se muestra un esquema que representa de manera visual el funcionamiento del FK, el cual fue detallado previamente a través de las ecuaciones correspondientes. En esta figura se pueden observar las diferentes etapas del filtro, incluyendo la predicción, corrección y estimación final.




Figura 2.4. Esquema del funcionamiento del FK.

## 2.11 Sistemas de Información Geográfica

Los SIG o *Geographic Information System (GIS)* son plataformas informáticas diseñadas para la gestión y análisis de datos espaciales. Estas herramientas son esenciales en la investigación dentro de las Ciencias de la Tierra y Ambientales, debido a que permiten manipular y visualizar información geoespacial de manera eficiente. El primer SIG se estableció en 1966 y ha sido resultado de la evolución e integración de diversas aplicaciones que, anteriormente, se utilizaban de forma independiente [70].

Un SIG orientado a meteorología se compone de varios subsistemas interrelacionados que permiten la recopilación, análisis y visualización de datos. El proceso inicia con la digitalización de mapas y la recopilación de datos meteorológicos a través de imágenes satelitales, estaciones meteorológicas y radares, los cuales se almacenan en bases de datos geoespaciales para su organización. Después, los datos son procesados y analizados por medio de técnicas estadísticas y modelos predictivos, lo que transforma las imágenes en información que puede ser utilizada para el diseño de mapas y

pronósticos. Los resultados del análisis se muestran por medio de visualizaciones cartográficas como mapas interactivos y gráficos, que facilitan la comprensión de fenómenos meteorológicos complejos. Finalmente, el SIG proporciona un medio eficaz para la toma de decisiones informadas en diversos campos, incluidos el urbanismo y la sustentabilidad [15]. Este proceso se muestra en la Figura 2.5.




Figura 2.5. Esquema del uso de SIG.

## 2.12 Distancia inversa ponderada

La técnica de *IDW* es uno de los métodos de interpolación más simple. Este enfoque consiste en calcular un promedio de las muestras dentro de una ventana de análisis, donde la influencia de cada punto de muestreo disminuye de manera inversamente proporcional a la distancia al punto desconocido. En este sentido, a medida que se aleja una muestra de un punto de muestreo, su contribución al valor estimado se reduce, siguiendo una función de distancia cuadrática [71].

La interpolación en el punto de interés se lleva a cabo asignando pesos a los datos del entorno, utilizando una relación inversamente proporcional a la distancia que los separa. El valor estimado en el punto  $j$  se obtiene mediante la fórmula general expresada en la Ecuación 14 [72].

$$\hat{z}_j = \frac{\sum_{i=1}^n w_{ij} z_i}{\sum_{i=1}^n w_{ij}} \quad (\text{Ec. 14})$$

En esta ecuación,  $\hat{z}_j$  representa el valor estimado en el punto  $j$ , mientras que  $n$  es la cantidad de puntos considerados en el proceso de interpolación. Los valores  $z_i$  corresponden a los datos en los puntos  $i$  —ésimo, y  $w_{ij}$  es el peso asignado al dato en el punto  $i$  para el cálculo en el nodo  $j$ . Los pesos  $w_{ij}$  tienen un rango entre 0 y 1 para cada dato individual, y la suma total de todos los pesos es igual a 1, asegurando que cada peso sea positivo [72]. Para establecer una relación proporcional entre el peso y la distancia. La fórmula se ajusta de acuerdo con la Ecuación 15. En esta ecuación,  $d_{ij}$  representa la distancia entre los puntos  $i$  y  $j$ , y  $p$  es un exponente que regula cómo disminuye el peso a medida que aumenta la distancia.

$$w_i = \frac{1}{d_{ij}^p} \quad (\text{Ec. 15})$$

# CAPÍTULO III

## METODOLOGÍA

A continuación, se presenta la metodología propuesta en esta tesis, que se centra en la mejora y evaluación de modelos de pronóstico de los parámetros meteorológicos de velocidad y dirección del viento. Inicialmente, se llevó a cabo la recolección de datos históricos de estos parámetros, seguida de un filtrado de las bases de datos para asegurar la calidad y consistencia de los datos. A continuación, se llevó a cabo un *EDA* para identificar posibles valores atípicos, patrones y tendencias relevantes. Posteriormente, se diseñaron modelos predictivos temporales (RNV y RND) y espacio-temporales (RNV-ET y RND-ET), complementado con un análisis de los residuales de estos últimos modelos para evaluar su precisión. Para mejorar la trayectoria de los modelos predictivos, se acopló el algoritmo de FK y se establecieron las fronteras del sistema a partir de la distribución geoespacial de las estaciones en un SIG para delimitar el alcance del modelo. Posteriormente, se integraron los modelos RNV-ET y RND-ET con la interpolación *IDW*, lo que permitió apoyar a los modelos en la interpolación y extrapolación de la información en función de la ubicación y el tiempo, alcanzando áreas con ausencia de información. Finalmente, como caso de estudio, se calculó la densidad de potencia eólica en la ciudad de Aguascalientes. Esta metodología, detallada a grandes rasgos, se ilustra en la Figura 3.1.





Figura 3.1. Metodología.

### 3.1 Recolección de datos de estaciones meteorológicas

Se consultaron bases de datos de diferentes sitios de las estaciones de monitoreo ubicadas en la entidad de Aguascalientes. Inicialmente, se recolectaron datos de la Red Universitaria de

En la Figura 3.2, se muestra la ubicación geoespacial de la estación de monitoreo de la RUOA [49], de la cual se extrajo la base de datos correspondiente al período de 1 año, comprendido entre septiembre 2022 y septiembre 2023, con registros por hora. En esta base de datos se encontraron mediciones de los parámetros meteorológicos de temperatura, humedad relativa, velocidad y dirección del viento, precipitación y radiación solar.



21

que se consideraron, una de ellas es la de la RUOA. En este contexto, la distribución geoespacial de las 17 estaciones de monitoreo se muestran en la Figura 3.3 [49].

Las estaciones de estas bases de datos están distribuidas en seis de los once municipios que conforman el estado de Aguascalientes, específicamente en Aguascalientes, Pabellón de Arteaga, El Llano, San Francisco de los Romo, Tepezalá y Rincón de Romos [49]. Esta distribución se detalla en el Anexo A como Tabla A.1, que presenta el número y nombre de cada estación, junto con sus respectivas coordenadas.




Figura 3.3. Distribución geoespacial de las 17 estaciones del INIFAP en el estado de Aguascalientes.

## 3.2 Filtrado de las bases de datos

Las bases de datos de la RUOA y del INIFAP fueron procesados mediante un tratamiento de filtración utilizando *Python* [74]. Para ello, los datos, que se encontraban en archivos *.csv*, fueron cargados y tratados con la librería *Pandas* [75], [76]. Durante este proceso fue necesario aplicar criterios específicos para seleccionar y extraer únicamente los datos relevantes para análisis posteriores. En particular, se eliminan aquellos registros que contienen valores nulos o negativos, ya que estos podrían afectar la calidad de los resultados. Al procesar las bases de datos, se incluyó su lectura, filtrado, transformación y visualización. Para la RUOA, el análisis y procesamiento de la información abarcó el

período de septiembre 2022 a septiembre 2023. Mientras que, para el INIFAP, se consideró el período de enero 2022 a diciembre 2023.

Cabe destacar que, debido a los posibles sesgos que la imputación de datos podría generar en la tendencia final del modelo, se optó por descartar los registros antes mencionados, en lugar de imputarlos, para mantener la integridad de los análisis [77], [78]. De esta manera, *Python* se establece como una herramienta fundamental para el manejo y procesamiento de datos, gracias a su naturaleza como lenguaje de programación de alto nivel y sintaxis clara [79].

### 3.3 Análisis Exploratorio de Datos

Se realizó un *EDA* empleando el lenguaje de programación de alto nivel *Python* [74] en conjunto con la librería *Pandas* y *Matplotlib* [76]. En estos análisis, se calcularon la media ( $\bar{x}$ ), la mediana ( $M$ ), la desviación estándar ( $\sigma$ ) y se generaron histogramas tanto para la velocidad como para la dirección del viento. Así mismo, se elaboró una rosa de los vientos y un diagrama de cajas para representar la dirección y velocidad del viento, respectivamente. Para la elaboración de la rosa de los vientos se utilizó la biblioteca *Seaborn* [80], la cual permitió personalizar la visualización y mejorar su diseño. Estos análisis se llevaron a cabo para conocer el comportamiento o distribución de los datos, así como para determinar la existencia de valores atípicos. Se empleó la prueba de *Shapiro-Wilk* específicamente en el contexto de los histogramas para evaluar la normalidad de los datos, utilizando la librería *Scipy* [81].

Por último, para analizar las series temporales de velocidad y dirección del viento, se les aplicó la *ACF* y *PACF*. Estas herramientas permiten identificar la relación entre un estado actual de la serie temporal y sus valores en momentos pasados (rezagos) de cada uno de los parámetros analizados, velocidad y dirección del viento.

Un estado previo se considera como variable predictora si su coeficiente de correlación supera un nivel de significancia predefinido. En este sentido, los rezagos que muestran correlaciones significativas indican una relación buena entre el estado actual y los estados previos, lo que los hace útiles para los modelos de RNA's. Por ello, al identificar rezagos significativos a través de los análisis de *ACF* y *PACF*, se seleccionaron el número de estados previos a utilizar dentro de los modelos. Para

ello, se utilizó la librería *Statsmodels* [82], que ofrece una amplia gama de herramientas para la estimación de diversos modelos estadísticos.

### **3.4 Diseño de modelo de RNN para pronósticos de velocidad y dirección del viento**

En esta sección se presenta el diseño de cuatro modelos de *RNN* para pronóstico de la dinámica del viento. Estos modelos se dividen en dos enfoques, uno temporal basado en los datos de la RUOA, y otro espacio-temporal utilizando los datos del INIFAP. Para cada enfoque se desarrollaron dos modelos, uno para el pronóstico de la velocidad y otro para la dirección del viento.

#### *3.4.1 Diseño de modelo de RNN temporal*

Se entrenaron dos modelos de *RNN* para pronosticar la dinámica tanto de la velocidad como de la dirección del viento, denominados RNV y RND, respectivamente. Estos modelos fueron construidos utilizando bases de datos de la RUOA con variables temporales de entrada como el día del año (día) y la hora del día (hora), junto con parámetros adicionales como el estado previo ( $v_{v1}$  para velocidad y  $d_{d1}$  para dirección del viento) y la temperatura (Temperatura). Para su desarrollo, se empleó la biblioteca *Keras* [83]. Cabe destacar que ambos modelos son de carácter temporal, ya que dependen exclusivamente del tiempo y del estado previo para velocidad y para dirección del viento.

La arquitectura del modelo RNV consistió en 4 neuronas en la capa de entrada, seguidas de 4 capas ocultas con 100, 200, 150 y 250 neuronas respectivamente, todas utilizando la función de activación *ReLU*. La capa de salida se compuso de una sola neurona con una activación lineal. El esquema de esta arquitectura se muestra en la Figura 3.4. La arquitectura, así como los hiperparámetros del modelo, las funciones de activación, función de pérdida, optimizador, entre otros, se seleccionaron de manera empírica. Para evaluar el rendimiento del modelo se reservó el 20% del conjunto de datos para pruebas, mientras que el 80% restante se utilizó para el entrenamiento, del cual el 10% fue utilizado para la validación.

El modelo fue entrenado durante 30 épocas para ajustar los parámetros y obtener una predicción precisa. En el entrenamiento, se empleó el optimizador *Adam* y la función de pérdida se definió como el *MSE*. Además, se aplicó un proceso de escalado relativo para preparar los datos de entrenamiento. Tanto los parámetros de entrada como los de salida fueron normalizados para ajustarse a un rango

entre -1 y 1, con el fin de facilitar la convergencia del modelo y también para que las magnitudes de los parámetros tengan el mismo peso durante el entrenamiento del modelo, para ello se utilizó la librería *MinMaxScaler*.




Figura 3.4. Esquema del modelo RNV.

En cuanto al modelo RND, se mantuvo una configuración similar, con 4 neuronas en la capa de entrada, seguidas de 4 capas ocultas que contenían 100, 300, 300 y 350 neuronas respectivamente, todas utilizando la función de activación *ReLU*. La capa de salida estuvo compuesta por una única neurona destinada al pronóstico de la dirección del viento, con una activación lineal. Esta arquitectura se muestra en la Figura 3.5. Todos los demás hiperparámetros del modelo, incluido el uso del optimizador *Adam*, el escalado y la función de pérdida del *MSE*, se mantuvieron similares al modelo de pronóstico de la velocidad del viento, entrenado durante 30 épocas. Se utilizó la librería de *Keras* para el diseño, entrenamiento y evaluación del modelo al ser considerada una librería de alto nivel que facilita el diseño y el uso de RNA [84].




Figura 3.5. Esquema del modelo RND.

### 3.4.2 Diseño de modelo de RNN espacio-temporal

Se entrenaron dos modelos de *RNN* con datos del INIFAP, uno para pronosticar la velocidad y otro para la dirección del viento, incorporando variables temporales como el día del año y la hora del día. El modelo diseñado para los pronósticos de la velocidad del viento se denomina RNV-ET, mientras que para dirección del viento RND-ET. Estos otros modelos integran como variables extras parámetros espaciales (latitud y longitud), así como también, el estado previo, para ello se empleó la biblioteca *Keras* [83].

En el caso del modelo RNV-ET, la arquitectura de la RNA constó de 4 neuronas en la capa de entrada, seguidas de 4 capas ocultas con 100, 300, 300 y 350 neuronas respectivamente, todas utilizando la función de activación *ReLU*. La capa de salida se compuso de una única neurona con activación lineal. Esta arquitectura se presenta en la Figura 3.6.




Figura 3.6. Esquema del modelo RNV-ET.

Para evaluar el rendimiento del modelo, se reservó el 20% del conjunto de datos para pruebas, mientras que el 80% restante se utilizó para el entrenamiento, del cual el 10% fue utilizado para la validación. El modelo se entrenó durante 30 épocas utilizando el optimizador *Adam* y la función de pérdida se definió utilizando el *MSE*. Además, al igual que en los temporales, se aplicó un proceso de escalado para preparar los datos de entrenamiento, tanto los parámetros de entrada como los de salida fueron escalados para ajustarse a un rango entre -1 y 1.

En cuanto al modelo para generar pronósticos RND-ET, se mantuvo una configuración similar, con 5 neuronas en la capa de entrada y 4 capas ocultas que contenían 100 neuronas cada una. Dos de estas capas ocultas emplearon la función de activación *ReLU*, mientras que las otras dos utilizaron la función de activación *Tanh*. La capa de salida se compuso de una sola neurona con una activación lineal. Esta arquitectura se muestra en la Figura 3.7. Todos los demás aspectos del modelo, incluido el uso del optimizador *Adam*, el número de épocas, el escalado y la función de pérdida del *MSE*, se mantuvieron similares al modelo RNV-ET de pronóstico de la velocidad del viento. Es importante señalar que los modelos fueron almacenados y pueden ser cargados nuevamente en memoria usando la librería *Joblib* [85], la cual facilita la creación de procesos eficientes y ligeros.




Figura 3.7. Esquema del modelo RND-ET.

### 3.5 Análisis de residuales de los modelos espacio-temporales

Dentro del análisis realizado con respecto a los modelos RNV-ET y RND-ET se examinaron los residuos de los modelos, los cuales constituyen la diferencia entre los valores reales y las predicciones. Para visualizar este análisis, se construyó un gráfico de dispersión de las predicciones con respecto a los residuos, para comprobar si los residuos se dispersaban de manera constante alrededor de una línea horizontal (esto se conoce como homocedasticidad). Además, se aplicó la prueba de *Bartlett* para respaldar esta evaluación, empleando la librería *Scipy* [81].

### 3.6 Acoplamiento de Filtro de Kalman a modelos RNN

En esta sección se describe el proceso de acoplamiento del algoritmo FK a los modelos de *RNN* para mejorar la trayectoria de los pronósticos de la dinámica del viento. El FK se acopla con los modelos *RNN* para corregir y mejorar las predicciones, ajustando los valores en función de las observaciones en tiempo real. Este acoplamiento se llevó a cabo en dos enfoques, el primero utilizando datos temporales de la RUOA, y el segundo aplicando datos espacio-temporales del INIFAP. A continuación, se detallan los procedimientos para el acoplamiento del FK en cada uno de estos enfoques.

### 3.6.1 Acoplamiento de Filtro de Kalman a RNN temporal utilizando datos de la RUOA

Para dar seguimiento a los parámetros meteorológicos, teniendo como base los modelos RNV y RND y con el objetivo de corregir la “trayectoria” de estos modelos desarrollados en la biblioteca Keras para el pronóstico tanto de la velocidad como de la dirección del viento, se incorporó al modelo el algoritmo predictivo-correctivo del FK. A partir de esto, se hará referencia al acoplamiento de estos modelos como RNV-FK para el modelo de velocidad del viento con FK y, RND-FK para el modelo de dirección del viento con FK. Este algoritmo, considerado una herramienta predictiva-correctiva, destaca en el ámbito de la estimación y predicción, siendo especialmente útil en sistemas que presentan ruidos en las mediciones y en el propio sistema. En el contexto de las *RNN*, el FK se utiliza para mejorar la trayectoria del modelo y mejorar la estimación de pronósticos [65], [86].

La implementación del FK se basa en la formulación de sistemas en términos de variables de estado, lo que permite modelar dinámicamente el comportamiento del sistema. A través de este método, se corrigen las estimaciones de salida de la *RNN* en presencia de incertidumbres, aumentando así la precisión de la red ante perturbaciones y variaciones en los datos, lo que garantiza que las *RNN* se adapten mejor a las condiciones cambiantes del entorno [65], [86].

Una vez establecido este enfoque, se procedió a cargar los escaladores de las características de entrada y de salida, los cuales fueron previamente normalizados utilizando *MinMaxScaler* junto con los datos de prueba. En este nuevo entorno, se aplicó el FK. Primero, se realizó la predicción del estado estimado y de la covarianza del error estimado. Luego, se llevó a cabo la corrección mediante el cálculo de la ganancia de Kalman y la actualización del estado estimado. A continuación, en la Figura 3.8, se muestra el algoritmo del FK acoplado en una *RNN*. En donde  $F_k$  es la matriz de transición de estado,  $P$  es la matriz de covarianza del error del estado estimado,  $Q_k$  es la matriz de covarianza del ruido del proceso,  $H$  es la matriz de observación y  $R$  es la matriz de covarianza del ruido de medición.




Figura 3.8 Acoplado de FK a un modelo de RNN.

Para los valores de las matrices del FK aplicadas al modelo de RNV-FK se consideraron los siguientes parámetros obtenidos de manera empírica:  $F_k = [0.001]$ ,  $P = [0.1]$ ,  $Q_k = [1.2]$ ,  $H = [0.9]$ ,  $R = [0.35]$ . Después de aplicar el algoritmo de corrección del FK, se procedió a validar el desempeño del modelo utilizando la métrica del coeficiente de determinación y a generar los gráficos de covarianza, ganancia de Kalman y el comportamiento del modelo corregido.

De forma similar a lo expuesto previamente, se llevó a cabo el mismo proceso para el modelo de RND-FK. Sin embargo, se utilizaron parámetros diferentes,  $F_k = [1.3]$ ,  $P = [0.004]$ ,  $Q_k = [1]$ ,  $H = [0.5]$  y  $R = [8]$ , determinados empíricamente.

Se compararon los modelos de RNV y RND con los modelos RNV-FK y RND-FK con la finalidad de determinar si los modelos de RNN con FK tenían un mejor desempeño que los modelos de RN solitarios. Para realizar la comparación de los modelos, se utilizaron las métricas de desempeño del coeficiente de determinación y el MSE.

### 3.6.2 Acoplamiento de Filtro de Kalman a RNN espacio-temporal utilizando datos del INIFAP

Se implementó un procedimiento análogo al utilizado para los modelos de RNV-FK y RND-FK de la RUOA. Sin embargo, en este caso, se hará referencia al modelo de RNN de velocidad del viento espacio-temporal con acoplamiento FK como RNV-ET-FK y al modelo de dirección del viento como RND-ET-FK, utilizando datos del INIFAP. Para cada modelo, se emplearon parámetros específicos.

En el caso del pronóstico del modelo de RNV-ET-FK, los parámetros utilizados para el FK fueron:  $F_k = [0.0001]$ ,  $P = [0.001]$ ,  $Q_k = [1.5]$ ,  $H = [1]$  y  $R = [0.35]$ . Por otro lado, para el pronóstico del modelo de RND-ET-FK, los parámetros fueron:  $F_k = [1.3]$ ,  $P = [0.004]$ ,  $Q_k = [1]$ ,  $H = [0.5]$  y  $R = [8]$ . Estos ajustes determinados empíricamente de los parámetros de FK permitieron adaptar el algoritmo a las características particulares de cada modelo de pronóstico.

Se compararon los modelos de RNV-ET y RND-ET con los modelos RNV-ET-FK y RND-ET-FK para determinar si los modelos de RN con FK tenían un mejor desempeño que los modelos de *RNN* solitarios. Para realizar la comparación de los modelos se utilizaron las métricas de desempeño del coeficiente de determinación y el *MSE*.

### **3.7 Definición de las fronteras del sistema**

Se utilizó QGIS [87] para georreferenciar las 17 estaciones de monitoreo del INIFAP. Para ello, se importaron los datos de ubicación de todas las estaciones, los cuales se encontraban previamente organizados en un archivo de formato CSV con las coordenadas geográficas de latitud y longitud. Cada estación fue visualizada en el mapa a partir de una capa de texto delimitado, mostrándose como puntos individuales y etiquetadas con el número de estación correspondiente a las bases de datos.

Además, con la finalidad de delimitar el área de interés en función de las estaciones de monitoreo, se utilizó la herramienta de creación de polígonos en QGIS. Se construyó un polígono, abarcando los extremos de las estaciones de monitoreo, estableciendo así un área geográfica, la cual representa el límite geográfico de la zona de estudio.

### **3.8 Evaluación espacio-temporal del modelo de RNV-ET y RND-ET**

En *Python*, se realizaron simulaciones de los modelos de RNV-ET y RND-ET previamente entrenados con datos de las 17 estaciones del INIFAP. Se definieron fronteras del sistema específicas para la latitud y la longitud, configurando una malla de coordenadas de 10 x 10, en donde se utilizó un valor promedio de velocidad y dirección del viento en todos los puntos como condición inicial. Otras condiciones iniciales para evaluar el modelo fueron las variables temporales correspondientes al día del año y la hora del día, junto con el estado previo en donde se consideraron los valores iniciales de

velocidad y dirección del viento. Para llevar a cabo el pronóstico, se desarrolló un único script en *Python* para velocidad y dirección del viento.

Este enfoque permitió observar el comportamiento del modelo en cuanto al pronóstico de la velocidad y dirección del viento en la región, generando mapas de contorno y de vectores de viento, respectivamente. Los cuales incluyeron la ubicación de las estaciones de monitoreo; para ello, se empleó la librería *Matplotlib* [76] en conjunto con la extensión incorporada de *Basemap* [88]. *Basemap*, es una herramienta para la creación de mapas en *Python*. Mientras que, *Matplotlib*, se encarga de dibujar elementos como contornos, vectores, imágenes y puntos en el mapa [89].

### **3.9 Acoplamiento de RNN e IDW para la generación de pronósticos espacio-temporales de velocidad y dirección del viento**

Se implementó un enfoque basado en los modelos de RNV-ET y RND-ET y el método de interpolación *IDW* para modelar y visualizar las variaciones horarias de la velocidad y dirección del viento. Esto permitió obtener predicciones espacio-temporales de ambos parámetros meteorológicos de manera individual sobre un área delimitada durante un ciclo de 24 horas, con intervalos de 1 hora.

Para cada parámetro, se utilizó el modelo de *RNN* preentrenado junto con los escaladores necesarios y se pronosticaron los valores en las 17 estaciones de monitoreo del INIFAP distribuidas en la zona de estudio. Los datos puntuales de estas estaciones se integraron en una matriz de 17 x 5 que almacena información como las horas del día, el día del año, la latitud, la longitud y el estado previo de cada parámetro. Esta matriz fue actualizada dinámicamente durante el ciclo de pronósticos.

A través de la interpolación *IDW* se calcularon los valores en cada punto de la malla espacial, ponderando la información según la distancia a las estaciones cercanas. Este proceso permitió generar mapas de contorno para velocidad y dirección del viento, los cuales de manera dinámica se fueron actualizando por hora, mostrando las variaciones espaciales y temporales. Para las visualizaciones se emplearon *Matplotlib* con la extensión incorporada de *Basemap* y la biblioteca *distance\_matrix* para calcular distancias, además de *Joblib* y *Keras* para cargar los modelos de RN.

Finalmente, se acoplaron los modelos de RNV-ET y RND-ET con el método de interpolación *IDW* para generar una representación de ambos modelos en un solo gráfico. Este gráfico combina un mapa de

vectores que representa la magnitud y la dirección del viento, y un mapa de contorno al fondo, que representa la velocidad del viento. Para realizar el análisis, se descompuso la dirección del viento interpolada en la malla geoespacial en sus componentes cartesianas  $u$  (Ecuación 17) y  $v$  (Ecuación 18), empleando funciones trigonométricas de seno y coseno. Este enfoque permitió calcular ambas componentes, facilitando la visualización de los vectores.

Las ecuaciones que describen las componentes cartesianas  $u$  y  $v$  del viento, se derivan de la descomposición trigonométrica de un vector, en función de su magnitud y dirección. Estas componentes representan las proyecciones horizontal y vertical del vector del viento.

$$u = v \cdot \cos(\theta) \quad (\text{Ec.17})$$

$$v = u \cdot \text{sen}(\theta) \quad (\text{Ec.18})$$

En este contexto, el método *IDW* estimó tanto la velocidad como la dirección del viento en cada punto de la malla espacial, integrando esta información para generar vectores que indican la magnitud y dirección del viento. De esta manera, el resultado es una visualización dinámica que combina ambos parámetros meteorológicos en un solo gráfico (RNE-IDW). Esto no solo mejora la interpretación de los datos espaciales y temporales, sino que también ofrece una herramienta eficaz para analizar patrones del viento a lo largo del día.

### 3.10 Caso de estudio

Se buscaron posibles aplicaciones de la interpolación *IDW* acoplada a los modelos espacio-temporales, con un enfoque a la sustentabilidad urbana. Para ello, se realizó un caso de estudio centrado en el cálculo de la densidad promedio del viento por hora en la ciudad de Aguascalientes. Este análisis buscó determinar la cantidad de energía eólica disponible por unidad de área dentro de la zona de estudio seleccionada.

Para ello, se utilizó el modelo de RNE-IDW previamente entrenado, enfocándose únicamente en la velocidad del viento. Para realizar esta estimación en los puntos de la malla durante un período representativo, se utilizaron como condiciones iniciales los valores de velocidad registrados el 1ro. de enero del 2022 a las 23:00 horas en las 17 estaciones de monitoreo. En este sentido, se utilizó la Ecuación 1, que integra la velocidad media del viento y la densidad del aire, siendo esta última

considerada como  $1.225 \frac{kg}{m^3}$ , valor correspondiente a condiciones estándar de presión (1 atm) y temperatura (15°C) a nivel del mar [53].

Finalmente, se generó un mapa de contorno, el cual ilustra la cantidad de energía disponible por unidad de área en la zona de estudio definida previamente en QGIS se evaluó utilizando el valor promedio de la velocidad del viento, obtenida por el modelo y por la interpolación *IDW*, determinada a partir de 8,760 horas, lo que sería el total de horas en 1 año. Este mapa proporcionó una visualización detallada de las áreas con mayor y menor densidad de potencia.

# CAPÍTULO IV

## RESULTADOS

### 4.1 Recolección de datos de estaciones meteorológicas

A partir de los datos recolectados de la estación de monitoreo de la RUOA, que corresponden al período de septiembre de 2022 a septiembre de 2023 sumando un total de 7,122 registros, se diseñaron los modelos de *RNN* temporales para el pronóstico de la dinámica del viento. En contraste, los datos en crudo provenientes de las 17 estaciones del INIFAP, correspondientes al período de enero de 2022 a diciembre de 2023, sumaban originalmente 1,048,576 registros, ya que se encontraban mediciones de cada 15 minutos. Sin embargo, al considerar solo los registros por hora, la cantidad de registros se redujo a 248,451, los cuales se emplearon para el diseño de los modelos de *RNNs* espacio-temporales para el pronóstico de la dinámica del viento.

### 4.2 Filtrado de las bases de datos

Los datos de la estación de la RUOA fueron sometidos a un proceso de filtración para eliminar registros incompletos. Se consideró como registro incompleto cualquier fila del *DataFrame* original que contuviera al menos un valor nulo en alguna de sus variables, de velocidad, dirección del viento o el tiempo de registro. Como resultado, se generó un nuevo *DataFrame* en el que ya no estaban incluidas dichas filas, reduciendo el número total de registros de 7,122 a 7,111. Esto representa la eliminación de 11 filas, equivalente a una reducción del 0.15%.

De manera similar, los datos proporcionados por el INIFAP fueron sometidos a un proceso de filtrado. Aunque los registros estaban en intervalos de 15 minutos, se seleccionaron únicamente aquellos correspondientes a cada hora, lo que resultó en un total de 248,451 datos. Posteriormente, se eliminaron las filas con valores nulos o negativos en el *DataFrame* original de velocidad del viento, generando un nuevo conjunto de datos compuesto por 183,257 registros. Esta modificación implicó una reducción de 65,194 datos, lo que equivale al 26.24%. En cuanto a la dirección del viento, se mantuvo un registro inicial de 248,451 datos. Posterior a la eliminación de las filas con valores nulos

en el *DataFrame*, el número de registros se redujo a 238,629, lo que implicó una disminución de 9,822 datos, equivalente al 3.95%.

## 4.3 Análisis Exploratorio de Datos

### 4.3.1 Análisis Exploratorio de Datos de la RUOA

Al realizar el EDA se pudo obtener la media, mediana y desviación estándar de la velocidad y dirección del viento. La velocidad promedio fue de 2.521 m/s para velocidad, mientras que la dirección del viento presentó un valor medio de 151.977 grados. Además, se obtuvo una desviación estándar de 1.204 m/s para la velocidad y 106.235 grados para la dirección del viento. La mediana de la velocidad fue de 2.272 m/s y la de la dirección del viento fue de 174.5 grados.

En este sentido, en el caso de la media se muestra un valor promedio del conjunto de datos con un período de septiembre 2022 a septiembre 2023. Además, el valor de la mediana se encuentra dentro del rango, lo que demuestra su poca afectación por posibles valores atípicos. Mientras que, la desviación estándar de la dirección del viento es mayor comparada con la media, lo que demuestra un comportamiento más caótico.

En la Figura 4.1 se muestran los diagramas de distribución de velocidad del viento. En la Figura 4.1a se presenta el histograma de la velocidad del viento, donde se observa que la mayoría de los datos se concentran en el rango de 1 a 3 m/s. Esto indica vientos suaves que apenas mueven las hojas de los árboles de acuerdo con la escala de Beaufort [90]. También, se observa que los datos no siguen una distribución normal al estar sesgados a la izquierda, lo que se interpreta como una predominancia de condiciones climáticas con velocidades de viento más bajas. Así mismo, se puede observar el valor relativamente pequeño de la desviación estándar. Mientras que, en la Figura 4.1b se muestra la distribución de los datos de la velocidad del viento con respecto a las horas del día, esto, a través de un diagrama de cajas. En este sentido, se observa que la mediana predomina entre los 2 y 3 m/s, así mismo, las cajas muestran datos simétricos dentro del promedio y valores atípicos en la parte superior, los cuales pueden asociarse a situaciones anormales, como lo son las ráfagas de viento que son más fuertes de lo normal. Así mismo, se observa que la velocidad del viento mayor se da entre las 17 y 19 horas, mientras que la menor, oscila entre las 5 y 6 horas del día.




Figura 4.1. Diagramas de distribución de velocidad del viento, a) Histograma, b) Diagrama de cajas.

Por otro lado, en la Figura 4.2 se presentan los diagramas de distribución de dirección del viento. La Figura 4.2a muestra el histograma de la dirección del viento, en el cual se puede observar la inexistencia de datos asimétricos, así mismo, no se observan barras aisladas dentro del histograma, por lo que se determina ausencia de valores atípicos. También, se observa que los datos no siguen una distribución normal. Además, se considera no ajustada al presentarse datos multimodales, por tal razón se observan dos picos, el primer pico demuestra los datos que ocurren previo a los  $50^\circ$ , por lo que se predomina una dirección entre el Norte-Nordeste (NNE) y el Nordeste (NE), tal como se muestra en la Figura 4.2b en donde se presenta el gráfico conjunto de distribución de frecuencias, denominado rosa de los vientos. Mientras que el segundo pico es a partir de datos previos a los  $200^\circ$ , lo cual demuestra una predominación en la dirección Sur-Sudoeste (SSW), la cual es menor en comparación con la anterior. Además, al aplicar la prueba de Shapiro-Wilk, el  $p$ -value fue menor a 0.05 para los datos de velocidad y dirección del viento, lo que confirma que ambas variables no presentan una distribución normal.




Figura 4.2. Diagramas de distribución de dirección del viento, a) Histograma, b) Rosa de los vientos.

En la Figura 4.3 se presentan dos conjuntos de gráficas ACF y PACF, uno para velocidad y otro para dirección del viento. En las gráficas ACF (Figuras 4.3a y 4.3b) se observa una correlación parcial entre las observaciones y sus valores previos, sin que se elimine la influencia de los retrasos intermedios. Este comportamiento se observa durante 23 retrasos. En este caso se usaron únicamente 23 retrasos en el análisis, ya que se toma como referencia el ciclo de día y noche del período de horas en un día. Por otro lado, en el PACF (Figuras 4.3c y 4.3d) es donde se elimina la influencia de los retrasos intermedios, lo que permitió identificar la influencia directa de los retrasos previos. A partir de estas correlaciones, se determinó considerar el estado previo (Lag 1) como el más relevante, dado que presenta el valor más alto en la PACF, alrededor de 0.75 para la velocidad y 0.5 para la dirección del viento. En este sentido, se observa que la velocidad del viento tiene un valor más alto comparado con la dirección del viento, debido a que los datos de dirección son más caóticos, se encuentran más dispersos y tienen una alta desviación estándar.




Figura 4.3 Gráficos de análisis de series temporales, a) ACF de la velocidad del viento, b) ACF de la dirección, c) PACF de la velocidad, d) PACF de la dirección.

#### 4.3.2 Análisis Exploratorio de Datos del INIFAP

En el EDA de la base de datos del INIFAP se obtuvo un valor medio de 4.120 m/s para velocidad y 169.584 grados para la dirección del viento. Además, se observó una desviación estándar de 5.087 m/s para la velocidad y 108.448 grados para la dirección del viento.

En la Figura 4.4 se muestran los diagramas de distribución de datos de la velocidad del viento. La Figura 4.4a corresponde al histograma, el cual está basado en datos de las 17 estaciones de monitoreo del INIFAP, donde se observa que la mayoría de los datos se concentran en velocidades bajas, por lo que conforme aumentan las velocidades, su frecuencia en el gráfico disminuye. Este comportamiento es análogo al de la RUOA. Asimismo, en la Figura 4.4b se muestra la distribución de la velocidad del viento a lo largo del día mediante un diagrama de cajas. Los valores atípicos en la parte superior pueden asociarse a situaciones anormales, como lo son las ráfagas de viento que son más fuertes de lo normal. La cantidad de estos valores no es alta como parece; esta percepción se debe a la gran

cantidad de datos analizados. Además, se observa que la velocidad del viento es mayor entre las 15 y 17 horas, por el contrario, la más baja, oscila entre las 6 y 8 horas del día.




Figura 4.4. Diagramas de distribución de velocidad del viento, a) Histograma, b) Diagrama de cajas.

En la Figura 4.5 se muestran los diagramas de distribución de dirección del viento. La Figura 4.5a presenta el histograma de la dirección del viento, en el cual se aprecia que no hay datos asimétricos ni barras aisladas, lo cual indica la ausencia de valores atípicos. Además, los datos no presentan un ajuste a una distribución normal. Este comportamiento es análogo al observado en la RUOA. Por su parte, en la Figura 4.5b se presenta el gráfico de distribución de frecuencias, conocido como la rosa de los vientos, el cual revela la variabilidad en la dirección del viento a lo largo del tiempo. Aun cuando la dirección del viento fluctúa considerablemente, se observan direcciones predominantes. Los datos presentan una distribución multimodal, presentándose por dos picos. El primer pico refleja una concentración de datos previo a los  $90^\circ$ , indicando una predominancia de dirección entre el Nordeste (NE) y el Norte-Nordeste (NNE). Por otro lado, el segundo pico, posterior a los  $200^\circ$ , señala una predominancia en la dirección Sur-Sudoeste (SSW), la cual es menor en comparación con la anterior. Los resultados de la prueba de *Shapiro-Wilk* mostraron un  $p\text{-value} < 0.05$  tanto para el histograma de velocidad como para el de dirección del viento, lo cual indica que no siguen una distribución normal.




Figura 4.5. Diagramas de distribución de dirección del viento a) Histograma y b) Rosa de los vientos

Por otro lado, en la Figura 4.6 se presentan dos conjuntos de gráficas de la *ACF* (Figura 4.6a y 4.6b) y *PACF* (Figura 4.6c y 4.6d), uno para velocidad y otro para dirección del viento. A partir de estas correlaciones, se decidió considerar al Lag 1, debido a su alto valor de *PACF*, aproximadamente 0.8 para velocidad y 0.5 para dirección del viento. Esto indica que la velocidad del viento muestra una correlación más fuerte en comparación con la dirección del viento, que presenta datos más caóticos y dispersos con una alta desviación estándar.




Figura 4.6. Gráficos de análisis de series temporales, a) ACF de la velocidad del viento, b) ACF de la dirección, c) PACF de la velocidad, d) PACF de la dirección.

En este sentido, los resultados del EDA permitieron identificar los principales patrones y tendencias del viento. En cuanto a la velocidad, se observó que varía a lo largo del año, con predominancia en valores inferiores a 6 m/s. Este resultado puede ser respaldado con un estudio realizado en la ciudad de Aguascalientes durante un periodo de 14 años. En dicho estudio, los vientos se clasificaron como débiles (menores a 3 m/s), moderados (entre 4 y 7 m/s) y fuertes (mayores a 7 m/s), concluyendo que, aunque las tres clasificaciones están presentes, predominan los vientos de débiles a moderados [91], lo cual también coincide con la escala de Beaufort [90]. Por otro lado, la dirección del viento presentó un comportamiento multimodal, destacándose dos direcciones predominantes, una hacia el Norte-Nordeste con un pico previo a los 90°, y otra hacia el Sur-Sudoeste, con un pico posterior a los 200°. Cabe resaltar que los resultados del EDA de los datos de las estaciones del INIFAP mostraron un comportamiento similar a los resultados obtenidos a partir de la estación de la RUOA.

## 4.4 Diseño de modelo de RNN para pronósticos de velocidad y dirección del viento

### 4.4.1 Diseño de modelo de RNN temporal

A continuación se presentan los resultados de la dinámica de la función de pérdida ( $MSE$ ) durante el entrenamiento de los modelos RNV y RND junto con un análisis detallado de los residuales de cada modelo. Este análisis tiene como objetivo identificar posibles tendencias en los residuales, como heterocedasticidad u homocedasticidad, y evaluar su normalidad. Finalmente, se obtuvo la validación de los modelos utilizando los datos de prueba y evaluando su desempeño mediante la métrica  $R^2$ . En la Figura 4.7 se muestra el comportamiento de la función de pérdida ( $MSE$ ) a lo largo de las épocas de entrenamiento para el modelo RNV con un  $R^2$  de 0.47 y 0.45 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente.




Figura 4.7. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento del modelo RNV para los conjuntos de entrenamiento y validación.

Por su parte, en la Figura 4.8 se muestra el comportamiento de la función de pérdida ( $MSE$ ) durante el entrenamiento del modelo RND con un  $R^2$  de 0.28 y 0.22 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente. En este análisis, se puede apreciar que la dirección del viento tiene un comportamiento más impredecible y variable que la velocidad del viento, lo que dificulta más su predicción.






Figura 4.8. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento del modelo RND para los conjuntos de entrenamiento y validación.

Por otro lado, en la Figura 4.9 se presenta el gráfico de la distribución de los residuales del modelo RNV a lo largo de las predicciones, los cuales se derivan de los datos de prueba. El análisis de estos residuales permite observar cómo se comporta el modelo en términos de su capacidad para ajustarse a los datos observados. En este caso, el *p-value* obtenido en la prueba de homocedasticidad de *Bartlett* para la velocidad del viento fue extremadamente bajo  $9.1764 \times 10^{-130}$ , lo que sugiere la presencia de heterocedasticidad. Esto indica que la varianza de los errores no es constante a lo largo de las predicciones, lo que podría mejorarse mediante la inclusión de parámetros adicionales relacionados con el sistema.

Por su parte, en la Figura 4.10 se observa el gráfico de la distribución de los residuales del modelo RND a lo largo de las predicciones, también obtenidos a partir de los datos de prueba. Al igual que en el caso del modelo RNV, el *p-value* obtenido en la prueba de homocedasticidad de *Bartlett* para la dirección del viento fue igualmente bajo ( $4.7674 \times 10^{-96}$ ), lo que también indica la presencia de heterocedasticidad. Este resultado, de igual manera que el anterior modelo, podría mejorarse mediante la inclusión de parámetros no considerados pero relacionados con el fenómeno [92]. Aunque no es una regla que se tenga que cumplir todos los supuestos sobre los residuales del ajuste del modelo, ya que estos solo aplican a modelos lineales, dentro de esta investigación fue útil como referencia para analizar el comportamiento del ajuste de ambos modelos.



*Figura 4.9. Distribución de los residuales de velocidad del viento a lo largo de la variable respuesta de predicciones.*



*Figura 4.10. Distribución de los residuales de dirección del viento a lo largo de la variable respuesta de predicciones.*

Como complemento a los gráficos anteriores, en la Figura 4.11 se muestra el comportamiento del modelo temporal de RNV y los datos reales de prueba a lo largo del tiempo, considerando un período de 50 registros de datos, que no son temporales consecutivos, sino una selección representativa del conjunto de datos. En este gráfico se puede observar cómo el modelo sigue la tendencia general de los datos reales, aunque con algunas variaciones que reflejan la complejidad del sistema modelado.




Figura 4.11. Comportamiento del modelo RNV en el tiempo

De manera similar, en la Figura 4.12 se presenta el comportamiento del modelo RND junto con los datos reales de prueba en función del tiempo, también durante un período de 50 registros de datos. En este caso, se puede observar que el modelo RND presenta un comportamiento más dinámico y variable, lo que refleja una mayor complejidad y variabilidad en comparación con el modelo RNV.




Figura 4.12. Comportamiento del modelo RND en el tiempo.

#### 4.4.2 Diseño de modelo de RNN espacio-temporal

A continuación se presentan los resultados de la dinámica de la función de pérdida (MSE) durante el entrenamiento de los modelos RNV-ET y RND-ET junto con un análisis detallado de los residuales de cada modelo. Este análisis tiene como objetivo identificar posibles tendencias en los residuales, como heterocedasticidad u homocedasticidad, y evaluar su normalidad. Finalmente, se obtuvo la validación de los modelos utilizando los datos de prueba y evaluando su desempeño mediante la métrica  $R^2$ .

En la Figura 4.13 se muestra el comportamiento de la función de pérdida (MSE) a lo largo de las épocas de entrenamiento para el modelo RNV-ET. En este punto como tal no se están haciendo los pronósticos, sino que durante el proceso de entrenamiento el modelo está ajustando los parámetros internos utilizando la técnica de *Backpropagation*, la cual consiste en una parametrización. En este sentido, se obtuvo un  $R^2$  de 0.83 y 0.76 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente.




Figura 4.13. Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento y validación del modelo RNV-ET.

Además, en la Figura 4.14 se muestra el comportamiento de la función de pérdida durante el entrenamiento del modelo RND-ET con un  $R^2$  de 0.28 y 0.26 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente. En este sentido, se tienen mejores resultados en la evaluación de las métricas para la velocidad que para la dirección, por lo que se pudiera confirmar que la dirección es más difícil de modelar que la velocidad, aplicando este tipo de modelos y para este

conjunto de datos. Por ello, se puede afirmar que la dirección tiene un comportamiento más caótico en comparación con la velocidad.




Figura 4.14 Respuesta de la función de pérdida a lo largo de las épocas de entrenamiento y validación del modelo RND-ET.

En este contexto, en la Figura 4.15 se presenta el gráfico de dispersión de velocidad del viento, comparando los pronósticos del modelo RNV-ET con los valores reales del conjunto de datos de prueba. En este gráfico, los puntos se ajustan lo más cerca posible a la línea diagonal, lo que indica que las predicciones del modelo tienen una buena precisión. Al mismo tiempo, se observa que gran parte de estos puntos están por debajo de la línea diagonal, lo que sugiere que dicho modelo podría estar experimentando problemas de subestimación en los pronósticos de velocidad del viento.

Por otro lado, en la Figura 4.16 se muestra el gráfico de dispersión de dirección del viento. En ese caso, los puntos muestran una mayor dispersión dentro del rango, generando un patrón más difuso o efecto de “mancha horizontal”. Esto indica que las predicciones de dirección del viento tienen una mayor variabilidad y sugieren que el modelo RND-ET podría mejorar su precisión a partir de un ajuste adicional. Esto podría lograrse a partir de la inclusión de variables adicionales relacionadas con el sistema o a través de la mejora en la configuración de los hiperparámetros del modelo.




Figura 4.15. Comparación entre los valores reales y predichos por el modelo RNV-ET.




Figura 4.16. Comparación entre los valores reales y predichos por el modelo RND-ET.

En este sentido, en la Figura 4.17 se muestra el comportamiento del modelo RNV-ET contra los datos reales de prueba a lo largo del tiempo en un período de 50 registros de datos. En este caso, se observa que el pronóstico del modelo se acerca a los puntos que representan los datos reales, pero con pequeñas variaciones, con un  $R^2$  de 0.83 y 0.77 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente. Esto sugiere que el modelo logra capturar la tendencia general de la velocidad del viento, aunque con algunas variaciones menores que pueden reflejar pequeñas imprecisiones en la predicción.




Figura 4.17 Comparación de la respuesta del modelo RNV-ET con respecto a datos reales de prueba.

Mientras que, en la Figura 4.18 se presenta el comportamiento del modelo RND-ET, en donde se comparó la respuesta del modelo con respecto a los datos reales de prueba. A diferencia del modelo de velocidad del viento, en este caso el modelo presenta una mayor dispersión. Los puntos de los datos reales de la dirección del viento se concentran principalmente en la parte superior o inferior del gráfico, mientras que el modelo se posiciona en el centro, esto indica que las predicciones del modelo no se ajustan ni están cercanos a los datos reales. En este modelo, se obtuvo un  $R^2$  de 0.28 y 0.25 para la evaluación del modelo con los datos de entrenamiento y prueba, respectivamente. Por ello, se sugiere que el modelo tiene dificultades para capturar la variabilidad dinámica y compleja de la dirección del viento en comparación con la velocidad del viento.




Figura 4.18. Comparación de la respuesta del modelo RND-ET con respecto a datos reales de prueba.

Los resultados mostraron que las *RNN* fueron más efectivas que otros modelos y técnicas reportados en la literatura, como ARIMA [15], RLM [16], WRF-Chem [17], así como métodos como el clasificador Gamma y modelos de dispersión de tipo Gaussiano [18], [19]. Las *RNN* demostraron ser más adecuadas debido a su capacidad para representar y manejar relaciones altamente no lineales y complejas, características propias de la variabilidad del viento. Sin embargo, al tratarse de un sistema altamente variable como es el viento, los resultados de la métrica de  $R^2$  obtenidos con los modelos de RN tanto temporales como espacio-temporales, permitió determinar la necesidad de incorporar una herramienta que permitiera eliminar el ruido en las mediciones, lo cual mejoraría la trayectoria de los modelos temporales y espacio-temporales. En este contexto, se decidió acoplar el FK, el cual es generalmente utilizado en sistemas de seguimiento de señales por su capacidad para manejar incertidumbres [22].

#### 4.5 Análisis de residuales de los modelos espacio-temporales

La distribución de los residuales de la velocidad del viento en función de las predicciones espacio-temporales se presenta en la Figura 4.19. Se observa cómo los residuales se distribuyen a lo largo de los valores predichos, lo cual permite evaluar la calidad del ajuste del modelo RNV-ET. El *p-value* obtenido en la prueba de homocedasticidad de *Bartlett* fue extremadamente bajo, con un valor de 0, indicando la presencia de heterocedasticidad.




Figura 4.19. Distribución de los residuales de velocidad del viento en función de las predicciones, modelo RNV-ET.

De manera similar, en la Figura 4.20 se muestra la distribución de los residuales para la dirección del viento. Al igual que en la Figura 4.19, el  $p$ -value obtenido en la prueba de homocedasticidad de *Bartlett* fue extremadamente bajo, con un valor de 0. Estos resultados indican una presencia de heterocedasticidad, es decir, la varianza de los errores en la predicción de este parámetro meteorológico no permanece constante.




Figura 4.20. Distribución de los residuales de dirección del viento en función de las predicciones, modelo RND-ET.

## 4.6 Acoplamiento de Filtro de Kalman a modelos RNN

### 4.6.1 Acoplamiento de Filtro de Kalman a RNN temporal utilizando datos de la RUOA

El análisis de la ganancia y covarianza de Kalman se muestra en la Figura 4.21. Mientras que, en la Figura 4.21a se puede observar cómo la ganancia de Kalman varía a lo largo del tiempo en respuesta a las mediciones, la ganancia muestra una tendencia hacia la estabilidad, indicando que el FK está adaptando su respuesta de manera óptima. Por otro lado, en la Figura 4.21b se muestra la evolución de la covarianza en el tiempo, la cual aumenta de 0.1 a un poco más de 0.3, pero se estabiliza al igual que la ganancia de Kalman. Ambas Figuras, correspondientes al modelo RNV, demuestran que el FK está trabajando correctamente, ajustando su estimación del estado del sistema en función de las mediciones recibidas, con estimaciones precisas y consistentes a lo largo del tiempo.




Figura 4.21. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RNV, a) Ganancia de Kalman y b) Covarianza de Kalman.

Por otro lado, en la Figura 4.22 se presenta la comparación del comportamiento del modelo RNV con el modelo RNV-FK a lo largo de 50 datos. Se observa una mejora significativa en el ajuste del modelo a los datos reales, con una disminución notable de la variabilidad entre los pronósticos del modelo y las mediciones observadas. Esta mejora en el ajuste se representa en una mayor precisión del modelo, donde el  $R^2$  pasó de 0.47 a 0.88, lo cual indica una mayor confiabilidad en el pronóstico del sistema.




Figura 4.22. Evolución temporal del modelo RNV, junto con una comparación de su desempeño con el modelo RNV-FK

De manera similar al modelo RNV, en la Figura 4.23 se observa el comportamiento de los parámetros d el FK, específicamente la ganancia y la covarianza, para el modelo RND. En la Figura 4.23a, se observa cómo el FK ajusta su ganancia, mientras que en la Figura 4.23b se ajusta la covarianza en función de las mediciones recibidas. Este proceso de adaptación continua permite que el FK realice estimaciones precisas y estables a lo largo del tiempo. Estos ajustes demuestran que el FK está funcionando correctamente, reduciendo de forma consistente la incertidumbre en el pronóstico de la dirección del viento.




Figura 4.23. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RND, a) Ganancia de Kalman y b) Covarianza de Kalman.

Por tal razón, en la Figura 4.24 se observa una mejora significativa en el ajuste del modelo a los datos reales de la dirección del viento, indicando de igual manera una mayor confiabilidad y precisión en los pronósticos. En este sentido se observa la comparación de los modelos RND y RND-FK, en donde la  $R^2$  pasó de 0.28 en RND a 0.83 en el modelo con acoplamiento del FK.




Figura 4.24. Evolución temporal del modelo RNV, junto con una comparación de su desempeño con el modelo RND-FK

#### 4.6.2 Acoplamiento de Filtro de Kalman a RNN espacio-temporal utilizando datos del INIFAP

La implementación del FK en los modelos de RNN espacio-temporales entrenados con los datos del INIFAP permitió obtener una adaptación precisa y confiable tanto para el modelo de velocidad como para el de dirección del viento. Este comportamiento es análogo al observado con los datos de la estación de la RUOA, donde también se logró una mejora en la estabilidad y precisión de los pronósticos.

En este sentido, en la Figura 4.25 se muestra un análisis de la ganancia y covarianza de Kalman al acoplarse el FK al modelo RNV-ET. En este contexto, los parámetros del modelo se estabilizaron después de un período de tiempo corto de manera abrupta, además se generó un aumento con respecto a los valores iniciales propuestos en ambos parámetros, pero siempre llegando a una estabilización tanto para la ganancia (Figura 4.25a) como para la covarianza (Figura 4.25b).




Figura 4.25. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RNV-ET, a) Ganancia de Kalman y b) Covarianza de Kalman.

Asimismo, en la Figura 4.26, se muestra el comportamiento del modelo solitario RNV-ET en comparación con el modelo acoplado con el FK, RNV-ET-FK. Se muestra una mejora significativa en el ajuste del modelo a los datos reales. Este incremento en la precisión indica que el FK ha potenciado la capacidad de pronóstico del modelo, permitiendo que las estimaciones sean más confiables a las condiciones reales del viento, demostrando la confiabilidad del sistema para futuros pronósticos, el  $R^2$  pasó de 0.83 a 0.97.




Figura 4.26. Evolución temporal del modelo RNV-ET, junto con una comparación de su desempeño con el modelo RNV-ET-FK.

La dinámica de los parámetros del FK, obtenidas de la evaluación del modelo RND-ET al acoplarle el FK, se muestra en la Figura 4.27. En este contexto, en la Figura 4.27a se presenta la evolución de la ganancia de Kalman, mientras que en la Figura 4.27b se muestra el comportamiento de la covarianza. Ambos parámetros, a lo largo del tiempo, demuestran una estabilización progresiva, lo que indica que el FK está ajustando adecuadamente las estimaciones, mejorando la precisión y estabilidad del modelo de manera consistente.




Figura 4.27. Análisis de la ganancia y covarianza de Kalman del acoplamiento al modelo RND-ET, a) Ganancia de Kalman y b) Covarianza de Kalman.

Además, en la Figura 4.28, se muestra una mejora significativa en el ajuste del modelo RND-ET-FK con los datos reales, lo que continúa resaltando el valor del FK en la mejora continua de las estimaciones en comparación con el modelo solitario. En este sentido, el  $R^2$  pasó de 0.28 a 0.90, elevando la precisión en las estimaciones e incrementando la confiabilidad de los modelos en entornos de alta variabilidad.




Figura 4.28. Evolución temporal del modelo RND-ET, junto con una comparación de su desempeño con el modelo RND-ET-FK.

Se conoce que el FK está diseñado específicamente para estimar estados desconocidos en sistemas dinámicos a partir de mediciones ruidosas e imprecisas, por lo que a partir de esto se pudo correlacionar directamente con el comportamiento del viento, el cual también se determina como un sistema dinámico. Aun cuando este algoritmo no tiene antecedentes en la literatura que sustente su aplicación en parámetros meteorológicos, como la dinámica del viento, demostró ser una aportación significativa a este proyecto.

Esta propuesta resultó efectiva, aunque presentó desafíos relacionados con la configuración de las matrices que conforman a las ecuaciones del algoritmo del FK. Existen reglas heurísticas para definir estos parámetros, pero su enfoque a la dinámica del viento requirió de un ajuste a partir de prueba y error debido a la ausencia de estudios previos en el área de parámetros meteorológicos. Sin embargo, a pesar de estas limitaciones, el uso del FK mejoró significativamente los pronósticos de la dinámica del viento, tanto para los modelos temporales como para los modelos espacio-temporales, incrementando la precisión y consistencia de las mediciones en función del tiempo. Este acoplamiento resultó aún más significativo en la dirección del viento, la cual presentaba inicialmente un mayor nivel de ruido en las observaciones. De esta manera, los resultados reflejaron una mejora en la trayectoria y precisión de los modelos, demostrando el potencial del FK para aplicaciones futuras en otros sistemas dinámicos.

## 4.7 Definición de las fronteras del sistema

El polígono que delimita la extensión geográfica de las estaciones de monitoreo, considerando ubicaciones en los principales puntos cardinales como el norte, sur, este, oeste y suroeste se presenta en la Figura 4.29. Este polígono, de forma irregular, está delimitado por las coordenadas de los puntos extremos: el punto noroeste tiene una latitud de 22.3512 y una longitud de -102.4605, mientras que el punto sureste se encuentra en una latitud de 21.7596 y longitud de -102.0535, con un margen de  $\pm 0.025$  en cada dirección. Estas coordenadas fueron fundamentales para la definición de las fronteras del sistema, lo que permitió generar mapas interactivos de contorno y vectores de viento en la entidad de Aguascalientes. Es importante destacar que los pronósticos dentro de este polígono tienen una mayor validez, ya que se sustentan directamente con los análisis realizados. En cambio, los datos fuera de estas fronteras corresponden a extrapolaciones, las cuales presentan una mayor incertidumbre y esto reduce su certeza. Esto, no solo ayudó a la generación de los análisis espacio-temporales, sino que también ofreció una comprensión más clara y detallada de cómo el viento se comporta en el contexto urbano, permitiendo una evaluación en su impacto en el diseño y la gestión urbana.




Figura 4.29. Polígono de delimitación de las estaciones del INIFAP con coordenadas extremas.

## 4.8 Evaluación espacio-temporal del modelo de RNV-ET y RND-ET

La aplicación principal de los modelos espacio-temporales obtenidos es la evaluación de toda el área de estudio para condiciones temporales particulares. A manera de ejemplo demostrativo se obtuvo un mapa de contorno de la velocidad del viento para el día 150 del año, a las 17 horas del día, con una velocidad inicial de 2.5 m/s y dirección de 300° (Figura 4.30). Se observa un patrón predominante de velocidades entre 0 y 5 m/s a lo largo de la región, por lo que se pueden considerar variaciones suaves en la intensidad del viento dentro del área de estudio.




Figura 4.30. Mapa de contorno de velocidad del viento

De manera análoga, en la Figura 4.31 se muestra un mapa de vectores que representa la dirección y magnitud del viento en diferentes puntos geográficos, basado en las mismas condiciones iniciales. Se destaca una tendencia hacia el SSW.




Figura 4.31. Mapa de vectores de magnitud y dirección del viento.

Además, se observa que las magnitudes de velocidad en la parte superior izquierda y derecha del mapa son más altas. Sin embargo, es importante señalar que los valores en estas áreas se consideran extrapolaciones del modelo, ya que las estaciones de monitoreo están concentradas en la parte central del mapa. Por lo tanto, las estimaciones en estas zonas podrían estar sesgadas respecto a los datos reales. Como resultado de esto, se utiliza el algoritmo de *IDW* para evaluar todos los puntos de la malla propuesta, basándose en la evaluación del modelo en cada uno de los puntos conocidos, con el fin de obtener estimaciones más representativas.

#### 4.9 Acoplamiento de RNN e IDW para la generación de pronósticos espacio-temporales de velocidad y dirección del viento

La Figura 4.32. presenta la integración de la velocidad y de la dirección del viento en un solo mapa, denominado RNE-IDW. Las Figuras 4.32a, 4.32b y 4.32c representan la dinámica de los patrones del

viento a lo largo de un período de 24 horas, a partir de las condiciones iniciales utilizadas para evaluar el modelo correspondiente al día 255 del año (8 de septiembre), mostrando las secuencias de imágenes en tres diferentes horas del día: a las 8, 16 y 24 horas, respectivamente.

En este sentido, se observan zonas donde predominan velocidades entre 6 y 13 m/s, mientras que lo restante se muestra uniforme en velocidades menores a 6 m/s, estos datos siguen la tendencia obtenida del EDA de los datos del INIFAP, en donde las velocidades más bajas se daban entre las 6 y 8 horas del día, mientras que las más altas entre las 15 y 17 horas del día, por lo que se puede determinar que el acoplamiento del modelo con el *IDW* está dando resultados que siguen la tendencia real de los datos. Las zonas con una velocidad mayor se encuentran principalmente en la parte noroeste del mapa de Aguascalientes, lo que sugiere una mayor incidencia en las zonas montañosas de la región, como la sierra fría. En cuanto a la dirección del viento, se destacan áreas con patrones de dirección predominante, representados por “lagunas” en el mapa, donde las líneas de contorno podrían indicar una estabilidad en la orientación del viento. En el norte y centro de la región, se observa una mayor concentración de líneas de contorno de dirección, lo que indica zonas con patrones consistentes de flujo, lo que podría estar influenciado por la topografía de esta parte del estado. La dirección predominante de los vectores fue sobre los 180°. En el apartado de Anexo B se incluye un código QR que permite visualizar, a través de un Formato de Intercambio de Gráficos (*GIF*), la dinámica de los patrones del viento durante 24 horas.




Figura 4.32 Mapa del modelo RNE-IDW, a) RNE-IDW a las 8 horas, b) RNE-IDW a las 16 horas, c) RNE-IDW a las 24 horas.

El método de interpolación *IDW* contribuyó en la interpolación y extrapolación de la información generada por los modelos. Esta técnica de interpolación facilitó la representación de la distribución

espacio-temporal del viento, ofreciendo un análisis más detallado de su dinámica en el entorno urbano, abarcando áreas donde existe una ausencia de información o de estaciones de monitoreo. A pesar de que se observó un comportamiento análogo entre los modelos temporales (RNV y RND), y entre los modelos espacio-temporales (RNV-ET y RND-ET), se optó por considerar el enfoque espacio-temporal para interpolar y extrapolar los datos según la zona de estudio delimitada por el polígono de QGIS. Esto permitió ampliar el análisis debido a que se contaba con una cantidad mayor de datos, por tratarse de 17 estaciones de monitoreo.

#### **4.10 Caso de estudio**

Como un caso de estudio particular, se utilizó el modelo RNE-IDW para la evaluación de la densidad de potencia eólica en la ciudad de Aguascalientes, México. En la Figura 4.33. se muestra el mapa de contorno de la densidad potencia del viento en el estado de Aguascalientes, el cual muestra la capacidad de generación de energía eólica en diferentes ubicaciones en términos de  $W/m^2$ , evaluado por el promedio de la velocidad del viento obtenida por el modelo RNE-IDW durante 8,760 horas (1 año). Las tonalidades del mapa representan diferentes niveles de densidad de potencia, en donde las áreas de colores más claros muestran las zonas con una mayor densidad de potencia, más de  $0.9 W/m^2$ , lo que podría ser zona de estudio para futuros proyectos de generación de electricidad a partir del viento. Estas zonas están ubicadas principalmente en la parte central y al norte del mapa, por lo que se consideran con un mayor potencial de generación de energía eólica. Por otro lado, las áreas de tonalidades de verde muestran una menor densidad de potencia y, por lo tanto, menor potencial para generación eólica.




Figura 4.33. Mapa de contorno de la densidad promedio del viento por hora en el estado de Aguascalientes.

Es importante señalar que los datos utilizados en este análisis provienen de mediciones realizadas a nivel estacional, de acuerdo con los lineamientos de la NOM-156-SEMARNAT-2012 [93], la cual asegura la confiabilidad y verificación de las estaciones meteorológicas. Asimismo, las especificaciones para la ubicación y exposición de instrumentos de medición, como el anemómetro y la veleta, se describen en la NMX-AA-166/2--SCFI-2015 [94], que establece una altura estándar de 10 metros para estos sensores, a diferencia de los otros equipos de medición que están por debajo de esta altura. En este contexto, considerando que se sigan estos criterios dentro de la estación del INIFAP, esta altura se debe considerar al interpretar los resultados, ya que las densidades de potencia eólica calculadas en este estudio corresponden a la escala definida por las normas.

Dado que la altura de los aerogeneradores generalmente varía entre 80 y 115 metros [95], sin descartar que existen modelos más altos, es necesario reconocer que la densidad de potencia evaluada en este estudio corresponde a una escala menor. Esto podría sugerir que, aunque se

identificaron áreas con potencial eólico, las simulaciones no representan completamente las condiciones reales a las que se encuentran los aerogeneradores en su altura operativa, lo que podría influir en la estimación del recurso energético disponible. No obstante, este caso de estudio resultó significativo para identificar áreas con potencial de aprovechamiento eólico y para demostrar la utilidad de la interpolación *IDW*.

En este sentido, bajo lo referido anteriormente y al analizar los resultados, se determinó que esta investigación no solo tiene el potencial de mejorar los pronósticos de fenómenos meteorológicos en la ciudad de Aguascalientes, sino que también podría contribuir a la gestión eficiente y sustentable de recursos, infraestructura y servicios urbanos. Al abordar las limitaciones actuales en el pronóstico de la dinámica del viento, considerando que Aguascalientes se encuentra en una transición de ciudad horizontal a ciudad vertical por las nuevas edificaciones y al proporcionar herramientas avanzadas para la visualización de datos como fue el caso del algoritmo del FK y la interpolación *IDW*, esta tesis representa un avance muy significativo en la línea de investigación de Ingeniería de procesos sustentables de la Maestría en Ciencias en Ingeniería Ambiental, específicamente en el área de simulación de parámetros meteorológicos y sustentabilidad urbana. Asimismo, da lugar a futuras investigaciones relacionadas con aplicaciones de interpolación *IDW* en otras áreas afines o incluso podrían ser parte del diseño de políticas públicas.

# CAPÍTULO V

## CONCLUSIONES

La ampliación de los modelos temporales hacia modelos espacio-temporales permitió mejorar la representatividad de los pronósticos al incorporar datos geoespaciales y herramientas como el SIG. Esto resulta fundamental para el pronóstico de la dinámica del viento a nivel urbano. Asimismo, se observó un comportamiento análogo entre las simulaciones utilizando los datos de la estación de la RUOA y los de las estaciones del INIFAP. Esto sugiere que, aún cuando el viento fluctúa considerablemente, existen direcciones predominantes, como el Norte-Nordeste y el Sur-Sudoeste, mientras que la velocidad del viento se mantiene en niveles suaves, de acuerdo con la escala de *Beaufort*, con mediciones predominantes inferiores a 6 m/s.

Los modelos temporales y espacio-temporales de velocidad y dirección del viento mejoraron significativamente su desempeño y precisión al acoplar el FK. Esta integración no solo mejoró la calidad de los pronósticos y permitió una anticipación más precisa de eventos meteorológicos para ambos modelos, sino que también resaltó la importancia de simular superficies basadas en estos datos.

La incorporación de técnicas de interpolación, como el *IDW*, fue una herramienta útil para la generación de mapas de contorno y de vectores del viento, los cuales proporcionaron una visualización más clara de las variaciones espacio-temporales en la velocidad y dirección del viento. Esto facilitó la identificación de direcciones y patrones predominantes. Esta técnica es un componente clave en estudios con comportamientos variables e inestables, como el viento, y resulta especialmente relevante para aplicaciones enfocadas a la sustentabilidad urbana, como la identificación de zonas con alto potencial eólico. Debido a su alta efectividad de esta herramienta se puede considerar para otros casos de estudio, mejorando la capacidad para reducir impactos ambientales e incrementar la resiliencia frente a desafíos climáticos.

La generación de mapas de contorno y de vectores no solo resultan útiles para la toma de decisiones en tiempo real, sino que también proporcionan una base sólida para estudios específicos y para el diseño de estrategias relacionadas con el comportamiento eólico. En este estudio, se identificaron dos puntos específicos al norte y al noroeste de la ciudad que presentan un alto potencial eólico, lo cual es clave para el aprovechamiento de la energía del viento en áreas urbanas.

El modelado de la dinámica del viento permitió comprender su comportamiento y su impacto directo en la sustentabilidad urbana. Esto afecta áreas como la producción de energía eólica, en donde se pueden identificar ubicaciones estratégicas para aerogeneradores contribuyendo a la transición hacia fuentes de energía renovable. Con respecto a la calidad del aire, se tiene un impacto considerable al permitir prever la propagación de contaminantes y generar planes de mitigación. Además, con respecto a la seguridad en construcciones, el análisis del viento permite mejorar la seguridad en zonas urbanas vulnerables a fenómenos meteorológicos extremos, como tormentas o vientos fuertes, y ayuda a mejorar el diseño de edificaciones que aprovechen las corrientes de aire para mejorar el confort térmico y reducir el uso de climatización artificial. En este sentido, apartir de la información obtenida se pueden gestionar de manera eficiente recursos, infraestructuras y servicios dentro de la ciudad.

Finalmente, la dinamica del viento se considera impredecible, sobre todo la dirección del viento que tiene un comportamiento más caótico en comparación la velocidad. Aunado a la alta variabilidad y falta de precisión en las mediciones de las estaciones meteorológicas, esto resalta la necesidad de darle un seguimiento constante a las estaciones con respecto al mantenimiento, ubicación y funcionamiento de todos y cada uno de los equipos e instrumentos de medición que las conforman. Esto también abre la oportunidad de utilizar la técnica *IDW* para determinar sitios óptimos para nuevas estaciones meteorológicas que permitan un mejor monitoreo de los principales parámetros meteorológicos dentro de los municipios que conforman a la ciudad de Aguascalientes.

## REFERENCIAS

- [1] F. Eraso-Checa, E. Escobar-Rosero, D. F. Paz, and C. Morales, "Methodology for the determination of wind characteristics and assessment of wind energy potential in Túquerres-Nariño ", doi: 10.14483/23448350.12304.
- [2] Á. Pinilla, "Wind power," pp. 64–69, Nov. 2008, Accessed: Sep. 22, 2024. [Online]. Available: <https://www.redalyc.org/pdf/1210/121015051009.pdf>
- [3] Dr Tedros Adhanom Ghebreyesus, "World Health Statistics 2023," *Monitoring health for the SDGs Sustainable Development Goals*, p. 119, 2023.
- [4] "La contaminación del aire y los problemas respiratorios." Accessed: Dec. 28, 2023. [Online]. Available: [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S0026-17422015000500044](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S0026-17422015000500044)
- [5] "Calidad del aire, partículas en suspensión y metales." Accessed: Aug. 20, 2024. [Online]. Available: [https://scielo.isciii.es/scielo.php?script=sci\\_arttext&pid=S1135-57272008000500001](https://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1135-57272008000500001)
- [6] "Medio ambiente y sustentabilidad urbana." Accessed: Jun. 04, 2024. [Online]. Available: [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-74252006000300007](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-74252006000300007)
- [7] M. Son, J. I. Lee, J. J. Kim, S. J. Park, D. Kim, and D. Y. Kim, "Evaluation of the Wind Environment around Multiple Urban Canyons Using Numerical Modeling," *Atmosphere (Basel)*, vol. 13, no. 5, May 2022, doi: 10.3390/ATMOS13050834.
- [8] I. M. Uribe, "Valoración del viento como fuente de energía eólica en el estado de Guerrero Valuation of the wind as a source of wind energy in the state of Guerrero," vol. 22, no. 3, 2018, Accessed: Sep. 22, 2024. [Online]. Available: <http://www.nco.ncep.noaa.gov/pmb/products/>
- [9] "El comportamiento del viento en la morfología urbana y su incidencia en el uso estancial del espacio público." Accessed: Sep. 22, 2024. [Online]. Available: <https://www.redalyc.org/pdf/2817/281732449006.pdf>
- [10] "Vientos Fuertes - Aprende sobre Huracanes - Florida International University - FIU." Accessed: Sep. 22, 2024. [Online]. Available: <https://huracanes.fiu.edu/aprende-sobre-huracanes/vientos-fuertes/index.html>
- [11] "Vista de Modelización del comportamiento del fuego en los incendios forestales: modelos empíricos de predicción de la velocidad de propagación desarrollados en túnel de viento." Accessed: Sep. 22, 2024. [Online]. Available: [https://secforestales.org/publicaciones/index.php/cuadernos\\_secf/article/view/9470/9388](https://secforestales.org/publicaciones/index.php/cuadernos_secf/article/view/9470/9388)
- [12] C. Bustamante, M. Jans, and E. Higuera, "El comportamiento del viento en la morfología urbana y su incidencia en el uso estancial del espacio público, Punta Arenas, Chile," *AUS*, vol. 2014, no. 15, pp. 28–33, 2014, doi: 10.4206/AUS.2014.N15-06.

- [13] E. Ng, "Policies and technical guidelines for urban planning of high-density cities – air ventilation assessment (AVA) of Hong Kong," *Build Environ*, vol. 44, no. 7, p. 1478, Jul. 2009, doi: 10.1016/J.BUILDENV.2008.06.013.
- [14] A. Salcido *et al.*, "Calidad del aire y monitoreo atmosférico," *Revista Digital Universitaria*, vol. 20, no. 3, May 2019, doi: 10.22201/codeic.16076079e.2019.v20n3.a3.
- [15] J. Sosa, "Modelo de pronóstico ARIMA en el monitoreo de parametros ambientales," *Cienc Desarro*, vol. 21, no. 2, p. 49, Dec. 2018, doi: 10.21503/cyd.v21i2.1631.
- [16] G. R. Morantes-Quintana, G. Rincón-Polo, N. A. Pérez-Santodomingo, G. R. Morantes-Quintana, G. Rincón-Polo, and N. A. Pérez-Santodomingo, "Modelo de Regresión Lineal Múltiple para estimar concentración de PM1," *Revista internacional de contaminación ambiental*, vol. 35, no. 1, pp. 179–194, 2019, doi: 10.20937/RICA.2019.35.01.13.
- [17] R. Parra Narváez and C. Páez Pérez, "Estrategia para el desarrollo de un modelo de predicción de la calidad del aire de Quito y resultados preliminares de la fase de diagnóstico," *Acta Nova*, vol. 3, no. 2, pp. 238–256, 2006, Accessed: Nov. 09, 2023. [Online]. Available: [http://www.scielo.org.bo/scielo.php?script=sci\\_arttext&pid=S1683-07892006000100008&lng=es&nrm=iso&tlng=es](http://www.scielo.org.bo/scielo.php?script=sci_arttext&pid=S1683-07892006000100008&lng=es&nrm=iso&tlng=es)
- [18] I. López Yáñez, C. Yáñez Márquez, O. C. Nieto, A. José, and A. Cruz, "Prediction of air contaminant concentration based on an associative pattern classifier," *Rev. Fac. Ing. Univ. Antioquia N.º*, vol. 60, pp. 20–30, 2011.
- [19] M. E. Manzur, G. Benzal, and S. N. González, "Atmospheric pollutants dispersion model," May 2012.
- [20] W. A. Castañeda Sánchez, B. R. Polo Escobar, F. Vega Huincho, W. A. Castañeda Sánchez, B. R. Polo Escobar, and F. Vega Huincho, "Redes neuronales artificiales: una medición de aprendizajes de pronósticos como demanda potencial," *Universidad, Ciencia y Tecnología*, vol. 27, no. 118, pp. 51–60, Feb. 2023, doi: 10.47460/UCT.V27I118.686.
- [21] W. Forero-Corba and F. N. Bennasar, "Techniques and applications of Machine Learning and Artificial Intelligence in education: a systematic review," *RIED-Revista Iberoamericana de Educacion a Distancia*, vol. 27, no. 1, pp. 209–253, Jan. 2024, doi: 10.5944/RIED.27.1.37491.
- [22] J. Gregorio Díaz, ; Ana, M. Mejías, and F. Arteaga, "Aplicación de los Filtros de Kalman a sistemas de control".
- [23] M. Cristina and M. Raga, "Filtro de Kalman y sus aplicaciones," Jun. 2018.
- [24] J. Sosa-Pedroza and F. Martínez-Zúñiga, "Los sistemas de información geográfica y su aplicación en enlaces de comunicaciones," vol. 13, pp. 27–34, 2009.
- [25] S. M. Pardo-García, "Geographic Information Systems (GIS) for Urbanism Instruction: the Case of Spain," vol. XXXVIII, 2017.

- [26] H. M. Fernando, R. Rodríguez, and I. Catastral Y Geodesta, "Application of interpolation methods and geostatistical modeling in the evaluation of air quality in Bogota".
- [27] M. Castro Franco, D. Y. García Ramírez, A. F. Jiménez López, M. Castro Franco, D. Y. García Ramírez, and A. F. Jiménez López, "Comparación de técnicas de interpolación espacial de propiedades del suelo en el piedemonte llanero colombiano," *Tecnura*, vol. 21, no. 53, pp. 78–95, 2017, doi: 10.14483/UDISTRITAL.JOUR.TECNURA.2017.3.A05.
- [28] "Distribución espacial del dengue basado en herramientas del Sistema de Información Geográfica, Valle de Aburrá, Colombia." Accessed: Sep. 22, 2024. [Online]. Available: [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0120-386X2014000100002](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0120-386X2014000100002)
- [29] A. J. Cavallo, S. M. Hock, and D. R. Smith, "Wind energy: Technology and economics," Dec. 31, 1993, *Island Press, Washington, DC (United States)*.
- [30] Á. Pinilla, "Wind power."
- [31] B. Aponte Páez and F. Alexis, "La sustentabilidad urbana en las ciudades," *Boletim Goiano de Geografia*, vol. 27, no. 2, pp. 11–33, 2007, Accessed: Jul. 10, 2024. [Online]. Available: <http://www.redalyc.org/articulo.oa?id=337127147001>
- [32] I. Nacional de Higiene, E. Microbiología Cuba Romero Placeres, D. Olite, and Á. Toste, "Revista Cubana de Higiene y Epidemiología," *Rev Cubana Hig Epidemiol*, vol. 44, no. 2, pp. 1–14, 2006, [Online]. Available: <http://www.redalyc.org/articulo.oa?id=223214848008>
- [33] J. Zhang and W. Ding, "Prediction of Air Pollutants Concentration Based on an Extreme Learning Machine: The Case of Hong Kong," *International Journal of Environmental Research and Public Health* 2017, Vol. 14, Page 114, vol. 14, no. 2, p. 114, Jan. 2017, doi: 10.3390/IJERPH14020114.
- [34] Rosales José, Torres Víctor, and Olaiz Gustavo, "Los efectos agudos de la contaminación del aire en la salud de la población: evidencias de estudios epidemiológicos." [Online]. Available: <http://www.insp.mx/>
- [35] C. Ubilla and K. Yohannessen, "Contaminación atmosférica efectos en la salud respiratoria en el niño," *Revista Médica Clínica Las Condes*, vol. 28, no. 1, pp. 111–118, Jan. 2017, doi: 10.1016/J.RMCLC.2016.12.003.
- [36] I. Nacional de Higiene, E. Microbiología Cuba Romero Placeres, D. Olite, and Á. Toste, "La contaminación del aire: su repercusión como problema de salud," *Rev Cubana Hig Epidemiol*, vol. 44, no. 2, pp. 1–14, 2006, Accessed: Nov. 09, 2023. [Online]. Available: <http://www.redalyc.org/articulo.oa?id=223214848008>
- [37] P. Homero and V. López, "Efectos de la contaminación ambiental en la flora y fauna en el cantón La Maná," *ConcienciaDigital*, vol. 1, no. 2, pp. 16–27, Apr. 2018, doi: 10.33262/concienciadigital.v1i2.947.

- [38] “La sustentabilidad urbana,” *Revista Bitácora Urbano Territorial* , vol. 1, pp. 8–14, 2004, Accessed: Jul. 30, 2024. [Online]. Available: <http://www.redalyc.org/articulo.oa?id=74800801>
- [39] “Naciones Unidas: Cumbre de johannesburgo 2002.” Accessed: Dec. 15, 2024. [Online]. Available: <https://www.un.org/spanish/conferences/wssd/desarrollo.htm>
- [40] “Naciones Unidas-Informe Brundtland,” p. 427, 1987.
- [41] “Medio ambiente y sustentabilidad urbana.” Accessed: Jul. 30, 2024. [Online]. Available: [https://www.scielo.org.mx/scielo.php?script=sci\\_arttext&pid=S1405-74252006000300007](https://www.scielo.org.mx/scielo.php?script=sci_arttext&pid=S1405-74252006000300007)
- [42] A. Rosa and A. Rodríguez, “La sostenibilidad urbana y el derecho a la ciudad,” vol. 21, no. 1, pp. 186–204, 2021, doi: 10.32997/2346-2884-vol.21.
- [43] A. Hayas Barrú, “Meteorología y contaminación atmosférica. Peculiaridades de la zona urbana de Jaén,” 1991.
- [44] A. Salcido *et al.*, “Calidad del aire y monitoreo atmosférico,” *Revista Digital Universitaria UNAM*, doi: 10.22201/codeic.16076079e.2019.v20n3.a3.
- [45] F. F. G. R., R. A. A. G., and K. M. J. J., “Metodología para la localización de estaciones de monitoreo de material particulado a escala local (0.5 a 4.0 Km) en la ciudad de Santa Marta,” *Gestión y Ambiente*, vol. 9, no. 2, pp. 121–135, 2006, Accessed: Nov. 19, 2024. [Online]. Available: <https://www.redalyc.org/articulo.oa?id=169420986001>
- [46] “Servicio Meteorológico Nacional.” Accessed: Jul. 29, 2024. [Online]. Available: <https://smn.conagua.gob.mx/es/>
- [47] “Comisión Nacional del Agua | Gobierno | gob.mx.” Accessed: Jul. 29, 2024. [Online]. Available: <https://www.gob.mx/conagua>
- [48] “Red Universitaria de Observatorios Atmosféricos.” Accessed: Dec. 06, 2023. [Online]. Available: <https://www.ruoa.unam.mx/index.php?page=estaciones&id=4>
- [49] INIFAP, “Estación Aguascalientes LNMySR”, Accessed: Feb. 15, 2024. [Online]. Available: <https://clima.inifap.gob.mx/lnmysr/Estaciones/Datos?numero=13476>
- [50] P. I. Fernanda Bolaños-Logroño, J. I. Luís Yauléma-Castañeda, O. Danilo Gavilánez-Álvarez III, and B. I. Leonardo Ayavaca-Vallejo, “Redes neuronales en la predicción de la velocidad del viento,” *Polo del Conocimiento: Revista científico - profesional*, ISSN-e 2550-682X, Vol. 5, Nº. 5, 2020, págs. 4-40, vol. 5, no. 5, pp. 4–40, 2020, doi: 10.23857/pc.v5i5.1398.
- [51] R. Garreaud S. and C. Meruane N., “Instrumentos meteorológicos y humedad atmosférica,” 2005.
- [52] R. Saldaña-Flores and C. Rivera-Blanco, “Assessment to wind power for electricity generation in the state of Veracruz, México”.

- [53] “Nueva Formula Densidad Aire PDF | PDF | Densidad | Metrología.” Accessed: Nov. 30, 2024. [Online]. Available: <https://es.scribd.com/document/355101516/NUEVA-FORMULA-DENSIDAD-AIRE-pdf>
- [54] S. Kumar. Mukhiya and Usman. Ahmed, “Hands-on exploratory data analysis with Python : perform EDA techniques to understand, summarize, and investigate your data,” p. 336, 2020.
- [55] S. F. Fernández, J. M. C. Sánchez, A. Córdoba, J. M. Cordero, and A. C. Largo, “Estadística Descriptiva,” *Estadística descriptiva*, p. 250, 2002, Accessed: Sep. 29, 2024. [Online]. Available: [https://books.google.com/books/about/Estadística\\_descriptiva.html?hl=es&id=31d5cGxXUnEC](https://books.google.com/books/about/Estadística_descriptiva.html?hl=es&id=31d5cGxXUnEC)
- [56] J. A. Mauricio, “Introducción al Análisis de Series Temporales,” pp. 47–67, Mar. 2007.
- [57] A. García, “Fundamentos Inteligencia Artificial,” *Fundamentos, Inteligencia Artificial*, vol. 12, pp. 1–14, 2012, Accessed: Aug. 20, 2024. [Online]. Available: <http://www.rclibros.es/pdf/InteligenciaArtificial.pdf>
- [58] R. M. Granados, “Modelos de regresión lineal múltiple”.
- [59] W. Forero-Corba and F. N. Bennasar, “Techniques and applications of Machine Learning and Artificial Intelligence in education: a systematic review,” *RIED-Revista Iberoamericana de Educacion a Distancia*, vol. 27, no. 1, pp. 209–253, Jan. 2024, doi: 10.5944/RIED.27.1.37491.
- [60] “El auge exponencial del lenguaje Python en el desarrollo tecnológico.” Accessed: Aug. 01, 2024. [Online]. Available: <https://journalingeniar.org/index.php/ingeniar/article/view/152/221>
- [61] “Artículo de investigación. Revista TIA,” vol. 8, no. 1 2020, Mar. 2020, Accessed: Sep. 28, 2024. [Online]. Available: [file:///C:/Users/andre/Downloads/aabucharp,+Revista+TIA.+Volumen+8+-+1+-+2020-37-53%20\(1\).pdf](file:///C:/Users/andre/Downloads/aabucharp,+Revista+TIA.+Volumen+8+-+1+-+2020-37-53%20(1).pdf)
- [62] C. Alonso, M. Tutor, and S. González, “Modelos de aprendizaje automático en la predicción de viento a corto plazo,” 2020, Accessed: Nov. 09, 2023. [Online]. Available: <https://repositorio.uam.es/handle/10486/692577>
- [63] A. M. Porcelli, “La Inteligencia Artificial y la Robótica: sus dilemas sociales, éticos y jurídicos,” *Derecho Global. Estudios sobre Derecho y Justicia*, vol. 6, no. 16, pp. 49–105, Oct. 2020, doi: 10.32870/DGEDJ.V6I16.286.
- [64] “Conceptos básicos de RNA.” Accessed: Sep. 30, 2024. [Online]. Available: <https://grupo.us.es/gtocom/pid/pid10/RedesNeuronales.htm>
- [65] M. Cristina and M. Raga, “Filtro de Kalman y sus aplicaciones,” Jun. 2018.

- [66] “Redes Neuronales de Clasificación y Regresión - Qiskit Machine Learning 0.7.0.” Accessed: Dec. 08, 2023. [Online]. Available: [https://qiskit.org/ecosystem/machine-learning/locale/es\\_UN/tutorials/02\\_neural\\_network\\_classifier\\_and\\_regressor.html](https://qiskit.org/ecosystem/machine-learning/locale/es_UN/tutorials/02_neural_network_classifier_and_regressor.html)
- [67] R. Flórez López and J. M. Fernández Fernández, “Las Redes Neuronales Artificiales: Aspectos generales,” *Las Redes Neuronales Artificiales Fundamentos*, pp. 16–17, 2008, Accessed: Sep. 30, 2024. [Online]. Available: [https://books.google.com/books/about/Las\\_Red\\_Neuronales\\_Artificiales.html?hl=es&id=X0uLwi1Ap4QC](https://books.google.com/books/about/Las_Red_Neuronales_Artificiales.html?hl=es&id=X0uLwi1Ap4QC)
- [68] J. P. Vasquez Lopez, “Red Neuronal Feedforward como estimador de patrones de corrientes en el interior del puerto de Manzanillo sujeto a la acción de Tsunamis,” *Publicación técnica*, no. 406, 2014, Accessed: Oct. 17, 2024. [Online]. Available: <https://www.imt.mx/archivos/Publicaciones/PublicacionTecnica/pt406.pdf>
- [69] N. Basado, E. N. Filtro, D. E. Kalman, H. Aboukheir, U. Rafael, and B. Chacín -Venezuela, “Revista Electrónica de Estudios Telemáticos”.
- [70] F. A. Sarria, “Sistemas de Información Geográfica”, Accessed: Sep. 30, 2024. [Online]. Available: <https://es.scribd.com/document/456597742/Sistemas-de-Informacion-Geografica-Francisco-A-Sarri-a-Cap-2>
- [71] “Argicultura de Precision - Google Libros.” Accessed: Sep. 30, 2024. [Online]. Available: [https://books.google.com.mx/books?id=1ef6-NN2XsAC&pg=PA154&dq=interpolacion+IDW&hl=es-419&newbks=1&newbks\\_redir=0&source=gb\\_mobile\\_search&ovdme=1&sa=X&ved=2ahUKEwiP0vWpnuylAxUcm7AFHTzFENGQuwV6BAgHEAY#v=onepage&q=interpolacion%20IDW&f=false](https://books.google.com.mx/books?id=1ef6-NN2XsAC&pg=PA154&dq=interpolacion+IDW&hl=es-419&newbks=1&newbks_redir=0&source=gb_mobile_search&ovdme=1&sa=X&ved=2ahUKEwiP0vWpnuylAxUcm7AFHTzFENGQuwV6BAgHEAY#v=onepage&q=interpolacion%20IDW&f=false)
- [72] “Métodos de interpolación.” Accessed: Sep. 30, 2024. [Online]. Available: <https://www6.uniovi.es/~feli/CursoMDT/Tema1/Page16.html>
- [73] Universidad Nacional Autónoma de México, “Observatorio Atmosférico Aguascalientes, Red Universitaria de Observatorios Atmosféricos.” Accessed: Jul. 07, 2023. [Online]. Available: <https://www.ruoa.unam.mx/index.php?page=estaciones&id=4>
- [74] V. Rossum, “Welcome to Python.org.” Accessed: Apr. 25, 2024. [Online]. Available: <https://www.python.org/>
- [75] “pandas - Python Data Analysis Library.” Accessed: Dec. 05, 2023. [Online]. Available: <https://pandas.pydata.org/>
- [76] “Matplotlib — Visualization with Python.” Accessed: Dec. 06, 2023. [Online]. Available: <https://matplotlib.org/>

- [77] Y. Dong and C. Y. J. Peng, "Principled missing data methods for researchers," *Springerplus*, vol. 2, no. 1, pp. 1–17, May 2013, doi: 10.1186/2193-1801-2-222/TABLES/3.
- [78] J. C. Jakobsen, C. Gluud, J. Wetterslev, and P. Winkel, "When and how should multiple imputation be used for handling missing data in randomised clinical trials - A practical guide with flowcharts," *BMC Med Res Methodol*, vol. 17, no. 1, pp. 1–10, Dec. 2017, doi: 10.1186/S12874-017-0442-1/TABLES/2.
- [79] C. Holguín, Y. Díaz-Ricardo, and R. Antonio Becerra-García, "The programming language Python ", Accessed: Oct. 24, 2024. [Online]. Available: <http://www.linuxjournal.com/article/2959>
- [80] "seaborn: visualización de datos estadísticos — documentación de seaborn 0.13.2." Accessed: Sep. 29, 2024. [Online]. Available: <https://seaborn.pydata.org/>
- [81] P. Virtanen, R. Gommers, M. Haberland, T. Reddy, and D. Cournapeau, "SciPy." Accessed: Apr. 25, 2024. [Online]. Available: <https://scipy.org/>
- [82] "statsmodels 0.14.0." Accessed: Dec. 05, 2023. [Online]. Available: <https://www.statsmodels.org/stable/index.html>
- [83] F. Chollet, "Deep learning mit python und keras: das praxis-handbuch vom entwickler der keras-bibliothek." Accessed: Feb. 19, 2024. [Online]. Available: <https://keras.io/api/>
- [84] "10 Librerías Python para Data Science y Machine Learning." Accessed: Aug. 02, 2024. [Online]. Available: <https://verneacademy.com/blog/articulos-ia/10-librerias-python-data-science-machine-learning/>
- [85] "Joblib: running Python functions as pipeline jobs — joblib 1.4.0 documentation." Accessed: Apr. 26, 2024. [Online]. Available: <https://joblib.readthedocs.io/en/stable/>
- [86] "Comparación de la Red Neuronal y del Filtro de Kalman en la estimación de Velocidad del Motor de Inducción".
- [87] "Spatial without Compromise · QGIS Web Site." Accessed: Aug. 21, 2024. [Online]. Available: <https://www.qgis.org/>
- [88] "basemap 1.4.1 documentation." Accessed: Jul. 10, 2024. [Online]. Available: <https://matplotlib.org/basemap/stable/>
- [89] "Introducción - documentación de basemap 1.4.1." Accessed: Sep. 29, 2024. [Online]. Available: <https://matplotlib.org/basemap/stable/users/introduction.html>
- [90] Semar.gob, "Escala Beaufort." Accessed: Dec. 05, 2023. [Online]. Available: <https://www.semar.gob.mx/meteorologia/ESCALA%20BEAUFORT.htm>
- [91] J. L. López López *et al.*, "Estadística preliminar de los vientos para la zona urbana de Aguascalientes," *Investigación y Ciencia: de la Universidad Autónoma de Aguascalientes*, ISSN-e 1665-4412, No. 41, 2008, *pág. 20*, no. 41, p. 20, 2008, Accessed: Dec. 05, 2024.

- [Online]. Available:  
<https://dialnet.unirioja.es/servlet/articulo?codigo=6104551&info=resumen&idioma=ENG>
- [92] A. Couto and A. Estanqueiro, “Enhancing wind power forecast accuracy using the weather research and forecasting numerical model-based features and artificial neuronal networks,” *Renew Energy*, vol. 201, pp. 1076–1085, Dec. 2022, doi: 10.1016/J.RENENE.2022.11.022.
- [93] “DOF - Diario Oficial de la Federación.” Accessed: Dec. 05, 2024. [Online]. Available: [https://www.dof.gob.mx/nota\\_detalle.php?codigo=5259464&fecha=16/07/2012#gsc.tab=0](https://www.dof.gob.mx/nota_detalle.php?codigo=5259464&fecha=16/07/2012#gsc.tab=0)
- [94] “DOF - Diario Oficial de la Federación.” Accessed: Dec. 05, 2024. [Online]. Available: [https://www.dof.gob.mx/nota\\_detalle.php?codigo=5408588&fecha=17/09/2015#gsc.tab=0](https://www.dof.gob.mx/nota_detalle.php?codigo=5408588&fecha=17/09/2015#gsc.tab=0)
- [95] “Aerogenerador: qué es, partes y su función | Enel Green Power.” Accessed: Dec. 05, 2024. [Online]. Available: <https://www.enelgreenpower.com/es/learning-hub/energias-renovables/energia-eolica/aerogenerador>
- [96] “Instituto Nacional de Investigaciones Forestales, Agrícolas y Pecuarias | Gobierno | gob.mx.” Accessed: Nov. 24, 2024. [Online]. Available: <https://clima.inifap.gob.mx/lnmysr/Estaciones/Mapa>
- [97] “GitHub.” Accessed: Dec. 13, 2024. [Online]. Available: <https://github.com/>

## Anexo A

En este Anexo se incluye la Tabla A.1, la cual detalla el número, nombre y ubicación de las 17 estaciones de monitoreo del INIFAP utilizadas en este estudio.

Tabla A.1. Estaciones de monitoreo del INIFAP [96].

| Número | Nombre        | Estado-municipio                          | Latitud    | Longitud    |
|--------|---------------|-------------------------------------------|------------|-------------|
| 22     | Granja Elsa   | Aguascalientes, Aguascalientes            | 21.7853    | -102.264    |
| 13467  | Don Primo     | Aguascalientes, Pabellón de Arteaga       | 22.1233616 | -102.254776 |
| 13470  | Santa Lucía   | Aguascalientes, San Francisco de los Romo | 22.0542774 | -102.29464  |
| 13471  | Makelisa      | Aguascalientes, Tepezalá                  | 22.2176666 | -102.274918 |
| 13472  | Santa Anita   | Aguascalientes, Aguascalientes            | 21.7551384 | -102.315    |
| 13473  | Los Pinos     | Aguascalientes, Rincón de Romos           | 22.33206   | -102.2231   |
| 13474  | Medio Kilo    | Aguascalientes, San Francisco de los Romo | 22.0025    | -102.26667  |
| 13476  | Universidad   | Aguascalientes, Aguascalientes            | 21.91565   | -102.318832 |
| 15977  | Sandoval      | Aguascalientes, El Llano                  | 21.9025269 | -102.069763 |
| 18787  | El Cedazo     | Aguascalientes, Aguascalientes            | 21.8648    | -102.259331 |
| 18833  | San Jacobo    | Aguascalientes, Jesús María               | 21.9224339 | -102.375549 |
| 22575  | El Potrerito  | Aguascalientes, Cosío                     | 22.3637218 | -102.291725 |
| 22581  | CEPAB         | Aguascalientes, Pabellón de Arteaga       | 22.1671257 | -102.292976 |
| 24576  | El Becerro    | Aguascalientes, Aguascalientes            | 21.978     | -102.183891 |
| 24588  | La Posta      | Aguascalientes, Jesús María               | 21.97286   | -102.362831 |
| 25427  | Los Gavilanes | Aguascalientes, Aguascalientes            | 21.77011   | -102.459053 |
| 48291  | Huizache      | Aguascalientes, El Llano                  | 21.942     | -102.0603   |

## *Anexo B*

En este Anexo se proporciona un Código QR B.1. que enlaza a un *GIF* asociado a la Figura 32 (modelo RNE-IDW) del capítulo de Resultados, el cual se encuentra en un repositorio de Github [97]. En dicho repositorio se encuentra tanto la Figura del *GIF* ya generada como el código desarrollado en *Python* para su creación. Además, se incluyen los respectivos modelos de RNN y los escaladores, en caso de que se desee ejecutar el código de manera independiente.

Particularmente en el *GIF* se visualiza la dinámica de los patrones del viento durante un período de 24 horas, proporcionando una perspectiva más detallada del análisis de los resultados presentados. Adicionalmente, el contenido también puede consultarse directamente a través del enlace: <https://github.com/AndreaAguilarBurke/RNE-IDW>.



*Código QR B.1. Dinámica de los patrones del viento durante un período de 24 horas (modelo RNE-IDW).*