

UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA

Facultad de Ingeniería, Arquitectura y Diseño



Maestría y Doctorado en
Ciencias e Ingeniería

**“MULTIFRACTALIDAD DE LOS VIENTOS DE SANTA ANA EN LA CUENCA
HIDROGRÁFICA DE GUADALUPE”**

TESIS

que para cubrir parcialmente los requisitos necesarios para obtener el grado de

DOCTOR EN CIENCIAS

Presenta

M.I. YERALDIN SERPA USTA

Ensenada, Baja California, agosto del 2024.

UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA

Facultad de Ingeniería, Arquitectura y Diseño

MULTIFRACTALIDAD DE LOS VIENTOS DE SANTA ANA EN LA CUENCA HIDROGRÁFICA DE GUADALUPE

TESIS

que para cubrir parcialmente los requisitos necesarios para obtener el grado de

DOCTOR EN CIENCIA

Presenta

M.I. YERALDIN SERPA USTA

Aprobada por:

Dr. Alvaro Alberto López Lambraño
Director de Tesis

Dra. Dora Luz Flores Gutiérrez
Codirectora de Tesis

Dr. Mario González Durán
Miembro del Comité

Dr. Jorge Octavio Mata Ramírez
Miembro del Comité

Dr. Efraín Gómez Arias
Miembro del Comité

Ensenada, Baja California, agosto del 2024.

Resumen de la tesis de Yeraldin Serpa Usta, presentada como requisito parcial para la obtención del grado de DOCTOR EN CIENCIAS del programa de Maestría y Doctorado en Ciencias e Ingeniería (MYDCI) de la UABC. Ensenada Baja California, México, agosto del 2024.

MULTIFRACTALIDAD DE LOS VIENTOS DE SANTA ANA EN LA CUENCA HIDROGRÁFICA DE GUADALUPE

Resumen Aprobado por:



Dr. Alvaro Alberto López Lambraño
Director de Tesis

Dra. Dora Luz Flores Gutiérrez
Co - director de Tesis

Se realizó el análisis fractal y multifractal de las variables meteorológicas de temperatura, presión, humedad relativa, velocidad y dirección del viento para dieciséis (16) estaciones localizadas en la cuenca hidrográfica de Guadalupe en Baja California, México. La investigación incluyó información de treinta y ocho (38) años de la base de datos de CLICOM y MERRA-2. Se investigó la naturaleza multifractal de los datos diarios de las series de tiempo diarias para variables climáticas asociadas con los vientos de Santa Ana. El análisis fractal permitió caracterizar los vientos de Santa Ana en términos de su persistencia, antipersistencia y aleatoriedad, del mismo modo se realizó con el exponente de Hurst generalizado estimado como parte del análisis multifractal; a su vez se generaron los espectros de singularidades de las variables ya mencionadas para explicar la ocurrencia, caracterización y fluctuaciones de las mismas. Con las propiedades multifractales se identificaron los procesos correlacionados y no correlacionados, las regiones susceptibles a eventos extremos, las correlaciones a largo plazo y corto plazo, y predominio de pequeñas o grandes fluctuaciones en las series de tiempo de los vientos de Santa Ana. Finalmente, los valores correspondientes a los parámetros y características del espectro multifractal o singularidades pueden usarse como indicadores cuantitativos y cualitativos para describir la dinámica de los procesos meteorológicos durante la ocurrencia de los vientos de Santa Ana en la cuenca de Guadalupe.

Palabras clave: espectro de singularidades, multifractalidad, vientos de Santa Ana.

DEDICATORIA

A mi madre y mi hermana,

Rosiris Usta Gloria

y

Diana Serpa Usta

AGRADECIMIENTOS

Quisiera expresar mi más profundo agradecimiento a mi asesor, Dr. Alvaro Alberto López Lambrano, por su guía inquebrantable, paciencia y apoyo incondicional durante todo el proceso de investigación y redacción de esta tesis. Su expertise y constante motivación fueron esenciales para el desarrollo y culminación de este trabajo. Como dijo Novak Djokovic: “Si solo hay una persona en este mundo que acepte, abrace y apoye tus sueños, encuentra a esa persona y sueña en grande”. Gracias por ser esa persona.

Mi gratitud también va dirigida a mi co-directora, Dra. Dora Luz Flores Gutiérrez, por ser inspiración para mí en un mundo dominado por los hombres; por su paciencia en las clases de redes neuronales y creer en que si podía aprender a programar.

Agradezco al M.Sc. Alvaro López Ramos, por ser la primera persona que dio un voto de confianza a mi proceso académico, gracias por su ejemplo y sus sabias palabras.

Agradezco también a los profesores Dr. Jorge Octavio Mata, Dr. Mario González Durán y al Dr. Efraín Gómez Arias por sus valiosas aportaciones, sugerencias y consejos a lo largo de mi formación académica. Sus enseñanzas y orientaciones han sido de gran ayuda en mi crecimiento profesional y personal.

Quisiera agradecer a la Universidad Autónoma de Baja California por brindarme los recursos y el ambiente adecuado para llevar a cabo mi investigación. También extendiendo mi gratitud al Consejo Nacional de Ciencia y Tecnología por la beca otorgada, que permitió dedicarme plenamente a mis estudios de doctorado.

A mis compañeros de estudio y colegas del posgrado, gracias por su camaradería, apoyo moral y por las enriquecedoras discusiones que tuvimos a lo largo de este camino. Su amistad y colaboración hicieron de este viaje una experiencia mucho más llevadera y gratificante. Por esas amistades virtuales producto de la pandemia.

A mi familia, en especial a mi madre Rosiris Usta, por su amor, comprensión y sacrificios. A mi hermana, Diana Carolina, por su constante apoyo y ánimo. Su confianza en mí ha sido una fuente constante de motivación. Y a mis amigas, Yina y María Lucía, gracias por su paciencia y por estar siempre ahí para brindarme su apoyo emocional.

A mi familia en México: Dina, Nicole y Paola, ustedes hicieron que esta extranjera se sintiera parte de un hogar, aunque no estuviera en casa.

Finalmente, agradezco a todos aquellos que, de una forma u otra, han contribuido a la realización de esta tesis. Gracias desde el fondo de mi corazón.

Tabla de contenido

ÍNDICE DE FIGURAS.....	iii
ÍNDICE DE TABLAS	vi
ÍNDICE DE ECUACIONES	vii
1 Introducción.....	1
1.1 Estado del arte (general).....	1
1.2 Justificación.....	5
1.3 Descripción del problema.....	5
1.4 Objetivos	6
1.4.1 Objetivo general	6
1.4.2 Objetivos específicos.....	7
1.5 Hipótesis.....	7
2 Área de estudio y descripción de los vientos de Santa Ana.....	8
3 Análisis fractal de vientos de Santa Ana (días con viento de Santa Ana y días sin vientos de Santa Ana)	13
3.1 Geometría fractal.....	16
3.1.1 Rango reescalado.....	17
3.1.2 Índice de previsibilidad climática	21
3.2 Metodología	23
3.3 Fractalidad de los Vientos de Santa Ana	24
3.3.1 Análisis fractal.....	24
3.3.2 Índice de previsibilidad	31
3.4 Conclusiones	49
4 Aplicación de redes neuronales recurrentes para la predicción de condiciones de vientos de Santa Ana.....	51
4.1 Introducción	51

4.2	LSTM para el pronóstico de condiciones de vientos de Santa Ana	52
4.3	Metodología	54
4.4	Resultados	58
4.5	Conclusiones	63
5	Análisis Multifractal de los vientos de Santa Ana.....	64
5.1	Formalismo multifractal.....	65
5.2	MF DFA	70
5.3	Parámetros multifractales.....	73
5.4	Multifractalidad de los vientos de Santa Ana.....	74
5.5	Conclusiones	92
6	Análisis complementario	95
6.1	Análisis de correlación de parámetros multifractales	95
6.1.1	Matriz de correlación	96
6.1.2	Análisis mediante matriz de correlación	97
6.2	Análisis multicriterio.....	102
6.2.1	Reclasificación	102
6.2.2	Álgebra de mapas	103
6.2.3	Solución del análisis multicriterio.....	104
6.2.4	Reclasificación de parámetros multifractales.....	105
7	Conclusiones Generales.....	114
8	Referencias	116
	APÉNDICE A. GRAFICAS DE LOS ESPECTROS PARA CADA ESTACIÓN.....	131

ÍNDICE DE FIGURAS

Figura 1. Localización del área de estudio.....	8
Figura 2. Metodología utilizada.....	9
Figura 3. Matriz de correlación de índices de previsibilidad para la serie de tiempo compuesta por días con vientos de Santa Ana.....	37
Figura 4. Matriz de correlación de índices de previsibilidad para la serie de tiempo compuesta por días sin vientos de Santa Ana.....	39
Figura 5. Matriz de correlación para exponentes de Hurst para las series de tiempo compuesta por días con vientos de Santa Ana.....	41
Figura 6. Matriz de correlación para exponentes de Hurst para las series de tiempo conformadas por días sin vientos de Santa Ana.	41
Figura 7. Mapas del exponente de Hurst para las series de tiempo conformadas por días con vientos de Santa Ana y para las variables de: (a) temperatura, (b)presión, (c) humedad relativa y (d) velocidad del viento.	42
Figura 8. Mapas del exponente de Hurst para las series de tiempo conformadas con días sin vientos de Santa Ana y para las variables de: (a) temperatura, (b)presión, (c) humedad relativa y (d) velocidad del viento.	44
Figura 9. Mapas del índice de previsibilidad para días con vientos de Santa Ana para las variables de (a) temperatura, (b) presión, (c) humedad relativa y (d) velocidad del viento.....	46
Figura 10. Mapas del índice de previsibilidad para días sin vientos de Santa Ana para las variables de: (a) temperatura, (b)presión, (c) humedad relativa y (d) velocidad del viento.	48
Figura 11. Diagrama de la estructura de una red LSTM (Shi et al., 2024).....	53
Figura 12. Gráfica de las series de tiempo de velocidad del viento, dirección del viento, temperatura, humedad relativa y presión.	55
Figura 13. Salida de media, desviación estándar y percentiles de las variables analizadas	55
Figura 14. Salida para ADFuller.	56
Figura 15. Gráfica de tasa de variación explicada de los componentes principales	56
Figura 16. Gráfica de la varianza explicada acumulada.	57
Figura 17. Salida de primer entrenamiento para la red propuesta	59
Figura 18. Curva de aprendizaje para la red modificada	60

Figura 19. Curva de aprendizaje para un tamaño de lote de 32.	61
Figura 20. Salida de días de la predicción que cumplen con la condición de Santa Ana.	61
Figura 21. Curva de aprendizaje implementando regularización de 0.01.....	62
Figura 22. Grafica de velocidad del viento actual y predicción	62
Figura 23. Representación log-log para la función de fluctuación de los datos de los vientos de Santa Ana en la estación Agua Caliente, $q = 10$	75
Figura 24. Función $h(q)$ y $\tau(q)$ para valores de $q = -10, 10$; a partir de dicha función se genera el espectro multifractal.....	77
Figura 25. Espectro multifractal de la serie de vientos de Santa Ana registrada entre 1980 y 2018 en la estación Agua Caliente. $f(\alpha)$ se obtuvo de las funciones $h(q)$ y $\tau(q)$ para valores de $q = -10, 10$	81
Figura 26. Espectro multifractal de las series de tiempo meteorológicas estudiadas para la cuenca hidrográfica de Guadalupe.	84
Figura 27. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la temperatura.	86
Figura 28. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la humedad relativa.	87
Figura 29. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la presión.	87
Figura 30. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la dirección del viento.	88
Figura 31. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la velocidad del viento.	88
Figura 32. Matriz de correlación de parámetros multifractales.	98
Figura 33. Mapas de reclasificación para el parámetro del $\Delta\alpha$ para valores < 0.4 el primer escenario la variable de a) temperatura, b) presión y c) dirección del viento.....	107
Figura 34. Mapas de reclasificación para el parámetro del $\Delta\alpha$ para valores < 0.5 de la variable de a) temperatura, b) humedad relativa, c) presión, d) dirección del viento y e) velocidad del viento.	108
Figura 35. Mapas de reclasificación para el parámetro del r para la variable de a) temperatura, b) humedad relativa, c) presión, d) dirección del viento y e) velocidad del viento.	109

Figura 36. Mapa con el área más predecible de las variables de temperatura, presión y dirección del viento para $\Delta\alpha < 0.4$	111
Figura 37. Mapa de zona más predecible de acuerdo a los anchos de los espectros de las variables de temperatura, humedad relativa, presión, dirección y velocidad del viento para $\Delta\alpha < 0.5$	112
Figura 38. Mapa de las zonas con asimetrías $r > 1$ para las variables de los vientos de Santa Ana.	113

ÍNDICE DE TABLAS

Tabla 1. Estaciones climatológicas en el área de estudio y sus características de interés.	10
Tabla 2. Exponente de Hurst para las estaciones de la cuenca hidrográfica del valle de Guadalupe para las variables de presión, temperatura (T), precipitación, humedad relativa (HR) y velocidad del viento (VV).	24
Tabla 3. Criterios para seleccionar días con vientos de Santa Ana.	27
Tabla 4. Exponente de Hurst para las variables meteorológicas en estudio en los días con vientos de Santa Ana y días sin vientos de Santa Ana.	27
Tabla 5. Índices de previsibilidad de presión, temperatura, precipitación, humedad relativa, velocidad y dirección del viento para días con y sin viento de Santa Ana.	31
Tabla 6. Índice de previsibilidad climática para días con vientos de Santa Ana y correlación entre parámetros meteorológicos.	33
Tabla 7. Índice de previsibilidad climática para días sin vientos de Santa Ana y correlación entre parámetros meteorológicos.	35
Tabla 8. Rangos del coeficiente de correlación	37
Tabla 9. Resumen de parámetros seleccionados	58
Tabla 10. Parámetros de la red con las modificaciones al diseño original.	59
Tabla 11. Parámetros multifractales del MF DFA (adimensionales) para las variables meteorológicas estudiadas.	80

ÍNDICE DE ECUACIONES

Ecuación (1).....	16
Ecuación (2).....	17
Ecuación (3).....	18
Ecuación (4).....	18
Ecuación (5).....	18
Ecuación (6).....	18
Ecuación (7).....	19
Ecuación (8).....	19
Ecuación (9).....	20
Ecuación (10).....	21
Ecuación (11).....	21
Ecuación (12).....	21
Ecuación (13).....	21
Ecuación (14).....	21
Ecuación (15).....	22
Ecuación (16).....	22
Ecuación (17).....	22
Ecuación (18).....	66
Ecuación (19).....	66
Ecuación (20).....	66
Ecuación (21).....	67
Ecuación (22).....	67
Ecuación (23).....	68
Ecuación (24).....	68
Ecuación (25).....	68
Ecuación (26).....	68
Ecuación (27).....	68
Ecuación (28).....	69
Ecuación (29).....	69

Ecuación (30).....	70
Ecuación (31).....	71
Ecuación (32).....	71
Ecuación (33).....	72
Ecuación (34).....	72
Ecuación (35).....	73
Ecuación (36).....	95

1 Introducción

1.1 Estado del arte (general)

La estimación de las fluctuaciones locales de las series de tiempo meteorológicas es uno de los problemas más desafiantes en el análisis de dichas series. En la década de 1970, los investigadores identificaron el comportamiento fractal de las series de tiempo, Mandelbrot propuso el termino fractal que deriva del latín *fractus* que significa quebrado, fracturado; esto se refiere a la propiedad que tiene un objeto geométrico fragmentario de poderse subdividir en partes, cada una de las cuales es una copia de tamaño reducido del todo. A lo largo de los años, se desarrollaron una gran cantidad de métodos para la estimación de la fractalidad de los datos de series de tiempo; estos incluyen momentos de doble traza, análisis espectral de Fourier, principios de auto semejanza extendida (Extended Self Similarity), módulo máximo de transformada de ondas (Wavelet Transform Modulus Maxima), análisis espectral de Hilbert de orden arbitrario (Arbitrary Order Hilbert Spectral Analysis). Peng et al., en 1994 propusieron un método eficaz denominado Análisis de fluctuación de tendencia (Detrended Fluctuation Analysis) para realizar el análisis fractal basado en un procedimiento de eliminación de tendencia, el DFA se ha utilizado ampliamente en los últimos años para la determinación de las propiedades de escala fractal y la detección de correlaciones de largo alcance en series de tiempo ruidosas y no estacionarias (Adarsh, Nourani, Archana, & Dharan, 2020). En 2002, Kantelhardt propuso un nuevo método basado en el DFA, pero ampliado al campo multifractal, este procedimiento es el análisis multifractal sin fluctuación de tendencia (Multifractal - Detrended Fluctuation Analysis).

La multifractalidad es una propiedad matemática que describe sistemas que exhiben una complejidad a diferentes escalas. En el contexto de las series de tiempo de variables climáticas, la

multifractalidad se refiere a la variabilidad de los patrones climáticos a diferentes duraciones. Las series de tiempo multifractales son aquellas en las que la relación estadística entre las fluctuaciones a diferentes escalas no es constante, sino que varía en función de la escala. Las series de tiempo hidrometeorológicas a menudo exhiben propiedades autosimilares o autoafines en un rango específico de escalas de tiempo y, por lo tanto, pueden caracterizarse como fractales (Shang & Kamae, 2005).

Aunque las características multifractales de las series de tiempo hidrológicas y meteorológicas han sido ampliamente estudiadas en la literatura, su aplicación práctica y difusión para simulación o predicción siguen siendo bastante limitadas. Comprender las propiedades multifractales puede ser muy efectivo para el modelado, la simulación y la generación sintética en los campos hidrometeorológicos, así como para la eliminación de ruido en señales hidrometeorológicas. Estas propiedades se presentan como herramientas capaces de detectar la homogeneidad y analizar la frecuencia. El análisis de la variabilidad espacial y temporal de las propiedades multifractales es de gran relevancia práctica, ya que puede ayudar a identificar los mecanismos y los tiempos de ocurrencia de eventos extremos hidrológicos tales como olas de calor, aumentos en la temperatura global, sequías y precipitaciones extremas.

La multifractalidad también se ha aplicado para entender fenómenos climáticos como el fenómeno del Niño. (Jaroszewicz, Mariani, Tweneboah, & Beccar-Varela, 2024) analizaron con el método del MF-DFA el Índice de Oscilación Sur (IOS) para un intervalo de tiempo de 1991 al 2020, que proporcione información sobre la compleja dinámica en las escalas de tiempo; lo que permite mejorar la comprensión de las fluctuaciones en el IOS, demostrando lo útil que es la aplicación de este tipo de técnicas; la perspectiva multifractal complementa los métodos tradicionales a su vez que respalda mejores modelos, pronósticos y conocimientos climáticos.

(Sankaran, Plocoste, Geetha Raveendran Nair, & Mohan, 2024) plantearon un análisis integral de la variabilidad espaciotemporal del comportamiento de escala de las series de temperatura diarias en todo el territorio continental de la India, utilizando un análisis de fluctuación multifractal sin tendencia (MFDFA) a fin de mejorar la comprensión del impacto del cambio climático en la India continental.

Precisamente en esas áreas donde se dificulta determinar que es cambio climático producto de la actividad antrópica o es parte del proceso natural, el análisis multifractal es una herramienta valiosa; como es el caso del aumento en los niveles medios del mar a nivel mundial y regional; si bien existe un consenso de los científicos de que esta ha aumentado desde finales del siglo XIX, la contribución de la naturaleza y la provocada por el hombre sigue sin estar clara. (Costas Varotsos, Mazei, Sarlis, Saldaev, & Efstathiou, 2024), encontraron que las correlaciones a largo plazo se deben principalmente a causas naturales, debido a las características de escala casi idénticas tanto para la serie temporal de mediciones en estaciones en zonas costeras e insulares de 134 años como para la serie temporal de nivel medio global del mar de 28 años obtenidas de las misiones de altímetro satelital TOPEX/Poseidon, Jason-1, Jason-2 y Jason-3. El análisis multifractal del nivel medio global del mar puede contribuir en temas tan álgidos como las proyecciones del aumento medio global y regional del nivel del mar y ayudar a integrar una visión holística para diseñar estrategias ad hoc y mitigar los impactos inevitables.

El análisis multifractal mediante el MF-DFA, se ha implementado también para examinar el comportamiento multifractal de las precipitaciones premonzónicas y monzónicas de verano de la India (Indian Summer Monsoon Rainfall) en la zona noreste de la India cuyos resultados confirman la estimación de las predicciones de lluvias futuras para estos dos eventos mediante métodos autorregresivos dada a la persistencia que exhibieron estas series de tiempo para el

premonzón y el monzón de verano aun cuando en algunos casos debido también a la presencia de cuasi aleatoriedad dificultaría el pronóstico autorregresivo (Devi & Chattopadhyay, 2023); este tipo de análisis permite caracterizar el régimen de lluvias e identificar las áreas donde el pronóstico de la cantidad de lluvia sería más fácil o un desafío.

El MF-DFA es una herramienta sólida para evaluar las propiedades no lineales de series temporales ambientales en un área compleja; comprender mejor las fluctuaciones de las precipitaciones en estos entornos complejos es crucial para desarrollar posteriormente modelos de predicción, de aquí la importancia de la caracterización multifractal de las series de precipitaciones para comprender las relaciones no lineales subyacentes entre la intensidad de la lluvia, la circulación atmosférica general y la ubicación geográfica en estas zonas como es el caso del Archipiélago de Guadalupe (Gómez-Gómez, Plocoste, et al., 2023)

El análisis de los valores de los parámetros multifractales permite distinguir los cambios que corresponden a cambio climático como es el caso de la temperatura media diaria en el territorio de Serbia, donde se compararon dos periodos de tiempo, de 1961 a 1990 y 1991 a 2020, y los cambios en los valores de los parámetros multifractales de α_0 , $\Delta\alpha$ y r entre periodos indican que para el segundo periodo el proceso estocástico subyacente que gobierna las fluctuaciones de temperatura se vuelve más complejo, lo que podría atribuirse al cambio climático (Stosic et al., 2023).

Además del método MF-DFA, existe una variante del mismo conocida como el análisis multifractal de correlación cruzada sin tendencia (MFCCA), propuesta por Oświęcimka et al. como una generalización adecuada del cálculo del exponente de escala de correlación cruzada fractal, λ , para diferentes momentos estadísticos para determinar correlaciones cruzadas multifractales entre dos series de tiempo. El MFCCA es útil para identificar correlaciones cruzadas

multifractales cuando participan más de tres variables. Además, tiene la ventaja de ser más fácil de interpretar que las distribuciones de muchas dimensiones obtenidas mediante el método multifractal conjunto (Gómez-Gómez, Ariza-Villaverde, Gutiérrez de Ravé, & Jiménez-Hornero, 2023).

El método multifractal MF-DFA, se ha aplicado para complementar modelos de predicción como parte de los llamados modelos híbridos, que se ajustan mejor a variables complejas como la velocidad del viento (Méndez-Gordillo & Cadenas, 2021).

1.2 Justificación

El análisis multifractal de las series de tiempo para múltiples variables meteorológicas se encuentra en desarrollo. Se ha manifestado como una herramienta útil para encontrar la relación entre los diferentes momentos en relación con la escala de tiempo. Así mismo, el análisis del espectro de singularidades podría explicar la ocurrencia, caracterización y fluctuaciones de las series temporales correspondientes a variables meteorológicas. Finalmente, el análisis multifractal podría servir como una herramienta de calibración y validación de vectores generados de manera sintéticas al comparar las singularidades observadas con las generadas.

1.3 Descripción del problema

Los parámetros meteorológicos tales como, la precipitación y la temperatura, dependen de una diversidad de procesos termodinámicos y muestran fluctuaciones aleatorias en diferentes escalas temporales y espaciales debido a los complejos procesos naturales que se ven involucrados. Además, las ecuaciones que describen estos procesos son a menudo de tipo no lineales, como, por ejemplo, las ecuaciones de Navier-Stoke que se utilizan para tratar de comprender la dinámica del

flujo atmosférico. El resultado de esto, es que los métodos estadísticos lineales y estocásticos son insuficientes para la realización de un análisis y caracterización de las series temporales de las variables meteorológicas como la temperatura, precipitación, humedad relativa, brillo solar, radiación solar, evaporación y velocidad del viento. Por lo anterior, en la actualidad se continúa trabajando en el desarrollo y aplicación de técnicas no lineales para el análisis de sistemas complejos, esperando así poder caracterizar de manera adecuada las series temporales relacionadas al estudio y análisis del clima en la superficie terrestre (Kalamaras, Philippopoulos, Deligiorgi, Tzanis, & Karvounis, 2017).

Hay que considerar que en la actualidad las inferencias sobre el calentamiento global se basan principalmente en el primer momento de las variables meteorológicas. Los momentos de orden superior apenas han sido explorados; las conclusiones sobre el cambio climático podrían ser reforzadas si los momentos de cualquier orden fueran ligados a la escala de tiempo estudiada. La teoría multifractal es la herramienta indicada para la conceptualización de los posibles cambios de los momentos de las variables en consideración con el tiempo.

1.4 Objetivos

1.4.1 Objetivo general

Determinar y analizar el espectro de singularidades correspondiente a las variables meteorológicas de los vientos de Santa Ana en la cuenca hidrográfica de Guadalupe para explicar la ocurrencia, caracterización y fluctuaciones de las mismas.

1.4.2 *Objetivos específicos*

- Determinar el exponente de Hurst generalizado (diferentes momentos), funciones de escalado y la dimensión de información de las series de temperatura, humedad relativa, velocidad del viento, presión atmosférica y dirección del viento para los días en que ocurren los vientos de Santa Ana para evaluar la persistencia y estacionariedad en los distintos momentos.
- Analizar si las series de temperatura, humedad relativa, velocidad del viento, presión atmosférica y dirección del viento, siguen una ley en potencia para comprobar su multifractalidad.
- Correlacionar las singularidades encontradas en las variables en consideración para identificar subcuencas meteorológicamente homogéneas.
- Determinar y espacializar los parámetros multifractales ancho, exponente de Holder y la asimetría de las series en estudio para establecer si existen correlaciones con las variables fisiográficas de la cuenca.
- Construir la matriz de correlación con los parámetros multifractales y las características fisiográficas de la cuenca con el fin de determinar la influencia de esta en el comportamiento de los vientos de Santa Ana.
- Proponer una red con enfoque de aprendizaje profundo para predecir y detectar condiciones de Santa Ana en la cuenca de Guadalupe.

1.5 Hipótesis

La teoría multifractal se puede utilizar para describir el comportamiento y la estructura matemática de las series de temperatura, humedad relativa, presión atmosférica, velocidad del viento y dirección del viento en la cuenca hidrográfica de Guadalupe.

2 Área de estudio y descripción de los vientos de Santa Ana

El área de estudio corresponde a la cuenca hidrográfica del valle de Guadalupe, localizada en el norte del estado de Baja California, entre latitudes 31°50'N, 32°16'N y longitudes 116°54' W, 115°52' W. Es una zona semiárida de clima mediterráneo, con una temperatura media anual de aproximadamente 16°C y una precipitación media anual de aproximadamente 254,6 mm. Tiene un área de 2390 km² dividida en tres subcuencas: Ojos Negros ubicada aguas arriba, Valle de Guadalupe en la parte central, y la subcuenca La Misión aguas abajo que desemboca en el Océano Pacífico (Figura 1) (A. A. López Lambraño et al., 2020).

Se implementaron los polígonos de Thiessen para estimar las estaciones climatológicas que tuvieron influencia dentro de la cuenca. Se encontraron 8 estaciones dentro del área de la cuenca y 8 entre los perímetros y límites de la cuenca para un total de 16 estaciones.




Figura 1. Localización del área de estudio.

La figura 2 muestra la estructura de la metodología implementada para el análisis propuesto.



Figura 2. Metodología utilizada.

Se utilizaron dos bases de datos, el Extractor Rápido de Información Climatológica (ERIC) en su versión web (SIG ERIC versión 1.0). Este cuenta con información de estaciones de la base de datos CLICOM y de la Red Climática de Referencia Nacional. Esta base de datos solo proporciona información sobre temperatura máxima, mínima y observada, precipitación, evaporación, tormenta eléctrica, granizo y niebla. Los datos se complementaron con el servicio web Modern-Era Retrospective Analysis for Research and Applications, Versión 2 (MERRA-2), que ofrece series temporales de temperatura, humedad relativa, presión, velocidad y dirección del viento, precipitación, nevadas y profundidad de nieve y la irradiación horizontal global. El período de análisis fue entre 1980 y 2018.

En la

Tabla 1 se muestra una lista de las estaciones implementadas en el análisis y algunas de las variables de interés climático como son: la temperatura máxima, mínima y media anual, humedad relativa, presión atmosférica, radiación solar, velocidad y dirección del viento media anual para cada estación. Análisis realizados con los registros diarios de 1980 a 2018.

Tabla 1. Estaciones climatológicas en el área de estudio y sus características de interés.

Código	Nombre	Latitud	Longitud	Altitud m.s.n.m.	P Total Anual (mm)	T Media Anual (°C)	T Máx Anual (°C)	T Mín Anual (°C)	HR Media Anual (%)	RS Media Anual (Wh/m2)	Presión Media Anual (hPa)	VV Media Anual (m/s)	DV Media Anual (°)
2001	Agua Caliente	32.107	-116.454	400	276.63	18.06	49	-7	49.52	6016.03	933.33	2.71	225.82
2004	Ignacio Zaragoza Belén	32.195	-116.486	540	336.93	16.44	52.3	-12.03	49.88	6008.12	937.56	2.78	225.14
2005	Boquilla Santa Rosa de la Misión	32.002	-116.777	250	265.8	15.45	42	-6.93	59.30	5941.70	975.30	2.64	245.81
2021	El Pinal	32.183	-116.292	1320	518.31	12.3	45	-2.67	44.76	6052.19	915.34	2.93	217.82
2025	Ensenada (Obs)	31.858	-116.606	21	251.53	17.12	39	0	56.79	5983.26	961.21	2.70	243.83
2035	Ojos Negros	31.912	-116.265	680	233.25	16.19	53	-17	45.89	6065.29	914.74	2.71	220.02
2036	Olivares Mexicanos	32.049	-116.681	340	302.32	16.62	47	-10.59	56.30	5963.98	962.17	2.62	239.41
2049	San Juan de Dios Norte	32.132	-116.165	1280	392.8	12.92	49	-16	41.93	6071.98	916.50	2.80	217.46
2066	Sierra de Juárez	32.004	-115.948	1580	391.2	10.68	43.14	-19	37.94	6104.63	928.51	2.54	218.17
2077	La Misión	32.102	-116.811	20	289.74	16.99	41	-2	59.68	5934.15	977.24	2.64	242.61
2079	El Alamar	31.836	-116.204	710	265.94	17.83	44	-3	45.33	6079.08	920.93	2.71	220.82
2094	El Farito	31.983	-116.667	250	253.42	16.16	33.7	1	56.54	5967.35	962.06	2.62	242.23
2114	Ejido Carmen Serdán	32.244	-116.584	560	288.46	15.4	56.35	-8	52.23	5985.77	948.28	2.76	226.98
2118	Valle San Rafael	31.919	-116.234	721	321.79	16.75	49.9	-7	44.99	6070.72	913.11	2.71	218.83
2122	Real del Castillo Viejo	31.951	-116.746	610	280.57	15.64	46.1	-8	59.44	5948.72	974.05	2.67	247.89
2164	Ejido El Porvenir	32.106	-115.852	330	276.44	17.36	45	-6.9	35.80	6109.20	942.29	2.55	225.81

A continuación, profundizaremos en cómo se definieron los criterios para determinar la ocurrencia o no de un día con viento de Santa Ana a partir de la revisión bibliográfica que se realizó sobre este fenómeno.

Los criterios utilizados para definir los vientos de Santa Ana dependen tanto del impacto de interés (por ejemplo, incendios forestales catastróficos) como de la ubicación y / o la hora del día examinada (Rolinski, Capps, & Zhuang, 2019).

(Rolinski et al., 2019) propuso una clasificación de las series de tiempo de vientos Santa Ana, basados en el gran potencial de fuego LFP_W y los gradientes medios de presión al nivel del mar, donde los criterios eran los siguientes: $LFP_W \geq 6$ y $W_S \geq 4.5$ m/s(10mph); luego se aplicaron los SOM (Self-Organizing Maps) para verificar que la serie temporal solo contuviera días legítimos de vientos Santa Ana; con los SOM se verificaron los patrones climáticos más frecuentes de las zonas.

Como indica (Raphael, 2003), se recogieron algunos criterios implementados en el pasado como la humedad relativa, velocidad del viento y dirección del viento para definir el viento de Santa Ana. Si la velocidad del viento promedio durante cuatro intervalos durante el día fue mayor o igual a 20 mph, la dirección del viento era del cuadrante noreste, y la humedad relativa a 1630 PST (hora estándar del Pacífico) era inferior al 40%, se consideró ser un evento de Santa Ana. (Edinger, Helvey, & Baumhefner, 1964) estudiaron siete años de base de datos del sur de California y la ocurrencia de un evento de Santa Ana venia asociada con una caída de presión de 3mb, incremento de la temperatura de 9°C, vientos del norte con velocidades mayores a 30mph y humedad relativa del 30% o menos.

(Raphael, 2003) analizó una serie de 33 años sobre mapas meteorológicos, con criterios de alta presión sobre la Gran Cuenca y de baja presión frente a la costa del sur de California, dirección del viento predominante desde el cuadrante noroeste.

(Jones, Fujioka, & Carvalho, 2010) estudió 28 años de valores del índice climático del fuego (Fire Wind Index), del cual los vientos secos era una componente. Los criterios para

considerar un día como un evento de vientos Santa Ana fue el siguiente: 1) La Gran Cuenca o el 30% de La Gran Cuenca debía tener gradientes positivos en la presión a nivel del mar. 2) las costas del sur de California tuvieran anomalías negativas en la presión a nivel del mar. 3) Vientos sobre la cuenca de Los Ángeles fueran del cuadrante noreste.

Para (Zamora, Lambert, & Montero, 2014) los vientos de Santa Ana están asociados a un cambio en la humedad relativa con caídas de menos del 10%, dirección en el cuadrante noreste correspondiente a 0° a 90° y velocidades más grandes o iguales a 20mph (8.9411 m/s).

(Navarro-Olache et al., 2021) utilizó criterios de humedad relativa inferior al 45% y velocidad del viento mayor o igual a 7 m/s, siguiendo los propuestos por (Guzman-Morales, Gershunov, Theiss, Li, & Cayan, 2016). Álvarez y Carbajal (Álvarez & Carbajal, 2019), en los valores observados en Ensenada, registraron datos de una velocidad mínima del viento de 1.08 m/s y máxima de 17.91 m/s, temperaturas entre 11.9 y 31.8 °C, y presión sobre el nivel del mar entre 1008.43 y 1017.93mb.

(Dye, Kim, & Riley, 2020) clasificó los vientos de Santa Ana asociados a un incendio con velocidades de 5.19m/s y dirección del viento de 38.51° ; y los vientos de Santa Ana sin incendios con velocidades de 3.96m/s y dirección del viento de 33.54° .

Se ideó un filtro para determinar en qué días ocurrió un evento Santa Ana y en qué días no. Para la selección del criterio se revisaron los conceptos anteriormente expuestos y los de (Álvarez & Carbajal, 2019; Cao, 2015; Castro, 2003; Navarro-Olache et al., 2021; Raphael, 2003; Schwarz et al., 2020; Trasviña, Ortiz-Figueroa, Herrera, Cosío, & González, 2003).

El criterio para evaluar la ocurrencia de un evento en Santa Ana asociado a la velocidad del viento se estableció en 4.5 m/s que es el valor en el cual los restos de fuego de un incendio podrían acelerar su propagación en el aire (Rolinski et al., 2019) . En consecuencia, los días

considerados con vientos de Santa Ana están vinculados a incendios; para la dirección del viento el criterio se estableció en vientos del primer cuadrante (Jones et al., 2010; Raphael, 2003; Zamora et al., 2014). Los días que cumplen con las dos condiciones anteriores se consideran días en los que ocurrió un evento de Santa Ana, los días que no cumplen con estos criterios se consideran días en los que no ocurrió un viento de Santa Ana.

3 Análisis fractal de vientos de Santa Ana (días con viento de Santa Ana y días sin vientos de Santa Ana)

Los vientos de Santa Ana son un fenómeno meteorológico que afecta el suroeste de Estados Unidos y noroeste de México, principalmente durante el otoño y el invierno (Álvarez & Carbajal, 2019). El viento de Santa Ana es un viento cálido, seco, tipo Föhn, del este o del noreste, que sopla desde el desierto este de la Sierra Nevada hasta la costa del sur de California (Glickman & American Meteorological Society, 2000). Llevan el nombre del cruce y valle del río de Santa Ana, California, tienden a ocurrir en invierno y primavera y pueden afectar gran parte de la región del sur de California (Schwarz et al., 2020).

La climatología de los vientos de Santa Ana ha sido estudiada principalmente a partir de información a escala sinóptica; sin embargo, se han aplicado otros enfoques que permiten el análisis diario de los vientos Santa Ana a partir de campos de presión (Raphael, 2003), y también mediante valores diarios del Índice Meteorológico de Incendios (Fire Weather Index) (Jones et al., 2010). (Abatzoglou, Barbero, & Nauslar, 2013) desarrollan la reconstrucción diaria empírica más larga hasta el momento, desde 1948 hasta 2012, basada en una reanálisis global de los campos de convección de presión y temperatura.

El modelado a mesoescala (MSM) también se ha utilizado en el estudio de los vientos de Santa Ana, generalmente para estudiar la estructura de estos a partir de una pequeña muestra de un solo evento y conjuntos de datos dinámicamente reducidos (Conil & Hall, 2006; Guzman-Morales et al., 2016; Hughes & Hall, 2010). Los vientos de Santa Ana generalmente ocurren entre los meses de septiembre y abril, pero las probabilidades de ocurrencia son mayores entre los meses de octubre a diciembre. Las altas velocidades del viento (de hasta 30mph), las direcciones del viento del noreste y la baja humedad relativa junto con un fuerte gradiente de presión entre la Gran Cuenca y la costa de California son indicadores meteorológicos de los vientos de Santa Ana (Abatzoglou et al., 2013; Billmire, French, Loboda, Owen, & Tyner, 2014; Conil & Hall, 2006; Dye et al., 2020; Jones et al., 2010; Raphael, 2003; Rolinski et al., 2016). Suelen formarse en invierno, pero los eventos más peligrosos suelen ocurrir en otoño antes que comiencen las lluvias invernales, coincidiendo en este tiempo que la vegetación tiende a ser extremadamente seca por lo cual existe un elevado peligro de incendios debido a la condición de humedad muy baja y los fuertes vientos que pueden provocar y propagar las llamas, despertando gran interés en la investigación de la dinámica del fuego en el sur de California (Cao, 2015; Cao & Fovell, 2016; Rolinski et al., 2016).

En el noroeste de México, el impacto de los vientos de Santa Ana, viene despertando interés, sin embargo, las investigaciones son pocas. En los últimos años, (Navarro-Olache et al., 2021) analizaron la influencia de los vientos de Santa Ana en la circulación superficial en la bahía de Todos los Santos. De manera similar (Álvarez & Carbajal, 2019) estudiaron el comportamiento de las variables meteorológicas y las tormentas de arena en el noroeste de México durante la ocurrencia de los vientos de Santa Ana, a partir de la simulación de un evento extremo en octubre de 2007. Otras investigaciones realizadas en esta zona corresponden a la ascensión del filamento debido a los vientos (Trasviña et al., 2003), al análisis de la evolución y extensión de los vientos

de Santa Ana para un evento ocurrido en febrero de 2002 utilizando el satélite QuickScat (Castro, 2003), la determinación del potencial eólico que generan estos vientos en la costa de Baja California (Zamora et al., 2014) y la evaluación del efecto de los vientos en las propiedades bio-ópticas (Sosa-ávalos, Durazo, & Mitchell, 2005).

Al estudiar variables climáticas, las técnicas no lineales como los fractales y multifractales, permiten analizar la ocurrencia de patrones y su interpretación a partir del análisis de la estructura de las series de tiempo (López-Lambrano, Fuentes, López-Ramos, Mata-Ramírez, & López-Lambrano, 2018; Millán, Kalauzi, Cukic, & Biondi, 2010). Debido a lo anterior, la predictibilidad de los fenómenos climáticos como la Oscilación del Atlántico Norte (North Atlantic Oscillation), El Fenómeno del Niño (El Niño Southern Oscillation) y la Oscilación Decadal del Pacífico (Pacific Decadal Oscillation) ha sido estudiada empleando los fractales y multifractales a partir de la estimación del exponente de Hurst a distintos ordenes, lo que ha permitido encontrar que el NAO presenta baja predictibilidad y una estrecha correlación con la oscilación cuasi bienal (Quasi Biennial Oscillation) (Caldeira, Fernández, & Pacheco, 2007; Maruyama, Kai, & Morimoto, 2017). Por otra parte, (Diodato, de Guenni, Garcia, & Bellocchi, 2019) validaron un modelo de predicción del Índice de Severidad de la Sequía de Palmer en función de la ENSO y PDO empleando la estimación del exponente de Hurst.

En este estudio, se optó por trabajar con análisis fractal en lugar de métodos que involucran probabilidad, dado que los sistemas dinámicos exhiben autosimilitud y fluctuaciones espacio-temporales en su comportamiento en todas las escalas, lo que indica correlación en un amplio rango (López-Lambrano et al., 2018). Los vientos de Santa Ana son un fenómeno que se presentan con una escala particular de tiempo, lo que hace que el análisis fractal sea adecuado para interpretar

las correlaciones entre las variables que se involucran en el estudio del fenómeno y también analizar la invarianza de escala a diferentes resoluciones temporales.

Los vientos de Santa Ana son un fenómeno que involucra relaciones entre variables complejas y procesos no lineales, esta complejidad del clima debe ser explorada más a fondo utilizando métodos emergentes de la ciencia de sistemas complejos para mejorar nuestra comprensión y ayudar a desarrollar y evaluar modelos climáticos más confiables (da Silva, Silva, & Stosic, 2020). Finalmente, con el presente trabajo se estudiará el comportamiento y correlación de las variables meteorológicas asociadas a los vientos de Santa Ana utilizando el exponente de Hurst y la dimensión fractal, además de la predictibilidad y dependencia entre dichas variables, empleando el Índice de Previsibilidad Climática.

3.1 Geometría fractal

Mandelbrot en 1968 definió un fractal como un conjunto para el cual su dimensión de Hausdorff es mayor a su dimensión topológica. Así mismo definió la dimensión fractal como un valor no entero, que permite describir la geometría fractal, así como la heterogeneidad de figuras irregulares; permitiendo capturar la información perdida al utilizar representaciones de geometría tradicional. La dimensión fractal se relaciona con el exponente de Hurst, mediante la siguiente ecuación desarrollada por Voss en 1985 (López, Carrillo, Fuentes, López, & López, 2017):

	$2H + 1 = 5 - 2D$	(1)
--	-------------------	-----

Despejando la ecuación anterior se obtiene una relación directa entre la dimensión fractal (D) y el exponente de Hurst (H), por lo tanto:

	$D = 2 - H$	(2)
--	-------------	-----

Donde D es la dimensión fractal y H es el exponente de Hurst.

A continuación, se presenta una descripción de uno de los métodos más usado para el análisis fractal de series de tiempo de variables climáticas.

3.1.1 Rango reescalado

El método de Rango reescalado fue propuesto por el hidrólogo inglés Harold Edwin Hurst 1951. Hurst dedicó sus investigaciones al estudio de la hidrología del río Nilo, en particular estaba interesado en los cambios anuales en el nivel del agua para adaptar la capacidad de almacenamiento de la presa de acuerdo con el entorno natural. Hurst observó que las inundaciones podrían caracterizarse como persistentes, es decir, las inundaciones más intensas iban acompañadas de inundaciones por encima del promedio, mientras que las inundaciones por debajo del promedio fueron seguidas por inundaciones menores. En el proceso de este hallazgo, desarrolló el análisis de rango reescalado (R/S) (Harrouni & Guessoum, 2009).

Debido a su simplicidad, el análisis de rango reescalado ha sido ampliamente utilizado para analizar las propiedades escalares y estadísticas y el comportamiento antipersistente, persistente y aleatorio del tiempo, series de precipitación, temperatura, etc. El método consta de los siguientes pasos (López et al., 2017)

1. Se inicia con una serie de tamaño M . Se define el perfil de entrada, este se obtiene de la diferencia entre los registros de dos puntos consecutivos:

$$M'_i = M_i - M_{i+1} \quad (3)$$

Donde M_i es el registro para el tiempo i .

2. Se obtiene el promedio de diferencias para el ancho de ventana seleccionado como:

$$\langle M' \rangle_w = \frac{1}{w} \sum_{i=1}^w I'_i \quad (4)$$

3. Se resta el promedio de las diferencias obtenidas en el paso anterior al perfil de entrada.

Definida como:

$$X(i, w) = \sum_{u=1}^i [M'_u - \langle M' \rangle_w] \quad (5)$$

4. Finalmente, el rango R y la desviación estándar S están dadas por:

(6)

$$R(w) = \max_{1 \leq i \leq w} X(i, w) - \min_{1 \leq i \leq w} X(i, w)$$

$$S(w) = \left\{ \frac{1}{w} \sum_{i=1}^w [M'_i - \langle M' \rangle_w]^2 \right\}^{1/2} \quad (7)$$

Donde:

$R(w)$, es el rango tomado por los valores de X en el intervalo w . El rango se mide con respecto a una tendencia en la ventana w , donde la tendencia se estima simplemente como la línea que conecta el primer y el último punto dentro de la ventana. Esto sustrae la tendencia promedio en la ventana.

$S(w)$, es la desviación estándar de las primeras diferencias de M'_i dentro de un ancho de ventana. Las primeras diferencias de M'_i como anteriormente se mencionó, son definidas como las diferencias entre un valor y el valor consecutivo.

De donde se obtiene, para cada valor de longitud de ventana w , un valor de R/S que obedece a una ley de potencia.

$$R/S(w) = w^H \quad (8)$$

Donde H es el exponente de Hurst. Este proceso se repite para varias longitudes de ventana, y los logaritmos de $R/S(w)$ se trazan vs los logaritmos de w . Si la traza es auto-afín, esta gráfica debe seguir una línea recta cuya pendiente es igual al exponente de Hurst

H . El valor del exponente de Hurst toma valores de 0 a 1 ($0 < H < 1$) y permite medir la persistencia de una serie de tiempo. Por lo tanto:

- Las caminatas aleatorias gaussianas, o, en general, los procesos independientes, tienen un $H = 0.5$.
- Si $0.5 < H < 1$, se indica dependencia positiva, y la serie se llama persistente.
- Si $0 < H < 0.5$, se indica dependencia negativa, produciendo anti-persistencia.

La dimensión fractal se puede calcular mediante la siguiente ecuación que relaciona el exponente de Hurst H y la dimensión fractal D :

$$D = 2 - H \quad (9)$$

Si la dimensión fractal D toma el valor de 1.5, obtenemos el movimiento Browniano. En este caso no hay correlación entre los cambios de amplitud correspondientes a dos intervalos de tiempo sucesivos. Por lo tanto, no se puede distinguir una tendencia en la amplitud de las series de tiempo y, por lo tanto, el proceso es impredecible. Sin embargo, a medida que la dimensión fractal disminuye a 1.0, el proceso se vuelve más y más predecible a medida que exhibe persistencia, es decir, la tendencia futura o pasada es cada vez más probable que siga una tendencia. A medida que la dimensión fractal aumenta de 1.5 a 2.0, el proceso exhibe anti-persistencia, es decir, una disminución en la amplitud del proceso es más probable que conduzca a un aumento en el futuro o en el pasado. Por lo tanto, la previsibilidad aumenta nuevamente (S. Rehman & Siddiqi, 2009).

3.1.2 *Índice de previsibilidad climática*

Basado en la teoría del exponente de Hurst y la dimensión fractal, el índice de previsibilidad climática IP_C tiene como objetivo encontrar la relación entre parámetros meteorológicos. Se ha aplicado para estudiar la dinámica climática en India (Rangarajan & Sant, 1997) y Arabia Saudita (Shafiqur Rehman, 2009). Este método es útil para cambiar el énfasis de las dimensiones fractales a la previsibilidad.

Los índices de previsibilidad de presión (IP_P), temperatura (IP_T), precipitación (IP_{PRE}), humedad relativa (IP_{HR}) y velocidad del viento (IP_{VV}) se definen de la siguiente manera:

$$IP_P = |D_P - 1.5| \quad (10)$$

$$IP_T = |D_T - 1.5| \quad (11)$$

$$IP_{prec} = |D_{prec} - 1.5| \quad (12)$$

$$IP_{HR} = |D_{HR} - 1.5| \quad (13)$$

$$IP_{VV} = |D_{VV} - 1.5| \quad (14)$$

Donde D_P , D_T , D_{Pre} , D_{HR} y D_{VV} son la dimensión fractal de las series de tiempo de presión, temperatura, precipitación, humedad relativa y velocidad viento respectivamente.

Aquí $|D|$ denota el valor absoluto del numero D . Esto debido a que la previsibilidad puede aumentar en los siguientes casos: cuando la dimensión fractal es menor que 1.5 y cuando esta es más grande que 1.5. En el primer caso hay correlación positiva o persistencia y en el segundo caso un comportamiento de anti-correlación o antipersistencia. Sin embargo, en ambos casos el proceso es muy predecible. Al usar el valor absoluto, aseguramos que un proceso con $D=1.3$ tiene el mismo índice de previsibilidad que un proceso con una dimensión fractal $D=1.7$.

El índice de previsibilidad climática para la precipitación, la humedad relativa y la velocidad del viento en términos de los índices de previsibilidad de la presión y la temperatura son definidos como se muestra a continuación (Li, Xia, & Meng, 2012):

$$IP_{CPre} = (IP_P, IP_T, IP_{Pre}) \quad (15)$$

$$IP_{CHR} = (IP_P, IP_T, IP_{HR}) \quad (16)$$

$$IP_{CVV} = (IP_P, IP_T, IP_{VV}) \quad (17)$$

Si uno de los índices esta cercano a cero, el proceso se aproxima a un movimiento browniano y por tal es impredecible. Si este se encuentra cercano a 1, el proceso es muy predecible.

Es útil tener los tres representados en un solo índice. Entonces es más fácil ver cómo cambian los tres subíndices en relación entre sí a medida que cambian las estaciones. Además, al introducir índices de previsibilidad en lugar de dimensiones fractales, se enfoca en cuán predecible es el proceso.

Un factor importante que no se ha incluido explícitamente en la composición del IP_C son los parámetros geográficos de la ubicación; sin embargo, en muchos casos es posible que uno de los índices anteriores ya incluya implícitamente el efecto de los parámetros geográficos. En tales casos, los parámetros geográficos pueden ser útiles para explicar por qué uno de los índices adquiere el valor que tiene. Un caso particular es el encontrado para la temporada junio-septiembre (monzón del sureste) en las estaciones ubicadas en la región noroeste de la India, donde también se encuentran los límites de hundimiento de la célula monzónica suroeste. Por tanto, la precipitación es impredecible incluso cuando la temperatura y la presión son predecibles (Rangarajan & Sant, 1997).

3.2 Metodología

Se calculó el exponente de Hurst y la dimensión fractal para las series de tiempo de temperatura, humedad relativa, presión, velocidad del viento y precipitación para días donde se presentó el evento Santa Ana y en los que no hubo Vientos de Santa Ana, utilizando el programa Benoit v1.31, siguiendo las ecuaciones descritas de la (3)-(9).

Se calculan los índices de previsibilidad de las variables mediante de las ecuaciones presentadas en la sección Rango reescalado, la ecuación (10) para la presión, temperatura (11), precipitación (12), humedad relativa (13) y velocidad del viento (14); a partir de estos se obtuvo el índice de previsibilidad climática para la precipitación, humedad relativa y velocidad del viento, ecuaciones (15)-(17) respectivamente; siendo de interés de estudio los dos primeros al estar relacionados con los vientos de Santa Ana.

Se generaron los mapas de distribución espacial mediante la técnica de interpolación de ponderación de distancia inversa (IDW) utilizando el software ArcGIS para los exponentes de

Hurst, dimensión fractal e índices de previsibilidad para la temperatura, presión, humedad relativa, velocidad del viento y precipitación.

3.3 Fractalidad de los Vientos de Santa Ana

3.3.1 *Análisis fractal*

En la Tabla 2 se muestran las estaciones meteorológicas utilizadas en los diferentes análisis realizados. También se reportan los valores estimados del exponente de Hurst para las variables de presión (P), temperatura (T), precipitación (PRE), humedad relativa (HR) y velocidad del viento (VV) a partir de las series de tiempo obtenidas con las bases de datos utilizadas.

Tabla 2. Exponente de Hurst para las estaciones de la cuenca hidrográfica del valle de Guadalupe para las variables de presión, temperatura (T), precipitación, humedad relativa (HR) y velocidad del viento (VV).

Código	Estaciones	SERIE COMPLETA				
	Nombre	Presión	T	Precipitación	HR	VV
2035	Ojos Negros	0.77	0.93	0.73	0.81	0.66
2066	Sierra de Juárez	0.80	0.96	0.69	0.85	0.68
2079	El Alamar	0.78	0.93	0.73	0.81	0.66
2118	Valle San Rafael	0.77	0.94	0.72	0.82	0.66
2164	Ejido El Porvenir	0.82	0.96	0.68	0.86	0.68
2001	Agua Caliente	0.79	0.93	0.74	0.81	0.65
2004	Ignacio Zaragoza Belén	0.80	0.93	0.74	0.81	0.64
2005	Boquilla Santa Rosa de la Misión	0.83	0.91	0.76	0.75	0.65
2021	El Pinal	0.77	0.94	0.72	0.83	0.64
2025	Ensenada (Obs)	0.82	0.92	0.76	0.77	0.66
2036	Olivares Mexicanos	0.82	0.92	0.76	0.77	0.65
2049	San Juan de Dios Norte	0.78	0.95	0.70	0.83	0.65
2094	El Farito	0.82	0.92	0.75	0.77	0.65
2122	Real del Castillo Viejo	0.83	0.90	0.76	0.75	0.65
2077	La Misión	0.83	0.91	0.76	0.74	0.65
2114	Ejido Carmen Serdán	0.81	0.93	0.75	0.80	0.64

Los valores del exponente de Hurst (Tabla 2) se estimaron a partir de las series registradas y sin clasificar los días en los que hubo ocurrencia o no ocurrencia de los vientos de Santa Ana. El objetivo fue identificar las características fractales de las variables de estudio consideradas y realizar una comparación con los resultados reportados en otras investigaciones.

Exponente de Hurst

Los resultados del exponente de Hurst de la serie de precipitación muestran que la variable tiene un comportamiento persistente al tener valores del exponente de Hurst mayores que 0.5. Estos resultados coinciden con los reportados por (López-Lambrano et al., 2018) en el área de estudio. Estos resultados también son similares a los informados en otros lugares, como Israel (0.7) (Broday, 2010), Australia (0.6) (Korvin, Boyd, & O'Dowd, 1990) y Arabia Saudita (0.59-0.71) (Shafiqur Rehman, 2009). Otros trabajos realizados en climas subtropicales y semiáridos reportan valores inferiores a 0.5, a pesar de tener condiciones similares a la región en estudio (A. López Lambrano, 2012; Peñate, Martín-González, Rodríguez, & Cianca, 2013; Velásquez Valle et al., 2013).

En cuanto a la temperatura, los valores obtenidos por (Mianabadi & Faridhosseini, 2011) en Mashad, Irán de 0.6 son similares a los obtenidos (0.85-0.96), ya que también son persistentes. De manera similar, para la isla de Creta en Grecia, el valor del exponente de temperatura generalizado de Hurst fue 0.65 (Kalamaras et al., 2017) . Sin embargo, en comparación con (Shafiqur Rehman, 2009), los valores del exponente de Hurst para la temperatura en Arabia Saudita son antipersistentes. En cuanto a la velocidad del viento y la humedad relativa para Rehman (2009), los valores promedio reportados fueron 0.64 y 0.61, respectivamente, similares a los encontrados en la región estudiada. Para la comparación del exponente de Hurst de presión, Rehman (2009)

encontró que, en Arabia Saudita, el exponente de Hurst tomó valores anti-persistentes de 0.2, mientras que los obtenidos en esta investigación son persistentes. Esto podría deberse a que el clima de la cuenca responde a las influencias de presión generada a gran escala en la región y no a fenómenos locales.

El clima de la cuenca de Guadalupe es generalmente persistente durante todo el año. En algunas variables el grado de persistencia es mayor que en otras, pero en general se puede definir que tiene características de memoria a largo plazo al analizar la estructura temporal de las series de precipitación, temperatura, presión, humedad relativa y velocidad del viento. Sin embargo, al desglosar las series para verificar la ocurrencia del fenómeno de los vientos de Santa Ana, se observa que, durante los días en que este evento no ocurre, mantienen el mismo comportamiento que la serie original. Lo anterior confirma que los cambios en los valores del exponente de Hurst de algunas variables para los días con vientos de Santa Ana están ligados a la sensibilidad de dichas variables a este fenómeno.

En la Tabla 3 se muestra un resumen que contiene el número de días que componen la serie temporal establecida como días con vientos de Santa Ana, así como los criterios establecidos para identificar dicha condición en cada una de las estaciones analizadas, incluyendo: velocidad del viento ≥ 4.5 m/s y dirección del viento entre 0° y 90° . En primera instancia también se evaluó el criterio de humedad relativa $\leq 10\%$, pero este criterio no se cumplió en los días en que se habían presentado vientos de Santa Ana. La humedad relativa en esos días no alcanzó el límite anterior, por lo que los criterios se redujeron únicamente a la velocidad y dirección del viento. Otras investigaciones también han descartado este parámetro (Álvarez & Carbajal, 2019; Zamora et al., 2014).

Tabla 3. Criterios para seleccionar días con vientos de Santa Ana.

Estaciones					Días con Viento Santa Ana		
Código	Nombre	Latitud	Longitud	Altitud	Criterio de VV ^a	Criterio de DV ^b	VV y DV ^c
2035	Ojos Negros	31.91	-116.26	680	1644	2859	463
2066	Sierra de Juárez	32.00	-115.95	1580	1673	2905	163
2079	El Alamar	31.84	-116.20	710	1675	2863	460
2118	Valle San Rafael	31.92	-116.23	721	1661	2889	447
2164	Ejido El Porvenir	32.11	-115.85	330	1778	2479	83
2001	Agua Caliente	32.11	-116.46	400	1535	2622	364
2004	Ignacio Zaragoza Belén	32.20	-116.49	540	1659	2578	360
2005	Boquilla Santa Rosa de la Misión	32.02	-116.78	250	1290	1992	349
2021	El Pinal	32.18	-116.29	1320	2175	2774	342
2025	Ensenada (Obs)	31.86	-116.61	21	1412	2134	332
2036	Olivares Mexicanos	32.05	-116.68	340	1296	2215	361
2049	San Juan de Dios Norte	32.13	-116.15	1280	1998	2818	266
2094	El Farito	31.98	-116.67	250	1288	2154	351
2122	Real del Castillo Viejo	31.95	-116.75	610	1346	1952	325
2077	La Misión	32.10	-116.81	20	1285	2052	370
2114	Ejido Carmen Serdán	32.24	-116.58	560	1580	2494	372

^a Donde VV es la velocidad del viento ≥ 4.5 m/s. ^b DV es la dirección del viento entre 0° y 90°, ^c es el cruce de los dos criterios (velocidad y dirección del viento).

A partir de las series de tiempo resultantes de los criterios establecidos anteriormente, se calcularon los exponentes de Hurst y las dimensiones fractales para los días con vientos de Santa Ana y los días sin vientos de Santa Ana (Tabla 4). En esta tabla, T representa la temperatura, P es la presión, PRE es la precipitación, HR es la humedad relativa, VV es la velocidad del viento y DV es la dirección del viento.

Tabla 4. Exponente de Hurst para las variables meteorológicas en estudio en los días con vientos de Santa Ana y días sin vientos de Santa Ana.

Estaciones		Días con Vientos de Santa Ana						Días sin Vientos de Santa Ana					
Código	Nombre	P	T	PRE ¹	HR	VV	DV	P	T	PRE	HR	VV	DV
2035	Ojos Negros	0.64	0.53	0.66	0.72	0.43	0.50	0.75	0.93	0.73	0.83	0.66	0.70
2066	Sierra de Juárez	0.48	0.59	*	0.60	0.63	0.18	0.79	0.95	0.69	0.85	0.68	0.65
2079	El Alamar	0.61	0.51	0.50	0.72	0.40	0.53	0.76	0.93	0.72	0.82	0.67	0.70

Código	Estaciones Nombre	Días con Vientos de Santa Ana						Días sin Vientos de Santa Ana					
		P	T	PRE ¹	HR	VV	DV	P	T	PRE	HR	VV	DV
2118	Valle San Rafael	0.63	0.50	0.65	0.71	0.40	0.50	0.75	0.93	0.72	0.83	0.66	0.70
2164	Ejido El Porvenir	0.36	0.49	*	0.60	0.63	0.32	0.82	0.96	0.68	0.86	0.68	0.62
2001	Agua Caliente	0.65	0.45	*	0.81	0.45	0.41	0.73	0.92	0.75	0.87	0.68	0.72
2004	Ignacio Zaragoza Belén	0.66	0.44	0.87	0.78	0.48	0.49	0.78	0.93	0.75	0.82	0.65	0.72
2005	Boquilla Santa Rosa de la Misión	0.65	0.49	0.77	0.74	0.50	0.46	0.82	0.90	0.77	0.75	0.65	0.72
2021	El Pinal	0.54	0.42	0.62	0.78	0.44	0.41	0.76	0.93	0.72	0.83	0.66	0.71
2025	Ensenada (Obs)	0.63	0.52	0.95	0.77	0.54	0.40	0.81	0.91	0.76	0.78	0.65	0.72
2036	Olivares Mexicanos	0.68	0.47	*	0.79	0.49	0.46	0.81	0.91	0.76	0.78	0.65	0.72
2049	San Juan de Dios Norte	0.57	0.44	*	0.72	0.45	0.33	0.77	0.94	0.70	0.83	0.66	0.71
2094	El Farito	0.62	0.49	0.90	0.75	0.49	0.45	0.81	0.91	0.76	0.77	0.65	0.72
2122	Real del Castillo Viejo	0.63	0.53	0.31	0.77	0.55	0.44	0.81	0.91	0.76	0.76	0.66	0.72
2077	La Misión	0.68	0.53	0.23	0.75	0.47	0.47	0.82	0.90	0.76	0.75	0.65	0.72
2114	Ejido Carmen Serdán	0.64	0.43	0.73	0.74	0.46	0.41	0.79	0.91	0.75	0.80	0.64	0.72

¹,* Datos que no se pudieron estimar porque la serie de tiempo formada no contaba con los datos mínimos para aplicar la técnica de rango reescalado. Ecuaciones (3)-(8).

Para la serie de datos de días con vientos de Santa Ana, el exponente de presión de Hurst fue mayor a 0.5 en la mayoría de las estaciones, excepto Sierra De Juárez y Ejido El Porvenir, donde fue de 0.48 y 0.36, respectivamente, lo que significa anti-persistencia e indica que estas áreas pueden verse afectadas por microclimas locales. El comportamiento de la presión en general es de persistencia débil, en comparación con la persistencia fuerte del exponente de Hurst en los días en que no hay vientos de Santa Ana. Para la temperatura, el valor de Hurst osciló entre 0.43 y 0.59. En la estación Valle de San Rafael el valor del exponente de Hurst fue de 0.5, mientras que en las estaciones Ejido Porvenir, Boquilla, Santa Rosa de La Misión y El Farito el valor estimado del exponente de Hurst fue de 0.49. Este comportamiento también se encontró en las estaciones Agua Caliente, El Pinal, Olivares Mexicanos, San Juan De Dios Norte y Ejido Carmen Serdán. Generalmente para la temperatura se puede notar un cambio en el valor del exponente de Hurst

entre una condición y otra, es decir, en los días sin vientos de Santa Ana es muy persistente, pero cuando ocurre este fenómeno la temperatura se vuelve antipersistente en muchas zonas. Esto podría ser consecuencia de grandes fluctuaciones de temperatura en estas épocas del año, llegando a ser aleatorias en determinados lugares, como ya se ha comentado.

En cuanto a los datos de precipitación registrados en los días con vientos de Santa Ana, no se pudo estimar el exponente de Hurst para todas las estaciones meteorológicas porque no había datos suficientes para utilizar el análisis de rango reescalado. En los casos en los que fue posible estimar valores del exponente de Hurst para la precipitación, los análisis arrojaron valores superiores a 0.5, manteniendo características persistentes. Sin embargo, en las estaciones Real del Castillo Viejo y La Misión los valores obtenidos fueron de 0.31 y 0.23, respectivamente. Para la estación Alamar se determinó el comportamiento aleatorio para los días con vientos de Santa Ana.

Para la serie de tiempo de la variable humedad relativa, los resultados arrojaron valores del exponente de Hurst superiores a 0.5 en todas las estaciones meteorológicas analizadas. Estas condiciones de persistencia se mantienen cuando los vientos de Santa Ana ocurren o no.

En el caso de la serie de velocidad del viento, los valores del exponente de Hurst denotan una tendencia de la variable a tener un comportamiento antipersistente debido a que los valores son menores a 0.5. Sin embargo, en las estaciones Sierra de Juárez y Ejido El Porvenir se estimaron valores de 0.63, y para las estaciones Ensenada y Real del Castillo Viejo se estimaron valores de 0.54 y 0.55, respectivamente. Con base en estos resultados, se podría decir que la velocidad del viento y la temperatura están reguladas por los vientos de la Gran Cuenca y los gradientes de presión generados durante esta época, a diferencia de la presión y la humedad relativa, independientemente de su ocurrencia. La condición de los vientos de Santa Ana conserva incluso en menor grado la persistencia de la serie. La humedad relativa no refleja los cambios en el valor

del exponente de Hurst que se esperarían para la época de Santa Ana, es decir, los valores del exponente de Hurst no se mantuvieron en el mismo rango, sino que se convirtieron en valores antipersistentes o aleatorios. en dicha estación, al igual que ocurre con otras variables como la velocidad del viento y la temperatura, donde el comportamiento del exponente de Hurst no es igual para las dos condiciones de análisis.

Esta situación puede deberse a lo mencionado anteriormente sobre los registros, los cuales, en la mayoría de las estaciones, no presentaban valores de humedad relativa $\leq 10\%$, como lo sugiere el criterio de clasificación. En algunas estaciones donde se encontró que se cumplían los criterios antes mencionados, no coincidieron con los meses de la temporada de Santa Ana, sino con la época en la que no se esperaba que se presentara este tipo de viento. Además, muchos de estos criterios se basan en análisis realizados en Estados Unidos, y el fenómeno, cuando llega a la región de Baja California, no ingresa con la misma intensidad y varía según las características topográficas de la zona. Esto se evidenció en las matrices de correlación y mapas de espacialización de variables, donde no toda la cuenca tiene el mismo comportamiento para las variables analizadas, como se examinará detalladamente en la Sección 3.3.2.3 Geospacialización.

Además, el exponente de Hurst de la dirección del viento se estimó, determinando valores inferiores a 0.5 para la mayoría de las estaciones. Sólo en El Alamar el valor de Hurst fue de 0.53. Condiciones aleatorias se presentaron en las estaciones Ojos Negros y Valle de San Rafael. En la estación Sierra de Juárez la antipersistencia fue más fuerte que en las demás estaciones, con un valor de 0.18. Estos resultados fueron para la condición de días con vientos de Santa Ana, mientras que, para los días sin vientos de Santa Ana, la dirección del viento fue persistente.

Esto se debe a que cuando hay vientos de Santa Ana el clima se altera. A medida que disminuye la humedad relativa, aumenta la velocidad del viento. La dirección de estos vientos es

sólo del primer cuadrante, y las temperaturas pueden o no bajar. Esta invariancia en la escala de las series temporales se ve afectada por un fenómeno regional denominado vientos de Santa Ana, ya que al segmentar el vector completo en dos estaciones se observan cambios, como se evidencia en los análisis anteriores. En los valores de Hurst de los días en los que no hay vientos de Santa Ana, se observa que la ocurrencia de presión, temperatura, precipitación, humedad relativa, velocidad del viento e incluso dirección del viento está influenciada por muchos factores climáticos regionales y/o sistemas de gran escala, por ejemplo, (Tatli, 2015) determinó altos valores de persistencia del exponente de Hurst, por lo que se afirmó que muchos sistemas climáticos regionales y/o de gran escala influyeron en la aparición de sequías en Turquía. Si algunos sistemas atmosféricos de pequeña escala fueran eficaces en la formación de sequías, entonces se deberían obtener al menos algunos valores de $H < 0.5$, resultado que no ocurrió.

Para los exponentes de Hurst en días con vientos de Santa Ana, se observa que este fenómeno regional modifica la dinámica climática de la cuenca, alterando las variables involucradas en la misma con diferentes intensidades.

3.3.2 *Índice de previsibilidad*

En la Tabla 5 se muestran los valores obtenidos para los índices de previsibilidad de presión, temperatura, precipitación, humedad relativa, velocidad y dirección del viento para los días con y sin viento de Santa Ana.

Tabla 5. Índices de previsibilidad de presión, temperatura, precipitación, humedad relativa, velocidad y dirección del viento para días con y sin viento de Santa Ana.

Estaciones		Días con vientos de Santa Ana						Días sin vientos de Santa Ana					
Código	Nombre	IP _P	IP _T	IP _{PRE} ²	IP _{HR}	IP _{VV}	IP _{DV}	IP _P	IP _T	IP _{PRE}	IP _{HR}	IP _{VV}	IP _{DV}
2035	Ojos Negros	0.27	0.06	0.31	0.43	0.15	0.00	0.50	0.85	0.45	0.65	0.33	0.40
2066	Sierra de Juárez	0.04	0.18	*	0.19	0.26	0.65	0.59	0.90	0.38	0.69	0.35	0.30

Estaciones		Días con vientos de Santa Ana						Días sin vientos de Santa Ana					
Código	Nombre	IP _P	IP _T	IP _{PRE} ²	IP _{HR}	IP _{VV}	IP _{DV}	IP _P	IP _T	IP _{PRE}	IP _{HR}	IP _{VV}	IP _{DV}
2079	El Alamar	0.22	0.02	0.00	0.43	0.20	0.05	0.53	0.85	0.45	0.65	0.34	0.41
2118	Valle San Rafael	0.25	0.00	0.30	0.42	0.20	0.00	0.50	0.86	0.44	0.65	0.32	0.40
2164	Ejido El Porvenir	0.29	0.03	*	0.19	0.26	0.35	0.64	0.93	0.36	0.71	0.35	0.23
2001	Agua Caliente Ignacio	0.30	0.11	*	0.61	0.10	0.18	0.47	0.84	0.50	0.73	0.35	0.44
2004	Zaragoza Belén	0.32	0.13	0.74	0.56	0.04	0.03	0.56	0.85	0.49	0.64	0.30	0.45
2005	Boquilla Santa Rosa de la Misión	0.31	0.02	0.54	0.47	0.01	0.09	0.64	0.80	0.53	0.50	0.29	0.44
2021	El Pinal	0.07	0.17	0.24	0.55	0.13	0.19	0.51	0.86	0.44	0.65	0.31	0.43
2025	Ensenada (Obs)	0.25	0.04	0.90	0.53	0.08	0.19	0.62	0.82	0.51	0.55	0.31	0.44
2036	Olivares Mexicanos	0.36	0.07	*	0.58	0.02	0.09	0.62	0.81	0.52	0.55	0.30	0.44
2049	San Juan de Dios Norte	0.14	0.11	*	0.44	0.09	0.33	0.54	0.87	0.40	0.67	0.32	0.42
2094	El Farito	0.25	0.01	0.80	0.50	0.01	0.11	0.62	0.82	0.51	0.55	0.30	0.43
2122	Real del Castillo Viejo	0.25	0.06	0.38	0.54	0.09	0.12	0.62	0.81	0.52	0.53	0.32	0.43
2077	La Misión	0.36	0.05	0.53	0.49	0.06	0.06	0.64	0.80	0.53	0.49	0.29	0.44
2114	Ejido Carmen Serdán	0.29	0.15	0.46	0.47	0.09	0.19	0.59	0.83	0.50	0.60	0.29	0.45

²,* Datos que no se pudieron estimar porque la serie de tiempo formada no contaba con los datos mínimos para aplicar la técnica de rango reescalado y determinar la dimensión fractal y el índice de previsibilidad. Ecuaciones (9)–(17).

Si uno de los índices de la tabla anterior está cerca de cero, el proceso se acerca a un movimiento browniano y, por tanto, es impredecible. Si es cercano a 1, el proceso es muy predecible.

En cuanto a los índices de previsibilidad en general, cuando hay vientos de Santa Ana, las variables de presión, temperatura, velocidad y dirección del viento se vuelven impredecibles, mientras que, cuando no hay vientos de Santa Ana, son predecibles. La humedad relativa también se vuelve menos predecible, como se evidencia en la Tabla 5, volviéndose impredecible en ciertas

estaciones, como Sierra Juárez y Ejido el Porvenir. Adicionalmente, se observa que, para el índice de previsibilidad de precipitación en las estaciones Ignacio Zaragoza Belén, Boquilla Santa Rosa de La Misión, Ensenada, El Farito y La Misión, tienen valores mayores a 0.5, es decir, su previsibilidad se acerca más a 1, lo que significa que son bastante predecibles, a diferencia de las estaciones Ojos Negros, El Alamar, Valle de San Rafael, El Pinal, Real del Castillo Viejo y Ejido Carmen Serdán, donde el índice tiene valores más cercanos a 0, lo que significa que la variable precipitación es impredecible.

3.3.2.1 Índice de previsibilidad climática

Para los índices de previsibilidad climática de precipitación, humedad relativa y velocidad del viento, se realizó un análisis para evaluar cómo la temperatura y la presión impactaban las variables antes mencionadas. La Tabla 6 muestra la interacción entre estas variables cuando ocurre un evento de Santa Ana y la Tabla 7 para días sin vientos de Santa Ana. El * indica estaciones donde no se pudo estimar el exponente de Hurst, la dimensión fractal y, por tanto, los índices de previsibilidad climática de la precipitación porque las series de precipitación no contaban con los datos mínimos necesarios para poder realizar los análisis.

Tabla 6. Índice de previsibilidad climática para días con vientos de Santa Ana y correlación entre parámetros meteorológicos.

Estaciones		Días con Viento Santa Ana			Impacto Temperatura y Presión		
Código	Nombre	IP _{CPRE} = (IP _P , IP _T , IP _{PRE})	IP _{CHR} = (IP _P , IP _T , IP _{HR})	IP _{CVV} = (IP _P , IP _T , IP _{VV})	IP _{CPRE}	IP _{HR}	IP _{VV}
2035	Ojos Negros	(0.270,0.058,0.314)	(0.270,0.058,0.432)	(0.270,0.058,0.002)	2	X	2
2066	Sierra de Juárez	(0.042,0.184, *)	(0.042,0.184,0.194)	(0.042,0.184,0.648)	*	2	2
2079	El Alamar	(0.222,0.018,0.000)	(0.222,0.018,0.434)	(0.222,0.018,0.052)	2	X	2
2118	Valle San Rafael	(0.254,0.004,0.296)	(0.254,0.004,0.418)	(0.254,0.004,0.000)	2	X	2
2164	Ejido El Porvenir	(0.290 ,0.028, *)	(0.290,0.028,0.192)	(0.290,0.028,0.352)	*	2	2

Estaciones		Días con Viento Santa Ana			Impacto Temperatura y Presión		
Código	Nombre	IP _{CPRE} = (IP _P , IP _T , IP _{PRE})	IP _{CHR} = (IP _P , IP _T , IP _{HR})	IP _{CVV} = (IP _P , IP _T , IP _{VV})	IP _{CPRE}	IP _{HR}	IP _{VV}
2001	Agua Caliente	(0.302,0.108, *)	(0.302,0.108,0.610)	(0.302,0.108,0.180)	*	X	②
2004	Ignacio Zaragoza Belén	(0.318,0.130,0.740)	(0.318,0.130,0.558)	(0.318,0.130,0.030)	X	X	②
2005	Boquilla Santa Rosa de la Misión	(0.308,0.024,0.538)	(0.308,0.024,0.472)	(0.308,0.024,0.086)	X	X	②
2021	El Pinal	(0.072,0.170,0.238)	(0.072,0.170,0.552)	(0.072,0.170,0.188)	②	X	②
2025	Ensenada (Obs)	(0.252,0.038,0.896)	(0.252,0.038,0.532)	(0.252,0.038,0.194)	X	X	②
2036	Olivares Mexicanos	(0.356,0.070, *)	(0.356,0.070,0.582)	(0.356,0.070,0.086)	*	X	②
2049	San Juan de Dios Norte	(0.144,0.112, *)	(0.144,0.112,0.436)	(0.144,0.112,0.334)	*	X	②
2094	El Farito	(0.248,0.014,0.796)	(0.248,0.014,0.498)	(0.248,0.014,0.106)	X	X	②
2122	Real del Castillo Viejo	(0.254,0.060,0.382)	(0.254,0.060,0.544)	(0.254,0.060,0.116)	②	X	②
2077	La Misión	(0.364,0.052,0.532)	(0.364,0.052,0.494)	(0.364,0.052,0.056)	X	X	②
2114	Ejido Carmen Serdán	(0.286,0.150,0.456)	(0.286,0.150,0.474)	(0.286,0.150,0.190)	X	X	②

X representa que los parámetros meteorológicos no se ven afectados por la temperatura y la presión. Esto indica previsibilidad independiente. ② representa que los parámetros meteorológicos fueron influenciados por la temperatura y la presión, con la misma previsibilidad. *Datos que no se pudieron estimar porque la serie de tiempo formada no contaba con los datos mínimos para aplicar la técnica de rango reescalado y determinar la dimensión fractal y el índice de previsibilidad. Ecuaciones (9)-(17)

Para el análisis de los días con vientos de Santa Ana y sin vientos de Santa Ana se establece el valor de 0.4 como el límite o el valor donde la serie comienza a considerarse predecible, tal como propone (Li et al., 2012). Se observó que la temperatura y presión controla o impacta el parámetro de humedad relativa en las estaciones Sierra de Juárez y Ejido el Porvenir, es decir, el índice de previsibilidad de presión y el índice de previsibilidad de temperatura afectan o varían en la misma medida, pero no son predecibles. Esto sucede cuando hay días de Santa Ana. Lo contrario sucede con los días donde no hay evento de Santa Ana, donde la humedad relativa es muy predecible en la mayoría de las estaciones y el índice de previsibilidad de la humedad relativa está controlado por el índice de previsibilidad de temperatura y presión. Es decir, la relación entre temperatura, presión y humedad relativa sólo se mantiene en las dos estaciones ya mencionadas para los dos casos presentados.

Tabla 7. Índice de previsibilidad climática para días sin vientos de Santa Ana y correlación entre parámetros meteorológicos.

Estaciones		Días sin Viento Santa Ana			Impacto Temperatura y Presión		
Código	Nombre	IP _{CPRE} = (IP _P , IP _T , IP _{PRE})	IP _{CHR} = (IP _P , IP _T , IP _{HR})	IP _{CVV} = (IP _P , IP _T , IP _{VV})	IP _{CPRE}	IP _{CHR}	IP _{CVV}
2035	Ojos Negros	(0.504,0.852,0.454)	(0.504,0.852,0.650)	(0.504,0.852,0.328)	2	2	X
2066	Sierra de Juárez	(0.588,0.904,0.380)	(0.588,0.904,0.692)	(0.588,0.904,0.350)	X	2	X
2079	El Alamar	(0.528,0.852,0.448)	(0.528,0.852,0.646)	(0.528,0.852,0.336)	2	2	X
2118	Valle San Rafael	(0.502,0.856,0.444)	(0.502,0.856,0.654)	(0.502,0.856,0.318)	2	2	X
2164	Ejido El Porvenir	(0.636,0.926,0.360)	(0.636,0.926,0.710)	(0.636,0.926,0.350)	X	2	X
2001	Agua Caliente	(0.466,0.836,0.496)	(0.466,0.836,0.732)	(0.466,0.836,0.352)	2	2	X
2004	Ignacio Zaragoza Belén	(0.562,0.854,0.492)	(0.562,0.854,0.644)	(0.562,0.854,0.304)	2	2	X
2005	Boquilla Santa Rosa de la Misión	(0.644,0.802,0.532)	(0.644,0.802,0.500)	(0.644,0.802,0.294)	2	2	X
2021	El Pinal	(0.512,0.858,0.436)	(0.512,0.858,0.650)	(0.512,0.858,0.312)	2	2	X
2025	Ensenada (Obs)	(0.620,0.820,0.510)	(0.620,0.820,0.550)	(0.620,0.820,0.306)	2	2	X
2036	Olivares Mexicanos	(0.618,0.814,0.520)	(0.618,0.814,0.552)	(0.618,0.814,0.300)	2	2	X
2049	San Juan de Dios Norte	(0.536,0.874,0.398)	(0.536,0.874,0.666)	(0.536,0.874,0.318)	X	2	X
2094	El Farito	(0.620,0.816,0.512)	(0.620,0.816,0.548)	(0.620,0.816,0.304)	2	2	X
2122	Real del Castillo Viejo	(0.624,0.810,0.520)	(0.624,0.810,0.528)	(0.624,0.810,0.316)	2	2	X
2077	La Misión	(0.644,0.798,0.526)	(0.644,0.798,0.490)	(0.644,0.798,0.292)	2	2	X
2114	Ejido Carmen Serdán	(0.588,0.826,0.500)	(0.588,0.826,0.596)	(0.588,0.826,0.288)	2	2	X

X representa que los parámetros meteorológicos no se ven afectados por la temperatura y la presión. Indica previsibilidad independiente. 2 representa que los parámetros meteorológicos fueron influenciados por la temperatura y la presión, con igual previsibilidad.

La velocidad del viento es impredecible, ya sea en la temporada de Santa Ana o fuera de ella. Sin embargo, para la temporada de Santa Ana, tanto la presión, la temperatura como la velocidad del viento se vuelven impredecibles y exhiben una aparente correlación. Esta es una observación lógica ya que estas variables son características del fenómeno de Santa Ana. Lo contrario sucede en el período sin Santa Ana, donde los índices de previsibilidad de presión y temperatura son muy predecibles pero el índice de previsibilidad de la velocidad del viento no lo es, por lo que no están estrechamente relacionados, lo que refleja que la velocidad es una variable independiente de las demás en condiciones donde no esté asociado a un fenómeno climático.

En el caso de la lluvia, a pesar de no ser una variable relevante asociada al fenómeno de Santa Ana, en los días sin vientos de Santa Ana muestra relación con la temperatura y la presión, ya que los tres valores son predecibles. Para los días con vientos de Santa Ana, esta relación solo se mantiene en cinco de las estaciones evaluadas.

El análisis anterior se complementó con una matriz de correlación desarrollada para los índices de previsibilidad de las variables en estudio en condiciones de ocurrencia y no ocurrencia de días con vientos de Santa Ana, como se muestra en la Figura 3, en la que se verificaron algunas de las relaciones que se encontraron en el análisis fractal. El análisis se complementó con la espacialización de los índices de previsibilidad de las variables analizadas, que se discutirá en detalle en la siguiente subsección.

3.3.2.2 Índice de previsibilidad de la matriz de correlación

Se generaron dos matrices de correlación para los dos casos de estudio, donde los colores claros corresponden a correlaciones positivas y los colores oscuros a correlaciones negativas. Se utilizó el método de Pearson porque permite cuantificar la relación lineal entre series de tiempo estacionarias, como las estudiadas (Jonah et al., 2021; Zhao, Shang, & Huang, 2017), lo que se observa en las correlaciones obtenidas para los dos escenarios.




Figura 3. Matriz de correlación de índices de previsibilidad para la serie de tiempo compuesta por días con vientos de Santa Ana.

Los rangos utilizados para medir el grado de correlación se muestran en la Tabla 8; clasificación de la correlación de acuerdo con el valor obtenido de r (Ratner, 2009):

Tabla 8. Rangos del coeficiente de correlación

Rango		Tipo de Correlación
± 0.00	$\rightarrow \pm 0.09$	Nula
± 0.10	$\rightarrow \pm 0.19$	Muy débil
± 0.20	$\rightarrow \pm 0.49$	Débil
± 0.50	$\rightarrow \pm 0.69$	Moderada
± 0.70	$\rightarrow \pm 0.84$	Significativa
± 0.85	$\rightarrow \pm 0.95$	Fuerte
± 0.96	$\rightarrow \pm 1.00$	Perfecta

En la matriz de correlación anterior, la altitud muestra una correlación negativa significativa con IP_P e IP_{HR} para los días con vientos de Santa Ana, mientras que con IP_T y IP_{VV} la

correlación es positiva pero moderada. En cuanto a la correlación de IP_P , con respecto al IP_{PRE} es débil, y con el IP_T es nulo, confirmando la relación que muestra el IP_{CPRE} como se muestra en la Figura 3. Caso similar ocurre para la humedad relativa, reflejando lo mostrado por el IP_{CHR} , dejando abierta la posibilidad de que las estaciones meteorológicas donde existe una relación entre los índices de previsibilidad de humedad relativa, temperatura y presión; y entre precipitación, temperatura y presión, dependa de otros factores tales como la ubicación geográfica de la estación y altitud. Para el IP_{VV} , la relación es moderada y negativa con respecto a IP_P , mientras que con el IP_T , hay una correlación muy débil.

En la Figura 4 se observa que la altitud para los días sin viento de Santa muestra una correlación débil con IP_P y moderada con IP_{PRE} pero negativa, mientras que con el IP_T y IP_{HR} es moderada pero positiva. Entre el IP_P y el IP_{PRE} exhiben una relación débil pero positiva mientras que entre el IP_{PRE} y el IP_T es perfecta pero negativa. El IP_{HR} y el IP_T tienen una relación significativa y positiva, mientras que con el IP_P es negativa y moderada. El IP_{VV} tiene una correlación negativa y débil con el IP_P ; mientras que con el IP_T es positiva y significativa.




Figura 4. Matriz de correlación de índices de previsibilidad para la serie de tiempo compuesta por días sin vientos de Santa Ana.

3.3.2.3 Geoespacialización

A continuación, se muestran los mapas obtenidos de la espacialización del exponente de Hurst y el índice de previsibilidad para las variables de temperatura, presión, humedad relativa y velocidad del viento para las condiciones con vientos de Santa Ana y en ausencia de vientos de Santa Ana.

Para complementar los análisis a partir de la geo-espacialización de los exponentes de Hurst de las variables climáticas en estudio, se realizó un análisis de correlación para las dos condiciones analizadas, es decir, para las series que representan la temporada de vientos de Santa Ana (Figura 5) y para la serie que no involucran esta condición (Figura 6). En estas matrices, al referirnos a presión, nos referimos a los valores del exponente de Hurst de la presión; lo mismo

ocurre con la temperatura, la humedad relativa (Hum. Relativa), la precipitación y Vel. Viento es el exponente de Hurst de la velocidad del viento.

En la Figura 7 se muestran mapas del exponente de Hurst para la serie de tiempo compuesta por días con vientos de Santa Ana. En dicha figura se observa que la variable temperatura presenta los valores más bajos y tiende a tener un comportamiento antipersistente en toda la cuenca. La estación El Pinal se ubica en una de las zonas más elevadas (msnm) de la cuenca y en ella se presentan valores bajos; a diferencia de la estación Sierra Juárez que es el punto más alto (msnm) de la cuenca, pero los exponentes de Hurst estimados en esta estación son de valores más altos. A partir de la matriz de correlación de la Figura 5, se determina que la altitud no tiene correlación con los valores del exponente de Hurst para la serie de temperatura. Para la presión, los valores más altos del exponente de Hurst se presentan en la parte baja de la cuenca, existe una correlación inversa entre altitud y longitud. Esto explicaría por qué en el análisis las estaciones Sierra Juárez y Ejido Porvenir presentan los valores más bajos de la cuenca. En el caso de la humedad relativa ocurre lo contrario que con la variable de la presión: los valores más bajos se encuentran en la estación Sierra de Juárez siendo ésta el lugar de mayor altitud de la cuenca. Los valores de Hurst más altos para dicha variable se encuentran en zonas de baja altitud y en la subcuenca del Valle de Guadalupe.




Figura 5. Matriz de correlación para exponentes de Hurst para las series de tiempo compuesta por días con vientos de Santa Ana.




Figura 6. Matriz de correlación para exponentes de Hurst para las series de tiempo conformadas por días sin vientos de Santa Ana.




Figura 7. Mapas del exponente de Hurst para las series de tiempo conformadas por días con vientos de Santa Ana y para las variables de: (a) temperatura, (b) presión, (c) humedad relativa y (d) velocidad del viento.

Para la velocidad del viento, la estación Sierra de Juárez es la que presenta el exponente de Hurst de mayor valor; sin embargo, las estaciones El Pinal y San Juan de Dios Norte presentan

valores de Hurst bajos, a pesar de estar ubicadas en la zona alta de la cuenca. Por tanto, se puede afirmar que no existe una relación clara entre la velocidad del viento y la altitud.

En la Figura 8 se presentan mapas del exponente de Hurst para la serie de tiempo compuesta por días sin vientos de Santa Ana. Como se muestra en la matriz de la Figura 6, la temperatura tiene una relación positiva con la altitud. En la zona más alta, donde se ubica la estación Sierra de Juárez, se muestran los valores más altos del exponente de Hurst; asimismo, los valores más bajos de dicho exponente se encuentran en la zona más baja de la cuenca, correspondiente a la subcuenca de la Misión. La serie de temperaturas es persistente, con valores altos cercanos a 1. Los análisis de la matriz de correlación de la Figura 6 también muestran que la temperatura tiene una correlación significativa con la variable humedad relativa. En el caso de los valores exponentes de presión, los valores más altos se presentan en las partes bajas de la cuenca o en altitudes más bajas (msnm), es decir, existe una correlación débil e inversa entre estos parámetros; de igual forma mantiene esta relación con la longitud. Para la humedad relativa la relación es positiva con respecto a la altitud, es decir, los valores más altos corresponden a las zonas más altas de la cuenca. Esta relación es la misma para la humedad relativa con la longitud. En el caso de la velocidad del viento, la correlación con la altitud es débil y positiva, mientras que la relación con la longitud es positiva y significativa, lo que puede explicar los altos valores en la parte oriental de la cuenca.




Figura 8. Mapas del exponente de Hurst para las series de tiempo conformadas con días sin vientos de Santa Ana y para las variables de: (a) temperatura, (b) presión, (c) humedad relativa y (d) velocidad del viento.

De lo anterior podemos afirmar que los vientos de Santa Ana modifican las relaciones entre las variables y las características geográficas de las estaciones, es decir, durante los días normales

del año, la presión tiene una relación inversa con la longitud y la altitud, pero con la longitud aumenta cuando hay vientos de Santa Ana. Para la humedad relativa, se encuentra que la relación se vuelve inversa durante la temporada de Santa Ana; en el caso de la temperatura y la velocidad del viento los grados de relación que existían en la época sin vientos de Santa Ana disminuyeron hasta ser nulos o muy débiles; lo cual es evidente ya que estas variables son las que reflejan mayores cambios cuando hay una época u otra.

De la Figura 9, para la temperatura, se observa que existe una relación positiva y moderada con respecto a la altitud. Se observa que los valores más altos corresponden a las estaciones Sierra Juárez, El Pinal y San Juan de Dios Norte. Para los valores de los índices de previsibilidad de presión existe una correlación inversa con la altitud, y los valores más bajos se encuentran en las estaciones mencionadas anteriormente. En cuanto al índice de previsibilidad de la humedad relativa, la relación con la altitud también es inversa pero débil; el mapa se visualiza que los valores más altos se encuentran en la cuenca media, correspondiente a la subcuenca del Valle de Guadalupe; mientras tanto, la relación entre la longitud y el índice de previsibilidad de la humedad relativa también es inversa pero significativa. Los valores más altos del exponente de Hurst al analizar la serie de velocidad del viento se presentan en las estaciones de Sierra Juárez y Ejido el Porvenir. La relación entre la velocidad del viento y la altitud es generalmente moderada y positiva, al igual que con la longitud, siendo esta una relación más significativa. Así, al revisar las correlaciones de presión y temperatura con respecto a la humedad relativa, de la matriz de correlación (Figura 3) y del análisis de previsibilidad (Tabla 6), se encuentra que la relación es nula con la temperatura y débil con la presión en las estaciones en las que se presenta la influencia de dichas variables, debido a sus parámetros de ubicación geográfica. Mientras tanto, para la

velocidad del viento, la relación con la temperatura es débil y positiva. En el caso de la presión, es negativa y moderada.




Figura 9. Mapas del índice de previsibilidad para días con vientos de Santa Ana para las variables de (a) temperatura, (b) presión, (c) humedad relativa y (d) velocidad del viento.

De las Figura 4, Figura 10 y Tabla 7, la temperatura muestra una relación positiva con la altitud, donde los valores más altos del índice de previsibilidad se encuentran en las zonas donde se ubican las estaciones Sierra de Juárez y Ejido el Porvenir. Cabe señalar que la estación Ejido el Porvenir se ubica a menor elevación que la estación Sierra de Juárez; sin embargo, presentan valores similares para el índice de previsibilidad. Esto puede deberse a la alta correlación entre la longitud y temperatura. Para la presión existe una relación débil e inversa con la altitud, evidenciada en que los valores más altos del índice de predictibilidad de presión se encuentran en las estaciones La Misión, Boquilla de Santa Rosa de La Misión y Ejido el Porvenir. Los valores más bajos del índice de previsibilidad de presión se encuentran en las partes altas de la cuenca, como en la estación El Pinal. De la matriz de correlación (Figura 3), se puede observar que, para la humedad relativa, la relación es moderada con respecto a la altitud, y positiva, como se observa en la Figura 9, donde los rangos más bajos corresponden a la parte baja de la cuenca y los rangos más altos están en la parte más alta de la cuenca. Para la velocidad del viento, la relación con la altitud es positiva pero débil, aunque la previsibilidad es menor en la Misión y mayor en la Sierra de Juárez. Agua Caliente, es una estación de altura intermedia y tiene una previsibilidad igual a la de Sierra de Juárez.




Figura 10. Mapas del índice de previsibilidad para días sin vientos de Santa Ana para las variables de: (a) temperatura, (b) presión, (c) humedad relativa y (d) velocidad del viento.

3.4 Conclusiones

A partir del análisis fractal mediante el cálculo del exponente de Hurst y los índices de previsibilidad climática, se establecieron las siguientes conclusiones:

El método de rango reescalado fue adecuado para evaluar la fractalidad de las series de tiempo que representan las condiciones de ocurrencia de los vientos de Santa Ana y para las series que representan los días en que no se produce dicho fenómeno. A partir de la estimación del exponente de Hurst se pudo caracterizar las series de tiempo de las variables de temperatura, precipitación, presión, humedad relativa y velocidad del viento en términos de las características de persistencia, anti persistencia o aleatoriedad.

Cuando existen fenómenos que alteran el clima de una zona como el caso de los vientos de Santa Ana, la interacción y el comportamiento de las variables climáticas en su entorno se pueden modificar con respecto a las condiciones que normalmente se registran u ocurren, por ejemplo al realizar el análisis fractal de una variable en específico podemos tener características predecibles y comportamientos persistentes; sin embargo, esto puede cambiar al realizar el mismo análisis en periodos de ocurrencia de eventos Santa Ana, como es el caso de la velocidad del viento que en épocas de Santa Ana exhibe un comportamiento antipersistente en la mayoría de estaciones pero persistente y predecible fuera de los meses donde no hay eventos Santa Ana.

Esto también ocurre para la temperatura, o en casos más puntuales como en las estaciones Ejido el Porvenir y Sierra de Juárez, donde la presión pasa de ser persistente en días normales a ser antipersistente para días con vientos de Santa Ana; o la previsibilidad de la velocidad del viento en Sierra Juárez y Ejido el Porvenir donde el comportamiento del viento es impredecible e independiente de la época, exista o no un evento de viento de Santa Ana. Esto nos lleva a concluir

que el índice se puede utilizar como discriminante para determinar qué estaciones pueden seleccionarse para su uso en el desarrollo de modelos climáticos regionales.

El análisis de las matrices de correlación nos permite entender las relaciones de la dinámica del clima en una zona y como pueden cambiar estas correlaciones frente a diferentes temporadas por ejemplo la relación entre el índice de previsibilidad de la humedad relativa y la velocidad se mantiene independiente del análisis de segmentación (exista o no exista condición Santa Ana) pero la humedad relativa y la altitud pasan de una relación positiva en condiciones normales a una relación inversa en días con vientos de Santa Ana.

Se recomienda continuar con estudios en los que se pueda involucrar el criterio de humedades relativas $<10\%$ para la identificación de la condición de vientos de Santa Ana.

Finalmente, este tipo de estudios contribuyen a comprender la dinámica regional de la cuenca Guadalupe y establecer unas bases para el desarrollo de modelos que permitan pronosticar los días de ocurrencia de los vientos de Santa Ana en dicha cuenca con el fin de mitigar las consecuencias negativas que pueden generarse, por ejemplo, incendios y sequías.

4 Aplicación de redes neuronales recurrentes para la predicción de condiciones de vientos de Santa Ana

4.1 Introducción

Los vientos de Santa Ana son un componente integral del clima y el régimen de incendios del sur de California y el norte de Baja California debido a su capacidad para propagar grandes incendios forestales (Dye et al., 2020). Estos generan pérdidas de miles de millones de pesos en daños a la propiedad, lesiones respiratorias por inhalación de humo y enormes gastos de manejo de incendios debido a la proximidad de los centros de población a las áreas silvestres quemables. Saber cuándo y dónde ocurren las condiciones de Santa Ana es importante para el manejo y prevención de incendios forestales en Baja California (Nguyen, Crawl, Li, Uys, & Altintas, 2018). Estos han sido estudiados ampliamente de manera tradicional y especialmente en la zona de California donde cuentan con un índice de amenaza de incendios; se busca crear un modelo que permita estimar la ocurrencia de estos en la Cuenca hidrográfica del Valle de Guadalupe. La predicción de la ocurrencia de vientos de Santa Ana, se realiza en su mayoría a partir de modelos de mesoescala como North American Mesoscale (NAM), Rapid Update Cycle (RUC), The Weather Research and Forecasting, etc; pero estos tienen sus limitaciones tales como el tiempo de información para los pronósticos. Los Santa Ana han sido analizados con aprendizaje no supervisado utilizando el algoritmo *k-means* para el área de San Diego, California. Además, hay antecedentes de estudios de fenómenos de variabilidad climática como el fenómeno del niño mediante redes neuronales (Jiménez-Carrión, Gutiérrez-Segura, & Celi-Pinzón, 2018) y de variables meteorológicas como la precipitación (Chhetri, Kumar, Roy, & Kim, 2020) y la evotranspiración (Deo & Şahin, 2015).

En los últimos años, los modelos híbridos o la combinación de varios modelos para predecir variables han ido en crecimiento debido a la ventaja de reducir los errores en los pronósticos.

(Yang et al., 2023) encontró que el modelo EEMD-LSTM (Ensemble Empirical Mode Decomposition - Long Short-Term Memory) supera al modelo LSTM independiente en términos de precisión predictiva, eliminando efectivamente el ruido de las señales y proporcionando una referencia valiosa en cuanto fue evaluado en la predicción de los cambios en el nivel del mar en el norte del Mar de China Meridional.

Para predecir las temperaturas en Alemania, se compararon desempeños de modelos SARIMA, red LSTM univariada, una red LSTM multivariada y una red convolucional combinada con LSTM; mostrando que el enfoque presentado basado en una red LSTM convolucional funciona mejor en todos los conjuntos de datos de prueba que fueron utilizados (Kreuzer, Munz, & Schlüter, 2020).

A continuación, se presenta una aproximación por predecir las condiciones de Santa Ana en la cuenca de Guadalupe mediante aprendizaje supervisado implementado redes neuronales recurrentes de tipo LSTM para la base de datos del MERRA-2.

4.2 LSTM para el pronóstico de condiciones de vientos de Santa Ana

El factor principal que subyace al éxito de un algoritmo de aprendizaje automático es encontrar características relevantes y el modelo apropiado. Por lo tanto, hoy en día, las redes neuronales son una solución poderosa en muchas aplicaciones cuando los modelos de aprendizaje automático convencionales alcanzan sus límites (Kreuzer et al., 2020). Las redes LSTM (Long Short Term Memory) son adecuadas para aplicar en el pronóstico de series de tiempo, debido a que guardan esa información temporal de los datos en el tiempo.

LSTM es una versión de la red neuronal recurrente (Recurrent Neural Network) que se utiliza para procesar datos de secuencias y problemas de series temporales. Fue propuesta por Hochreiter y Schmidhuber en 1997, se volvió popular rápidamente después de que la RNN solucionara el problema del desvanecimiento o descenso del gradiente. La red LSTM se creó para abordar el problema que tienen las RNN tradicionales al lidiar con las dependencias a largo plazo. Cuando una RNN típica procesa secuencias largas, el gradiente desaparece o explota progresivamente, lo que dificulta la captura de dependencias a larga distancia. La LSTM aborda este problema agregando un mecanismo de compuerta. Como se muestra en la Figura 11, incluye principalmente una unidad de memoria, una compuerta de olvido (f_t), una compuerta de entrada (i_t) y una compuerta de salida (o_t). La puerta de entrada determina cuánta información nueva se agrega al estado de la unidad, la puerta de olvido controla si se olvidará en cada momento y la puerta de salida determina si hay salida de información en cada momento (Shi et al., 2024).




Figura 11. Diagrama de la estructura de una red LSTM (Shi et al., 2024)

4.3 Metodología

Se implemento la base de datos MERRA-2 de la NASA para tener los valores diarios de las variables de temperatura, presión, humedad relativa, velocidad del viento y dirección del viento de la estación Agua Caliente. Esta base es de acceso público, solo basta con digitar las coordenadas del punto que se quiere localizar y seleccionar desde que año se desean los datos. El MERRA-2 tiene datos disponibles desde enero de 1980 y se actualizan periódicamente con un retraso aproximado de un mes, para el análisis se abarco el periodo de 1980 a 2020. El enlace para acceder a la página es el siguiente: <http://www.soda-pro.com/web-services/meteo-data/merra>. A estos datos se les calculó su estadística descriptiva.

A los datos se realizó un preprocesamiento. El archivo que se descarga de la base de datos del MERRA-2 está conformado por la fecha, datos de temperatura, humedad relativa, presión, velocidad del viento, dirección del viento, nevada, profundidad de la nevada y radiación de onda corta. Las variables que no son necesarias para el análisis son eliminadas del archivo, además de la información de geolocalización y las unidades de medidas.

Se generaron las gráficas de las variables en estudio, se calcularon algunos estadísticos de prueba y se comprobó la estacionalidad de la serie. Ver Figura 12 y Figura 13.




Figura 12. Gráfica de las series de tiempo de velocidad del viento, dirección del viento, temperatura, humedad relativa y presión.




Figura 13. Salida de media, desviación estándar y percentiles de las variables analizadas

La prueba de Dickey Fuller Aumentada fue aplicada, la prueba ADF no es una prueba directa para estacionalidad, pero indirectamente a través de la existencia (o ausencia) de una raíz unitaria. Todos los estadísticos de prueba son menores que el nivel de significancia, los datos son estacionarios. Ver Figura 14.

```

...: print("ADF test static for {} is {}".format(column, adf[1])) #Print the
adfuller results
ADFFuller Test: Significance: 0.05
ADF test static for Wind speed is 2.02205000005376e-30
ADF test static for Wind direction is 3.030337864647605e-24
ADF test static for Temperature is 9.303746874823615e-30
ADF test static for Relative Humidity is 1.0020023602150568e-25
ADF test static for Pressure is 4.1187754225171076e-26
In [123]:

```

Figura 14. Salida para ADFuller.

Adicionalmente se emplea el análisis de componente principal para determinar si se puede reducir la dimensionalidad de la serie de datos, comprobando que tanto influyen en la variable objetivo.

El análisis de componentes principales (PCA) es uno de los métodos de reducción de dimensionalidad más populares que transforma los datos proyectándolos en un conjunto de ejes ortogonales. Funciona al encontrar los autovectores y autovalores de la matriz de covarianza del conjunto de datos. Los vectores propios se denominan "componentes principales" del conjunto de datos (Anshul Jindal, 2019). Se obtuvo la siguiente gráfica, ver Figura 15.




Figura 15. Gráfica de tasa de variación explicada de los componentes principales

Se verifica que es necesario incluir todas las variables seleccionadas para abarcar el 100 (%) por ciento. Esto también se observa en la gráfica de varianza acumulada.




Figura 16. Gráfica de la varianza explicada acumulada.

Dentro de las métricas de desempeño que se tomaron para hacer el pronóstico de las series de tiempo, se realizó una revisión literaria para los modelos LSTM, las recomendaciones eran utilizar de 200 a 1000 épocas dependiendo de la complejidad del modelo, se aplicó un early-stopping para las 100 primeras épocas y el modelo se entrenó para 500 épocas.

Aproximación al diseño de la red neuronal

Se abordó como un problema de predicción y clasificación. De las 16 estaciones de la cuenca de Guadalupe, se escogió la estación Agua Caliente. El problema de predicción se puede abordar con diferentes modelos; en este caso particular para evaluar si hay ocurrencia de un evento Santa Ana se deben verificar los criterios de velocidad del viento, dirección del viento y humedad relativa; en este caso particular se despreció el dato de la humedad relativa debido que al hacer la verificación en los días que había ocurrencia de la condición de Santa Ana no se presentaban

valores de humedad relativa $\leq 10\%$. La red va a tener 5 variables de entrada representadas en la velocidad del viento, dirección del viento, la temperatura, la humedad relativa y la presión y tener una salida de estas cinco variables. Se inicio con un modelo sencillo compuesto de 100 neuronas para la capa de LSTM, 5 neuronas para la capa de salida. Luego se hace un ajuste de la red, mediante una búsqueda de los hiperparámetros de tasa de aprendizaje, tamaño del batch, número de épocas, regularización, función de activación, y la arquitectura de la red.

En la siguiente tabla se resumen los valores de la arquitectura de la red inicial:

Parámetro	Valor
Número de neuronas para la capa de salida	5
Número de neuronas capa lstm	100
Inicializador	Defecto Keras
Función de activación	Defecto Keras
Normalización	--
Regularización	L1 y L2 0.01
Optimizador	Adam
Tasa de aprendizaje	Defecto Keras
Métrica evaluación	Error medio cuadrático

Tabla 9. Resumen de parámetros seleccionados

4.4 Resultados

De la primera corrida del modelo propuesto se obtuvo una curva de aprendizaje bien ajustada, los parámetros a tener en cuenta son: se pronosticó las cinco variables para un día futuro a partir de 7 días pasados; la métrica que se verificó es el error medio cuadrático. El conjunto se dividió en 70% entrenamiento y 30% prueba. Ver Figura 17.




Figura 17. Salida de primer entrenamiento para la red propuesta

Para el modelo configurado de la siguiente forma ver

Tabla 10, se obtuvo la siguiente curva de aprendizaje. Los anchos de ventana utilizados fueron: a partir de 90 días pasados, predecir 30 días futuros.

Parámetro	Valor
Número de neuronas para la capa de salida	5
Número de neuronas capa lstm	100
Inicializador	He normal
Función de activación	Elu
Normalización	--
Regularización	L1 y L2 de 0.01
Optimizador	Adam
Tasa de aprendizaje	--
Early stopping	100 épocas
Métrica evaluación	Error medio cuadrático

Tabla 10. Parámetros de la red con las modificaciones al diseño original




Figura 18. Curva de aprendizaje para la red modificada

Al comparar los valores de la predicción con los datos iniciales se obtuvo un RMSE: 42.829, que es un valor alto por lo que se puede seguir mejorando la red. Además, al realizar la predicción dentro de los valores al aplicarle el filtro para determinar los días con vientos de Santa Ana, ninguno de los días coincide con el filtro.

Para una red configurada con un batch size de 32, métrica de error medio absoluto (MAE). Se obtiene la siguiente curva de aprendizaje, Figura 19, el cálculo de la predicción del RMSE es igual a 2.986. Al aplicar el filtro de velocidad del viento $\geq 4.5 \text{ m/s}$ y dirección del viento de 0 a 90° , se obtienen los siguientes días con condición de Santa Ana. La curva muestra un buen ajuste ya que las pérdidas de entrenamiento y prueba son bajas y convergen; aunque se puede seguir mejorando las oscilaciones modificando el tamaño del lote o con la tasa de aprendizaje.




Figura 19. Curva de aprendizaje para un tamaño de lote de 32.




Figura 20. Salida de días de la predicción que cumplen con la condición de Santa Ana.

Se varió el ancho de ventana, a partir de diez (10) días pasados predecir cinco (5) días en el futuro, con una regularización 11 y 12 de 0.01. Con un puntaje de RMSE de 1.74 entre la predicción y los valores originales de la serie.




Figura 21. Curva de aprendizaje implementando regularización de 0.01.

La siguiente figura corresponde a la gráfica del conjunto de datos iniciales y los valores del pronóstico calculados con los datos de prueba.




Figura 22. Grafica de velocidad del viento actual y predicción

4.5 Conclusiones

- A pesar que el modelo se ajustó de buena manera al conjunto de datos de acuerdo a las curvas de aprendizaje, al hacer las predicciones se obtuvieron valores de RMSE no tan bajos por lo que se sugiere utilizar otro tipo de modelo que capte mejor los patrones de los datos. En el análisis planteado también se observó que el modelo se ajustaba mejor a periodos donde los anchos de ventana de días pasados y días futuros eran pequeños y no tan amplios.
- Se recomienda utilizar una base de datos más grande, hacer validación cruzada, seguir con la optimización de hiperparámetros, cambiar la medida de las pérdidas, incluir la tasa de aprendizaje iniciando con un valor bajo.
- Realizar predicciones de los vientos de Santa Ana con redes neuronales permite una mayor precisión en la predicción de estos ya que la red tiene la capacidad de aprender y modelar las relaciones no lineales y complejas de los datos. Además, tiene la ventaja que constantemente este mejorando a medida que se alimenta con nuevos datos, es decir que se adapta mejor a los cambios en las condiciones climáticas y mejorar sus predicciones con el tiempo.

5 Análisis Multifractal de los vientos de Santa Ana

Como ya se mencionó en capítulos anteriores los vientos de Santa Ana son un fenómeno meteorológico que afecta principalmente la región suroeste de Estados Unidos y la región noroeste de México durante los meses de otoño e invierno (Álvarez & Carbajal, 2019). Son un viento cálido, seco, de tipo Föhn, del este o noreste que sopla desde el desierto oriental de Sierra Nevada hasta la costa del sur de California (Glickman & American Meteorological Society, 2000). En trabajos recientes, el análisis fractal resultó útil y adecuado para evaluar las series de tiempo que representaban las condiciones de ocurrencia de los vientos de Santa Ana, así como las series que representaban los días en los que este fenómeno no ocurre. Así, fue posible caracterizar series temporales de variables, como temperatura, precipitación, presión, humedad relativa y velocidad del viento, en términos de características de persistencia, antipersistencia o aleatoriedad (Serpa-Usta et al., 2022) . Cada variable meteorológica está controlada por una variedad de procesos físicos y exhibe fluctuaciones en varias escalas espaciales y temporales (Baranowski et al., 2019); por lo tanto, la teoría multifractal sirve como un marco sólido para investigar procesos no lineales que exhiben diversos niveles de intensidad. Además, el comportamiento multifractal está relacionado con sistemas en los que la física subyacente se rige por un proceso multiplicativo aleatorio que implica una medición y su fundamento geométrico según una regla especificada. Así, los análisis exhaustivos de este fenómeno facilitan la cuantificación precisa de fenómenos complejos (Lima, 1998; Zeleke & Bing, 2004).

El análisis multifractal ofrece varias ventajas al emplear un espectro más amplio de momentos estadísticos (q), lo que permite una comprensión más profunda de la variabilidad estructural de los datos. Se basa en el cálculo de dos conjuntos de parámetros o funciones asociadas con la serie temporal de las variables: los exponentes de Holder (α), que cuantifican la regularidad,

y el espectro multifractal, que cuantifica la multifractalidad de la señal y la medición (A. López Lambraño, 2012; Xiong, Yu, & Zhang, 2015). El espectro multifractal asocia cada conjunto de datos con la misma regularidad con la dimensión de Hausdorff de ese conjunto de datos, también conocida como espectro de singularidad (Grassberger, 1981).

En la literatura revisada, no se encontraron trabajos sobre el uso de enfoques multifractales para analizar las series de tiempo de los vientos de Santa Ana. Para abordar este vacío, se utilizó el método de Análisis de Fluctuación Multifractal sin Tendencia (Multi Fractal Detrended Fluctuation Analysis) en las series de tiempo diarias de los vientos de Santa Ana desde 1980 hasta 2018. Un factor determinante en la elección del método a aplicar fue el número de parámetros de entrada disponibles; el modelo sería más complejo si tuviera un mayor número de parámetros. El método elegido en este estudio es fácil de aplicar y ha sido ampliamente mencionado en la literatura reciente (Akinsusi, Ogunjo, & Fuwape, 2022; Balkissoon, Fox, & Lupo, 2020; de Lima & Grasman, 1999; Devi & Chattopadhyay, 2023; García-Marín, Estévez, Jiménez-Hornero, & Ayuso-Muñoz, 2013; Gómez-Gómez, Ariza-Villaverde, et al., 2023; Gómez-Gómez, Carmona-Cabezas, Sánchez-López, de Ravé, & Jiménez-Hornero, 2022; Jiang, Zhang, Liu, & Li, 2016; Laib, Golay, Telesca, & Kanevski, 2018; Liu, Xu, Chen, Nie, & Wei, 2014; Philippopoulos, Kalamaras, Tzanis, Deligiorgi, & Koutsogiannis, 2019; Sankaran, Plocoste, Nourani, Vahab, & Salim, 2023; Santos et al., 2021; Stosic et al., 2023; Tan & Gan, 2017; C Varotsos & Kirk-Davidoff, 2006; Zeng, Yang, Zhao, & Meng, 2013).

5.1 Formalismo multifractal

Existen diversos métodos que permiten obtener la dimensión fractal para un conjunto. Algunos otros métodos estiman un parámetro conocido como el exponente de Hurst (Hurst, 1951;

Pawelzik & Schuster, 1987). La dimensión fractal se relaciona con el exponente de Hurst, mediante la expresión desarrollada por (Hurst, 1956):

$$2H + 1 = 5 - 2D \quad (18)$$

Despejando la ecuación anterior se obtiene una relación directa entre la dimensión fractal (D) y el exponente de Hurst (H), por lo tanto:

$$D = 2 - H \quad (19)$$

Donde D es la dimensión fractal y H es el exponente de Hurst.

El concepto de objeto multifractal ha sido desarrollado por Mandelbrot (Mandelbrot, 1974) para investigar varias características en la intermitencia de turbulencia (Meneveau & Sreenivasan, 1991). Muchos autores han aplicado la multifractalidad a varios campos de la investigación científica. El formalismo multifractal se basa en la definición de la llamada función de partición $Z(q, \varepsilon)$,

$$Z(q, \varepsilon) = \sum_{i=1}^{N_{boxes}(\varepsilon)} \mu_i(\varepsilon) \quad (20)$$

La cantidad $\mu_i(\varepsilon)$ es una medida y depende de ε , el tamaño o la escala de las cajas utilizadas para cubrir la muestra. Los cuadros están etiquetados por el índice i y $N_{boxes}(\varepsilon)$ indica el número de cajas de tamaño ε necesarios para cubrir la muestra. El exponente q es un parámetro real, que da el orden del momento de la medida. La elección de la forma funcional de la medida $\mu_i(\varepsilon)$ es arbitraria, siempre que se cumpla la condición más restrictiva $\mu_i(\varepsilon) \geq 0$.

El parámetro q puede considerarse como un microscopio potente, capaz de mejorar las diferencias más pequeñas de dos mapas muy similares (Diego, Martínez-González, Sanz, Mollerach, & Martínez, 1999). Además, q representa un parámetro selectivo: valores altos de q mejoran cajas con valores relativamente altos para $\mu_i(\varepsilon)$; mientras que los valores bajos de q favorecen cajas con valores relativamente bajos de $\mu_i(\varepsilon)$. El tamaño de cajas ε se puede considerar como un filtro, por lo que los valores grandes del tamaño son equivalentes para aplicar un filtro a gran escala al mapa. Cambiando el tamaño ε , uno explora la muestra a diferentes escalas. Por lo tanto, la función de partición $Z(q, \varepsilon)$ proporciona información a diferentes escalas y momentos.

Las dimensiones generalizadas están definidas por la siguiente ecuación:

$$D(q) = \lim_{\varepsilon \rightarrow 0} \frac{1}{q-1} \frac{\ln Z(q, \varepsilon)}{\ln \varepsilon} \quad (21)$$

$D(0)$ es la dimensión de capacidad; $D(1)$ es la dimensión de información, y $D(2)$ es la dimensión de correlación. Un objeto se llama monofractal si $D(q)$ es constante para todos los valores de q , de lo contrario se llama multifractal. En la mayoría de las aplicaciones prácticas, el límite en la ecuación $D(q)$ no se puede calcular, porque no tenemos información a pequeña escala, o porque por debajo de una longitud física mínima no puede existir escala alguna (Diego et al., 1999). En general, se encuentra una región de escala, donde se puede ajustar una ley de potencia a la función de partición, que en ese rango de escala se comporta como:

$$Z(q, \varepsilon) \propto \varepsilon^{\tau(q)} \quad (22)$$

La pendiente $\tau(q)$ está relacionada con la dimensión generalizada mediante la siguiente ecuación:

$$\tau(q) = (q - 1)D(q) \quad (23)$$

Una medida habitual en la caracterización de multifractales está dada por el espectro de singularidad o el espectro de Legendre $f(\alpha)$, que se define de la siguiente manera. Si para cierta caja j la medida se escala como:

$$\mu_j(\varepsilon) \propto \varepsilon^{\alpha_j} \quad (24)$$

El exponente α , que depende de la caja j , se llama exponente de Holder. Si todas las cajas tienen la misma escala con el mismo exponente α , la muestra es monofractal. El multifractal se da si diferentes cajas se escalan con diferentes exponentes α , que corresponden a diferentes fuerzas de la medida. Denotando como S_α el subconjunto formado por las cajas con el mismo valor de α , e indicando como $N_\alpha(\varepsilon)$ la cardinalidad de S_α , para un multifractal se mantiene la siguiente relación:

$$N_\alpha(\varepsilon) \propto \varepsilon^{-f(\alpha)} \quad (25)$$

Mediante la transformación de Legendre, las cantidades α y $f(\alpha)$ pueden relacionarse con q y $\tau(q)$:

$$\alpha(q) = \frac{d\tau(q)}{dq} \quad (26)$$

$$f(\alpha) = q(\alpha)(q) - \tau(q) \quad (27)$$

La curva $f(\alpha)$ es una función de joroba simple para un multifractal, mientras que se reduce a un punto para un monofractal.

Para reconocer cuantitativamente las posibles diferencias en los espectros Legendre derivados de diferentes señales, es posible ajustar, por un método de mínimos cuadrados, los espectros a una función cuadrática alrededor de la posición de sus máximos en α_0 (Shimizu, Turner, & Ehrenberger, 2002):

$$f(\alpha) = A(\alpha - \alpha_0)^2 + B(\alpha - \alpha_0) + C \quad (28)$$

El parámetro B mide la asimetría de la curva, que es cero para formas simétricas, positiva o negativa para formas inclinadas a la izquierda o inclinadas a la derecha, respectivamente.

Otro parámetro es el ancho del espectro, que estima el rango de α donde $f(\alpha) > 0$, obtenido extrapolando la curva ajustada a cero; así el ancho se define como:

$$W = \alpha_{max} - \alpha_{min} \quad (29)$$

$$\text{Donde } f(\alpha_{max}) = f(\alpha_{min}) = 0$$

Estos tres parámetros sirven para describir la "complejidad" de la señal. Si α_0 es bajo, la señal se correlaciona y el proceso subyacente "pierde estructura fina" y se vuelve más regular en apariencia (Shimizu et al., 2002). El ancho W mide la longitud del rango de exponentes fractales en la señal; por lo tanto, cuanto más amplio es el rango, más "rica" es la señal en la estructura. El

parámetro de asimetría B informa sobre el dominio de los exponentes fractales bajos o altos con respecto al otro. Un espectro sesgado a la derecha denota exponentes fractales altos ponderados relativamente fuertes, correspondientes a estructuras finas, y exponentes bajos (más lisos) para espectros sesgados a la izquierda (Telesca, Colangelo, Lapenna, & Macchiato, 2003).

5.2 MFDFA

Muchas señales presentan características de “autosimilaridad”, es decir, que tienen propiedades similares en todas las escalas. Normalmente, la autosimilaridad es correlacionada con las dimensiones fractales, esto es, la relación no entera entre la medida del dominio y la medida del gráfico.

Las propiedades de escala de las series de tiempo meteorológicas analizadas se estudiaron con el método del Análisis Multifractal sin Fluctuación de Tendencia (MFDFA). Esta herramienta se puede utilizar para la detección de multifractalidad de la serie temporal de interés y la información sobre el comportamiento de escala y los parámetros obtenidos pueden eventualmente ayudar a realizar el modelado multifractal (Adarsh et al., 2020).

Según (Broday, 2010; Kantelhardt et al., 2002; López-Lambraño et al., 2018; A. López Lambraño, 2012; Sadegh Movahed, Jafari, Ghasemi, Rahvar, & Reza Rahimi Tabar, 2011), el procedimiento DFA multifractal modificado (MFDFA) consta de cinco pasos. Se supone que x_k es una serie de longitud N , y que esta serie es de soporte compacto, es decir, $x_k = 0$ sólo para una insignificante fracción de valores.

Paso 1— Se determina el perfil:

$$Y(i) \equiv \sum_{k=1}^i [x_k - \langle x \rangle], \quad i = 1, \dots, N \quad (30)$$

La sustracción de la media $\langle x \rangle$ no es obligatoria ya que será eliminada en el análisis de tendencia que se desarrolla en el paso 3.

Paso 2— Se divide el perfil $Y(i)$ en $N_s = \text{int}(N/s)$ segmentos no superpuestos de longitudes iguales s . Dado que la longitud N de la serie a menudo no es múltiplo de la escala de tiempo s considerada, puede quedar una pequeña parte al final del perfil. Para eliminar esta parte de la serie, se repite el mismo procedimiento, empezando por el extremo opuesto. El resultado es que se obtienen $2N_s$ segmentos en total.

Paso 3— Se calcula la tendencia local para cada uno de los segmentos de $2N_s$ mediante un ajuste de mínimos cuadrados de la serie. Luego se determina la varianza:

$$F^2(s, v) \equiv \frac{1}{s} \sum_{i=1}^s \{Y[(v-1)s + i] - y_v(i)\}^2 \quad (31)$$

para cada segmento $v, v = 1, \dots, N_s$, y:

$$F^2(s, v) \equiv \frac{1}{s} \sum_{i=1}^s \{Y[N - (v - N_s)s + i] - y_v(i)\}^2 \quad (32)$$

Para $v = N_s + 1, \dots, 2N_s$. Donde, $y_v(i)$ es el polinomio de ajuste en el segmento v . En el procedimiento de ajuste se pueden emplear polinomios lineales, cuadráticos, cúbicos o de orden superior. Dado que la eliminación de tendencias de la serie temporal se completa restando el ajuste

polinómico del perfil, los DFA de diferente orden difieren en su capacidad de eliminar tendencias en la serie.

Paso 4— Se promedian todos los segmentos para obtener la función de fluctuación de orden q , definida como:

$$F_q(s) \equiv \left\{ \frac{1}{2N_s} \sum_{v=1}^{2N_s} [F^2(s, v)]^{q/2} \right\}^{1/q} \quad (33)$$

Donde, generalmente, la variable índice q puede tomar cualquier valor real excepto cero. Para $q = 2$, se recupera el procedimiento estándar del DFA. En general, estamos interesados en cómo la función de fluctuación generalizada $F_q(s)$ q -dependiente, dependen de la escala de tiempo s para diferentes valores de q . Por lo tanto, se deben repetir los pasos 2, 3 y 4 durante varias escalas de tiempo. Es evidente que $F_q(s)$ aumentará al aumentar s . Por supuesto, $F_q(s)$ depende del orden m del DFA. $F_q(s)$ sólo se define intencionalmente para $s \geq m + 2$.

Paso 5— Se determina el comportamiento escalar de la función de fluctuación analizando las gráficas log-log de $F_q(s)$ contra s para cada valor de q . Si la serie x_i presenta correlaciones con una ley de potencia de largo alcance, $F_q(s)$ aumenta para valores grandes de s , entonces se tiene que:

$$F_q(s) \sim s^{h(q)} \quad (34)$$

Donde $h(q)$ es el exponente generalizado de Hurst.

Con la relación $\tau(q) = qh - 1$ y la transformada de Legendre $\alpha = \frac{d\tau}{dq}$, el espectro multifractal se obtiene como:

$$f(\alpha) = q\alpha - \tau(q) \quad (35)$$

5.3 Parámetros multifractales

En este caso de estudio, se calcularon los parámetros multifractales de: α_0 , $\Delta\alpha$ y r . El ancho del espectro $\Delta\alpha$ es la diferencia entre α_{max} y α_{min} y puede considerarse como una medida directa del grado o complejidad de la multifractalidad. El resultado muestra la longitud hasta la cual se extiende el exponente fractal en la serie, lo que es un indicador de la "riqueza" de la estructura de la señal. Cuando el valor de $\Delta\alpha$ es mayor, la multifractalidad está más desarrollada. El parámetro α_{min} indica los eventos más extremos en el proceso estudiado y α_{max} indica los eventos más suaves. El parámetro α_0 entrega información valiosa sobre la estructura del proceso estudiado, con un valor alto indicando que está menos correlacionado y posee una estructura fina. Si el proceso subyacente se correlaciona y pierde su fina estructura, volviéndose más regular en apariencia, el valor α_0 , que indica en qué valor de un espectro multifractal alcanza su máximo, es bajo. La forma del espectro multifractal se ve fuertemente modificada por el parámetro de asimetría r . La asimetría depende de α_{max} , α_{min} y α_0 . Los valores negativos de r (la forma de los espectros de singularidad está sesgada hacia la izquierda) indican exponentes fractales bajos de pesos pequeños, lo que implica que los eventos extremos juegan un papel destacado en la estructura temporal de la serie temporal. Por el contrario, un espectro sesgado a la derecha (valor positivo de r) significa exponentes fractales ponderados bastante fuertes, que son típicos en series de estructuras finas (Baranowski et al., 2019; Krzyszczak et al., 2019).

La función de fluctuación, el exponente de Hurst generalizado, escalado de exponente de masa, el espectro multifractal y los parámetros multifractales (α_{max} , α_{min} , α_0 , $\Delta\alpha$ y r) se calcularon para las series de tiempo de temperatura, humedad relativa, presión, dirección del viento y velocidad del viento para los días en que ocurrió el evento de Santa Ana. Estos cálculos se completaron utilizando las ecuaciones descritas en (30) a (35).

5.4 Multifractalidad de los vientos de Santa Ana

El MFDFA se aplica a la temperatura, humedad relativa, presión, dirección y velocidad del viento, para las series temporales que comprenden registros de datos entre los años 1980 y 2018.

Se presentan los resultados obtenidos una vez aplicado el método MFDFA. Se selecciona la estación Agua Caliente como ilustración del proceso de implementación; las salidas gráficas de los resultados se construyeron utilizando el método MFDFA.

El objetivo es obtener un espectro de singularidad para comprobar la naturaleza multifractal de las series temporales de los vientos de Santa Ana (temperatura, humedad relativa, presión, dirección y velocidad del viento). Para ello, se debe definir el momento estadístico “q”. El presente estudio lo definió entre -10 y 10. El perfil de una serie se determina aplicando la Ecuación (30) con $q = 10$. Una vez definido el perfil, se realiza un análisis de fluctuación para $q = -10$ y $q = 10$, como se muestra en la Figura 23. Es importante mencionar que, en este caso en particular, el análisis de fluctuación se realiza con 100 segmentos o ventanas.




Figura 23. Representación log-log para la función de fluctuación de los datos de los vientos de Santa Ana en la estación Agua Caliente, $q=10$.

La función de fluctuaciones en la Figura 23 representa la evolución de la función de fluctuación a partir de un número determinado de ventanas para el análisis. Además, dicho gráfico muestra varias oscilaciones y cambios de pendiente en todas las variables analizadas. Los cambios en la pendiente indican que la señal exhibe múltiples escalamientos, es decir, se presenta con un carácter multifractal. Este comportamiento es muy similar en los momentos analizados, que en este caso son $q = -10$ y $q = 10$.

Este procedimiento anterior se repite para todas las escalas de tiempo (segmentos) para obtener una relación entre $F(s)$ y el tamaño del segmento S . Esto se aplica a diferentes valores de q . Por otro lado, la pendiente de la función de fluctuación corresponde al exponente de Hurst generalizado para el momento de orden q , véase ecuación (34).

La gráfica del exponente de Hurst generalizado se obtiene para valores q que oscilan entre -10 y 10 (Ver Figura 24); los resultados se observan en la figura mencionada, donde se muestran las funciones $h(q)$ y $\tau(q)$, véase ecuación (35).

La figura anterior (Figura 24) muestra que la serie tiempo de los vientos de Santa Ana es un proceso multifractal debido a una fuerte dependencia del exponente generalizado q y $\tau(q)$. Para valores $q < 0$ y $q > 0$ se tienen distintos comportamientos, que se puede observar por la variación presente en la línea de pendiente que conecta ambos puntos, ya que esta línea difiere para valores positivos y negativos. Se selecciona la temperatura para ejemplificar el cambio de pendiente. La Tabla 11 resume los cambios para las otras variables. De acuerdo a la relación entre el exponente de Hurst y $h(q)$, es decir, $h(q = 10) - 1 = H$, el valor del exponente de Hurst es igual a 0.4638 y la dimensión fractal se puede obtener como $Df = (2 - H) = 1.5362$. Para valores negativos de q se calculó una pendiente $\tau(q)$ de 0.70, mientras que en valores positivos la pendiente es de 0.48. También se puede notar que la curva $\tau(q)$ es una curva convexa lo que es un indicador de multifractalidad.

El espectro multifractal (o de singularidad), se puede obtener siguiendo la ecuación (35), correspondiente a la transformada de Legendre; en la Figura 25 se puede observar el espectro multifractal de la temperatura, humedad relativa, presión, velocidad y dirección del viento en la Estación Agua Caliente con valores de $q = -10, 10$.




Figura 24. Función $h(q)$ y $\tau(q)$ para valores de $q = -10, 10$; a partir de dicha función se genera el espectro multifractal.

El espectro multifractal en la Figura 25 representa una función cóncava, para la cual diferentes partes de la estructura están caracterizadas por diferentes valores de (α) , lo que lleva a la existencia del espectro multifractal $f(\alpha)$. Por un lado, el comportamiento de las parábolas inversas es una prueba del carácter multifractal de la serie y, por otro lado, el ancho espectral de $\Delta\alpha = (\alpha_{max} - \alpha_{min})$ proporciona el grado de variabilidad que puede presentar una variable, siendo la temperatura, humedad relativa, presión, velocidad del viento y dirección del viento las variables en este estudio. La fuerza multifractal es una medida utilizada para determinar qué tan fuerte es la multifractalidad presente en un proceso. El análisis realizado en la presente investigación estima $(\Delta\alpha)$ para los datos de la serie de datos de días con Vientos de Santa Ana. Se escogió el espectro de temperatura en la Figura 25 para ejemplificar la estimación del ancho del espectro, presentando valores de $\alpha_{max} = 0.8361$ y $\alpha_{min} = 0.426$ para la temperatura. Por tanto, el ancho del espectro tiene un valor de $\Delta\alpha = 0.41$. Los valores anteriores de $(\alpha_{max} - \alpha_{min})$ representan el rango entre los valores máximos y mínimos de temperatura. Las estimaciones del ancho para las otras variables y estaciones se muestran en la Tabla 11.

	Código de estación	2118	2035	2066	2079	2164	2001	2004	2005	2021	2025	2036	2049	2094	2122	2077	2114
Temperatura	m para q^-	0.86	0.92	0.79	0.96	0.74	0.70	0.69	0.74	0.68	0.70	0.67	0.71	0.75	0.77	0.83	0.73
	m para q^+	0.45	0.46	0.47	0.46	0.35	0.48	0.40	0.45	0.48	0.50	0.44	0.38	0.49	0.45	0.46	0.37
	$hq(q = 10)$	0.46	0.47	0.49	0.47	0.36	0.46	0.40	0.45	0.49	0.42	0.44	0.39	0.49	0.46	0.47	0.37
	Df	1.54	1.53	1.51	1.53	1.64	1.54	1.60	1.55	1.51	1.58	1.56	1.61	1.51	1.54	1.53	1.63
	α_{max}	0.94	1.01	0.83	1.06	0.87	0.84	0.79	0.85	0.74	0.77	0.74	0.80	0.83	0.84	0.93	0.82
	α_{min}	0.43	0.43	0.43	0.43	0.30	0.43	0.35	0.41	0.45	0.38	0.39	0.34	0.45	0.41	0.42	0.32
	$\Delta\alpha$	0.52	0.59	0.39	0.63	0.57	0.41	0.44	0.44	0.29	0.39	0.35	0.46	0.38	0.43	0.51	0.50
Humedad Relativa	m para q^-	1.15	1.23	0.98	1.21	1.37	1.18	1.16	1.01	1.14	1.15	1.15	0.95	1.10	1.08	1.05	1.01
	m para q^+	0.60	0.64	0.45	0.62	0.49	0.68	0.70	0.69	0.58	0.67	0.67	0.56	0.64	0.67	0.67	0.70
	$hq(q = 10)$	0.63	0.66	0.48	0.64	0.53	0.70	0.72	0.71	0.60	0.69	0.69	0.58	0.67	0.69	0.69	0.72
	Df	1.37	1.34	1.52	1.36	1.47	1.30	1.28	1.29	1.40	1.31	1.31	1.42	1.33	1.31	1.31	1.28
	α_{max}	1.21	1.30	1.04	1.27	1.42	1.23	1.22	1.06	1.20	1.22	1.21	1.00	1.17	1.14	1.10	1.07
	α_{min}	0.53	0.57	0.38	0.55	0.42	0.63	0.64	0.63	0.50	0.62	0.61	0.51	0.57	0.60	0.61	0.65
	$\Delta\alpha$	0.68	0.73	0.66	0.73	1.00	0.61	0.58	0.43	0.70	0.60	0.61	0.49	0.59	0.54	0.49	0.42
Presión	m para q^-	0.88	1.04	0.77	0.76	1.31	0.80	0.74	0.82	0.63	0.82	0.82	0.83	0.77	0.80	0.87	0.76
	m para q^+	0.72	0.57	0.41	0.59	0.96	0.66	0.64	0.60	0.53	0.60	0.61	0.55	0.55	0.54	0.60	0.64
	$hq(q = 10)$	0.72	0.59	0.42	0.60	0.97	0.66	0.65	0.61	0.53	0.61	0.62	0.56	0.56	0.55	0.61	0.64
	Df	1.28	1.41	1.58	1.40	1.03	1.34	1.35	1.39	1.47	1.39	1.38	1.44	1.44	1.45	1.39	1.36
	α_{max}	0.94	1.15	0.87	0.81	1.37	0.85	0.78	0.88	0.67	0.88	0.88	0.91	0.84	0.79	0.92	0.81
	α_{min}	0.71	0.53	0.34	0.55	0.92	0.63	0.61	0.56	0.49	0.55	0.57	0.52	0.49	0.57	0.55	0.61
	$\Delta\alpha$	0.24	0.63	0.52	0.27	0.45	0.22	0.16	0.33	0.18	0.34	0.31	0.39	0.35	0.23	0.37	0.21
Vel. del viento	m para q^-	0.91	0.90	0.74	0.90	0.78	0.85	0.87	0.96	0.83	0.92	0.93	0.76	0.97	0.91	0.99	0.82
	m para q^+	0.39	0.43	0.14	0.44	0.31	0.49	0.46	0.49	0.38	0.40	0.49	0.33	0.51	0.38	0.04	0.48
	$hq(q = 10)$	0.41	0.44	0.17	0.45	0.33	0.50	0.48	0.50	0.40	0.42	0.50	0.35	0.52	0.41	0.47	0.49

Dir. del viento	Df	1.59	1.56	1.83	1.55	1.67	1.50	1.52	1.50	1.60	1.58	1.50	1.65	1.48	1.59	1.53	1.51
	α_{max}	0.98	0.96	0.81	0.97	0.83	0.93	0.92	1.03	0.90	0.98	1.01	0.82	1.04	0.97	1.07	0.89
	α_{min}	0.33	0.37	0.06	0.38	0.24	0.46	0.39	0.45	0.31	0.33	0.44	0.26	0.46	0.30	0.39	0.44
	$\Delta\alpha$	0.65	0.58	0.75	0.59	0.58	0.47	0.53	0.59	0.58	0.65	0.57	0.55	0.59	0.67	0.67	0.45
	$m \text{ para } q^-$	0.71	0.82	0.86	0.80	0.75	0.59	0.68	0.67	0.53	0.66	0.72	0.59	0.73	0.74	0.71	0.64
	$m \text{ para } q^+$	0.48	0.45	0.37	0.44	0.52	0.25	0.36	0.37	0.31	0.28	0.43	0.40	0.32	0.29	0.43	0.37
	$hq(q = 10)$	0.48	0.46	0.39	0.46	0.53	0.27	0.37	0.39	0.32	0.29	0.44	0.41	0.34	0.31	0.45	0.38
	Df	1.52	1.54	1.61	1.54	1.47	1.73	1.63	1.61	1.68	1.71	1.56	1.59	1.66	1.69	1.55	1.62
	α_{max}	0.77	0.89	0.94	0.84	0.79	0.66	0.76	0.72	0.57	0.74	0.79	0.64	0.81	0.80	0.77	0.72
	α_{min}	0.43	0.40	0.31	0.40	0.49	0.20	0.32	0.29	0.24	0.22	0.38	0.36	0.26	0.20	0.38	0.33
	$\Delta\alpha$	0.34	0.49	0.63	0.45	0.30	0.45	0.44	0.43	0.33	0.52	0.42	0.27	0.55	0.60	0.39	0.39

Tabla 11. Parámetros multifractales del MFDFA (adimensionales) para las variables meteorológicas estudiadas.




Figura 25. Espectro multifractal de la serie de vientos de Santa Ana registrada entre 1980 y 2018 en la estación Agua Caliente. $f(\alpha)$ se obtuvo de las funciones $h(q)$ y $\tau(q)$ para valores de $q = -10, 10$.

Cuando hay una acumulación concentrada de puntos en los extremos del espectro, se puede indicar la existencia de valores extremos alejados de la media, situación que puede ser presentada para ordenes mayores para rangos de q , como sucede en la estación de Agua Caliente. Por el contrario, si una rama del espectro multifractal es más corta que la otra, podría indicar valores de heterogeneidad con los espectros de temperatura, presión y dirección del viento, como se observa en la Figura 25. En el ANEXO A, se encuentran las gráficas correspondientes a la función de fluctuación, el exponente de Hurst generalizado, la función de exponente de masa y el espectro multifractal para cada variable climática de cada estación.

Visualmente, los espectros multifractales de humedad relativa y velocidad del viento parecen tener valores homogéneos de (α) y $f(\alpha)$ porque las ramas de la izquierda y la derecha tienen una longitud similar. Sin embargo, con la estimación del parámetro de asimetría se encontró que estos eran asimétricos hacia la derecha. Esta información se discutirá con más detalle más adelante.

La Figura 26 muestra el espectro multifractal de cada estación para cada una de las variables analizadas de los vientos de Santa Ana.

El espectro multifractal de las variables meteorológicas estudiadas muestra variabilidad espacial. Además, en el espectro de temperatura la rama a la derecha es más larga que la de la izquierda, y a su vez la rama derecha del espectro de temperatura es más larga en comparación de las ramas de los espectros de las otras variables (Figura 26). Esto se atribuye a la estructura multifractal de la serie de tiempo que es insensible a las fluctuaciones locales de grandes magnitudes (Kalamaras et al., 2017).

Entre las series de tiempo analizadas en la Tabla 11, tanto la presión como la humedad relativa presentan valores de $h(q)$ mayores a 0.5, con excepción de la estación Sierra de Juárez (2066), donde el $h(q)$ para esta variable cae por debajo de 0.5. Esta excepción resalta la dinámica única de esta zona, al ser el punto más alto sobre el nivel del mar de la cuenca de Guadalupe, indicando un comportamiento antipersistente. Generalmente las demás estaciones de la cuenca tienen un comportamiento persistente, es decir, las series de humedad relativa tienen alta probabilidad de mostrar un comportamiento creciente positivo. Esto implica que la serie temporal de humedad relativa tiene un alto grado de ocurrencia sobre eventos futuros o en su memoria de comportamiento a largo plazo; lo mismo sucede para la variable de la presión.

Por el contrario, los valores $h(q)$ más bajos se obtuvieron para la velocidad del viento (0.17-0.52), la dirección del viento (0.27-0.53) y la temperatura (0.36-0.49); lo que sugiere un comportamiento anti-persistencia en estas series de tiempo. Esto significa que las variables de temperatura, velocidad y dirección del viento en esta región a menudo exhiben un patrón de aumentos positivos seguidos de disminuciones posteriores en sus valores registrados, y viceversa. Según Malamud y Turcotte, una serie de tiempo antipersistente tendrá un comportamiento estacionario en el tiempo debido a los aumentos y disminuciones que se compensan entre sí. Los momentos estadísticos son independientes de las series temporales (López-Lambraño et al., 2018).




Figura 26. Espectro multifractal de las series de tiempo meteorológicas estudiadas para la cuenca hidrográfica de Guadalupe.

Sin embargo, existen algunas excepciones, por ejemplo, la dirección del viento en la estación Ejido Porvenir (estación 2164) tiene un valor de $0.53 h(q)$, es decir, tiene un

comportamiento persistente en contraste con los valores reportados en las otras estaciones (Tabla 11). Este valor demuestra que existe una correlación entre los valores de longitud y $h(q)$ correspondientes a la serie temporal de la variable de dirección del viento. Para la subcuenca Guadalupe, la velocidad del viento presenta valores de antipersistencia y aleatoriedad, debido a que los valores de $h(q)$ en algunas estaciones son inferiores a 0.5 (estación 2049—San Juan de Dios Norte) mientras que en otras es igual a 0.5 (estación 2001—Agua Caliente). Lo anterior puede estar asociado a la correlación inversa encontrada entre altitud y longitud con respecto a los valores de $h(q)$.

Los resultados de los valores de $h(q)$ de las variables temperatura, velocidad y dirección del viento denotan que los vientos de Santa Ana exhiben alta variabilidad climática en la zona.

Si bien la temperatura no fue uno de los criterios utilizados para evaluar la ocurrencia de días de viento en Santa Ana, los valores de $h(q)$ de esta variable muestran la influencia y ocurrencia del viento de Santa Ana en la propia serie temporal de temperatura, es decir, en este caso, los valores $h(q)$ de la temperatura pueden considerarse como un criterio para identificar la ocurrencia de los vientos de Santa Ana en la región.

Con base en los valores de $h(q)$ y considerando el momento de orden q (-10 a 10), se puede observar que la estación meteorológica Sierra de Juárez (2066) muestra un comportamiento diferente al resto de las estaciones, es decir, los valores de $h(q)$ para las variables humedad relativa, presión y velocidad del viento son menores en comparación con las otras estaciones. Esta diferencia se puede atribuir a que la estación en cuestión se encuentra ubicada en el punto más alto de la cuenca, como se muestra en la Tabla 11.

De acuerdo con (Dos Santos, Do Nascimento, Jale, Xavier, & Ferreira, 2023), cuando el parámetro multifractal de α_0 es igual a 0.5, las series de tiempo se consideran aleatorias. Para valores de α_0 inferiores a 0.5, las series son antipersistentes, es decir, presentan cambios bruscos en el tiempo. Para valores de α_0 mayores que 0.5, la serie exhibe un comportamiento persistente, lo que indica que la serie de tiempo no muestra cambios abruptos en el tiempo.

En las Figura 27b, Figura 28b, Figura 29b, Figura 30b y Figura 31b , se puede observar que los valores de α_0 fueron predominantemente mayores a 0.5, lo que indica la presencia de un comportamiento persistente.




Figura 27. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la temperatura.




Figura 28. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la humedad relativa.




Figura 29. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la presión.




Figura 30. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la dirección del viento.




Figura 31. (a) Valores de $h(q)$, (b) valores de α_0 , (c) valores de $\Delta\alpha$, mientras que (d) contiene los valores de asimetría r para la velocidad del viento.

Los valores de α_0 para la temperatura exhiben una correlación positiva con la altitud y una correlación negativa con la latitud, como se muestra en el mapa de la Figura 27b. Esto significa que α_0 disminuye en dirección de este a oeste, lo que indica una disminución en la persistencia. Este patrón concuerda con lo reportado en la investigación (da Silva et al., 2020), donde se observa que la α_0 de la serie de temperaturas disminuye con la latitud.

En el caso de α_0 para la humedad relativa (Figura 28b), se observó una correlación inversa con la altitud y la longitud. Los valores más altos de α_0 ocurrieron cerca de la costa del Pacífico, y esto puede estar asociado con la formación de niebla que ocurre en el mar durante la ocurrencia de los vientos de Santa Ana.

En la Figura 28b se puede observar un comportamiento persistente debido a que los valores de α_0 son mayores que 0.5 y aumentan de oeste a este.

La Figura 30b ilustra los valores de α_0 para la dirección del viento y se observa una correlación inversa con la latitud. En las zonas altas de la cuenca se presenta un comportamiento antipersistente que puede estar relacionado con la desviación del flujo de aire provocada por la orografía de la región.

Respecto a los valores de α_0 para la variable velocidad del viento (Figura 31b), también se observó una correlación inversa con la altitud. Este comportamiento es similar al observado en los valores de α_0 de humedad relativa (Figura 28b), por ejemplo, la estación Sierra Juárez (2066) ubicada en el punto más alto de la cuenca, que exhibió un valor de α_0 correspondiente a 0.49. La estación La Misión (2077), en tanto, se ubica en el punto más bajo y occidental de la cuenca y presentó un valor correspondiente a 0.64. Las estaciones más

cercanas a esta longitud, como Boquilla Santa Rosa de La Misión (2005), Olivares Mexicanos (2036) y El Farito (2094), también tuvieron valores de α_0 de 0.64.

En la Figura 27c, Figura 28c, Figura 29c, Figura 30c, Figura 31c y Tabla 11 muestran los valores correspondientes al ancho del espectro de singularidad ($\Delta\alpha$) para las diferentes variables meteorológicas analizadas. El ancho es una medida del tamaño de las fluctuaciones y del grado de multifractalidad. Los valores más altos indican un mayor grado de multifractalidad. Se encontró que $\Delta\alpha$ tenía una correlación inversa débil entre la latitud y las variables de temperatura, presión, velocidad del viento y dirección. En el caso de la humedad relativa existe una correlación positiva con la longitud y el grado de multifractalidad aumenta de oeste a este.

Cuanto mayor es la amplitud del espectro, mayor es la dificultad para hacer predicciones. Al analizar las series de temperatura (Figura 27c) y presión (Figura 29c), se encontró que los valores de $\Delta\alpha$ en las estaciones El Pinal (2021) y Olivares Mexicanos (2036) son los más bajos. Estas estaciones están ubicadas en el Valle de Guadalupe, es decir que corresponde a la zona donde se podría realizar las mejores predicciones sobre esta variable. Lo contrario ocurre en el área correspondiente a la subcuenca de Ojos Negros (región sur).

Para la variable velocidad del viento (Figura 31c), los valores más altos de $\Delta\alpha$ se reportan en las estaciones de la Misión (2077) y Sierra de Juárez (2066). Esto confirma que estas variables tienen una naturaleza de escalamiento multifractal. Para la serie correspondiente a la dirección del viento, la estación Sierra de Juárez (2066) presenta el valor de $\Delta\alpha$ más alto.

En general, los mapas correspondientes al parámetro $\Delta\alpha$ muestran que todos los espectros de singularidad son lo suficientemente amplios como para indicar la ocurrencia de multifractalidad en la cuenca. La zona de la Sierra de Juárez muestra un mayor grado de multifractalidad según los anchos de los espectros analizados.

El parámetro (r) mide la asimetría del espectro multifractal o singularidades. Para este caso de estudio, el parámetro de asimetría (r) presenta valores mayores a 1 en la mayoría de las estaciones donde se analizaron las variables (Figura 27d, Figura 28d, Figura 29d, Figura 30d y Figura 31d), es decir, una asimetría con tendencia hacia la derecha del espectro multifractal (valor positivo de r), lo cual denota exponentes fractales de valores altos y gran peso (Aguilar-Molina, Angulo-Brown, & Muñoz-Diosdado, 2019; Muñoz-Diosdado & Del Río-Correa, 2006).

Además, las Figura 27d, Figura 28d, Figura 29d, Figura 30d y Figura 31d, muestran que en la estación Sierra de Juárez (2066), las series correspondientes a temperatura, humedad relativa y velocidad del viento tienen un espectro multifractal sesgado hacia la izquierda ($r < 1$). Los valores negativos del parámetro de asimetría indican bajos exponentes fractales de bajo peso y sugieren el predominio de grandes fluctuaciones, que pueden estar relacionadas con eventos extremos (Baranowski et al., 2019; Dos Santos et al., 2023).

La multifractalidad de la serie estudiada se cuantificó a través del ancho y asimetría del espectro multifractal. Esto permite concluir que la naturaleza multifractal de las series de tiempo correspondientes a temperatura, velocidad y dirección del viento, humedad relativa y presión en los días en que ocurren los vientos de Santa Ana exhiben una estructura fina con pequeñas fluctuaciones.

Finalmente, los valores correspondientes a los parámetros y características del espectro multifractal o singularidades pueden usarse como indicadores cuantitativos y cualitativos para describir la dinámica de los procesos meteorológicos durante la ocurrencia de los vientos de Santa Ana en la cuenca de Guadalupe.

A partir de estos resultados, se puede confirmar que las series de tiempo estudiadas, asociadas a la ocurrencia de los vientos de Santa Ana, mantienen el mismo comportamiento y estructura para un momento de orden $q = 2$ (monofractal) y un momento de orden $q = 10$ (multifractal), es decir, es invariante a la escala.

5.5 Conclusiones

Las series de tiempo diaria de las variables meteorológicas de 38 años de duración de la base de datos MERRA-2 posee propiedades multifractales, como lo confirmó el Análisis multifractal sin fluctuación de tendencia (MF DFA).

Del análisis multifractal se estimaron el exponente de Hurst generalizado y los parámetros del espectro multifractal ($\alpha_0, \Delta\alpha$ y r) y se obtuvieron las siguientes conclusiones.

Primero, se investigó la naturaleza multifractal de los datos de las series de tiempo diarias para las variables climáticas asociadas con los vientos de Santa Ana. Se empleó el método MF DFA para extraer los parámetros de complejidad multifractal ($\alpha_0, \Delta\alpha$ y r) y construir los espectros multifractales para la temperatura, humedad relativa, presión, dirección y velocidad del viento en las 16 estaciones de monitoreo dentro del área de influencia de la cuenca. Mientras tanto, el método MF DFA resultó adecuado para evaluar la multifractalidad de las series de tiempo que representan las condiciones de ocurrencia de los vientos de Santa Ana. A partir de la estimación del exponente de Hurst generalizado (hq),

fue posible caracterizar las series temporales de las variables meteorológicas en términos de sus características de persistencia, antipersistencia o aleatoriedad.

En segundo lugar, el Análisis Multifractal Sin Fluctuación de Tendencia (MFDFA) confirmó que la serie de tiempo meteorológica de los vientos de Santa Ana exhibe características multifractales. La fuerte correlación lineal observada entre $\log(Fq)$ y $\log(s)$, junto con los perfiles estables de los espectros multifractales, prueban que los datos analizados son aplicables para el análisis multifractal. Además, la fuerte dependencia del exponente generalizado q y $\tau(q)$ mostró que la serie de tiempo meteorológica de los vientos de Santa Ana es un proceso multifractal. Los valores $q < 0$ y $q > 0$ tienen comportamientos diferentes debido a la variación presente en la recta de pendiente que une ambos puntos, ya que esta recta es diferente para valores positivos y negativos. Además, los espectros multifractales calculados permitieron estimar la dimensión fractal del conjunto de soporte de cada variable, obteniendo buena precisión en la estimación de la dimensión de información. Los espectros multifractales obtenidos en las estaciones climatológicas de la cuenca Guadalupe son asimétricos con ramas sesgadas a la derecha, es decir ramas más largas hacia ese lado, en la mayoría de los casos, lo que indica una alta heterogeneidad de las variables asociadas a los vientos de Santa Ana.

Además, el análisis multifractal revela que todas las variables examinadas muestran un grado de persistencia, siendo la temperatura, la dirección y la velocidad del viento las que muestran el grado más débil. Al mismo tiempo, la humedad relativa y la presión exhiben los niveles de persistencia más fuertes, y la espacialización de los parámetros multifractales asociados con las variables meteorológicas consideradas muestra una variabilidad espacial significativa. Este comportamiento puede estar vinculado a diversos factores, tales como:

deflexión del flujo horizontal de gran escala por la orografía, geografía física de la región, la topografía, proximidad al mar, movimiento de masas de aire y microclimas.

La distribución espacial de los parámetros multifractales exhibe variaciones, lo que permite identificar regiones susceptibles a eventos extremos, procesos correlacionados o no correlacionados. Esto se nota más en los mapas de temperatura, velocidad y dirección del viento.

Además, ofrece una valiosa alternativa a los enfoques convencionales para el análisis de la dinámica climática y tiene potencial para estudios comparativos.

El análisis multifractal y los mapas de los parámetros multifractales permiten describir el comportamiento de los vientos de Santa Ana a través de leyes potenciales caracterizadas por sus propios exponentes. También constituye una herramienta válida para la conceptualización de posibles cambios en el tiempo para brindar información valiosa que pueda ayudar a los agricultores a tomar decisiones y realizar acciones para mitigar el impacto de fenómenos de variabilidad climática, como los vientos de Santa Ana.

Por supuesto, el presente estudio no puede explicar exhaustivamente la muy compleja variabilidad espaciotemporal de las variables climáticas asociadas con los vientos de Santa Ana; sin embargo, representa un aporte a la caracterización de los vientos de Santa Ana y al entendimiento de los mecanismos que gobiernan su dinámica en la cuenca de Guadalupe.

Para futuros trabajos se debe realizar una aplicación horaria y mensual a lo largo de los años para comparar las características de multifractalidad en la serie, considerando que los vientos de Santa Ana presentan variaciones horarias en un mismo día. Además, un trabajo futuro podría asociar la multifractalidad con la clasificación climática.

Finalmente, este tipo de estudios contribuye a comprender la dinámica regional de la cuenca de Guadalupe y a establecer una base para el desarrollo de modelos que permitan pronosticar los días en que se presentan los vientos de Santa Ana para mitigar las potenciales consecuencias negativas, como incendios y sequías.

6 Análisis complementario

Se profundizará en las correlaciones y distribuciones espaciales de los parámetros multifractales mediante la construcción de una matriz de correlación para comparar y complementar los análisis generados de las relaciones encontradas con la especialización de dichos parámetros.

6.1 Análisis de correlación de parámetros multifractales

El análisis de correlación muestra la fuerza de la relación de una variable a partir de otra (normalmente Y a partir de X).

La correlación o coeficiente de correlación (r) es un número puro entre -1 y 1 que resume la fuerza de la relación. Una correlación de 1 indica una relación de línea recta perfecta con inclinación hacia arriba; una correlación de -1 indica una relación de línea recta perfecta con inclinación hacia abajo (negativa). La correlación le indica qué tan cerca están los puntos de estar exactamente en una línea recta inclinada, pero no le dice qué tan inclinada es esa línea. La fórmula para el coeficiente de correlación es:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{n\sqrt{\sigma_x^2 \sigma_y^2}} = \frac{\text{cov}(x, y)}{\sqrt{\sigma_x^2 \sigma_y^2}} \quad (36)$$

La covarianza de X e Y es el numerador en la fórmula del coeficiente de correlación.

La correlación no es causalidad. El coeficiente de correlación resume la asociación entre los números, pero no puede explicarla. La correlación puede deberse a que la variable X afecta a Y, que la variable Y afecta a X, o a la existencia de un tercer factor oculto que afecta tanto a X como a Y, haciendo que parezcan estar asociados. El término correlación espuria se refiere a una correlación alta que en realidad se debe a este tercer factor (Siegel & Wagner, 2022).

6.1.1 Matriz de correlación


Cuando se analizan más de 2 variables ($n > 2$) se utiliza la matriz de correlación R , que es una matriz cuadrada constituida por los coeficientes de correlación de cada pareja de variables; de manera que tendrá unos en su diagonal principal, y en los elementos no diagonales los correspondientes coeficientes de correlación r_{ij} entre las variables. De esta forma, la matriz de correlación será simétrica, y conservará las propiedades de ser definida-positiva y tener un determinante no negativo menor o igual que 1, tal como se muestra a continuación (Reed & Rodriguez-Herrera, 2019):

$$R = \begin{pmatrix} 1 & r_{12} & \dots & r_{1n} \\ r_{21} & 1 & \dots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{n1} & r_{n2} & \dots & 1 \end{pmatrix}$$

6.1.2 *Análisis mediante matriz de correlación*

La Figura 32 muestra la matriz de correlación obtenida a partir del análisis realizado entre los parámetros multifractales de las variables relacionadas con los vientos de Santa Ana y las características fisiográficas de altitud, latitud y longitud. Para esto, se utilizaron los valores obtenidos del análisis multifractal. Para el análisis de la matriz se utilizarán los rangos y tipos de correlación mostrados en la Tabla 8.

Figura 32. Matriz de correlación de parámetros multifractales.



De acuerdo a la matriz de correlación de la Figura 32, la longitud presenta una fuerte correlación negativa con el parámetro de hq de la humedad relativa, de igual forma con el hq de la velocidad del viento la correlación es significativa y negativa, relaciones que se explican debido a la misma dinámica del fenómeno que empieza en tierra y finaliza en el mar con la formación de neblina en este y a que son variables que reflejan cambios cuando dicho fenómeno ocurre, altera su comportamiento. En cuanto al valor de hq de la presión y la dirección del viento, presenta una relación positiva y débil con la longitud es decir cambia de este a oeste, y esto se debe al relieve de la región y a que estas variables están dominadas también por las características orográficas de la región, muchas veces su comportamiento obedece a la geografía de la zona. Mientras que el hq de la temperatura es afectada por latitud de forma negativa. Análisis que se profundizaron en el capítulo anterior.

Con respecto al valor de los anchos de los espectros y la variable latitud, las correlaciones son negativas en todos los casos y débil con las variables de temperatura, humedad relativa, presión y dirección del viento; siendo la relación con la velocidad del viento la única con un valor moderado.

Con respecto a la velocidad del viento y la humedad relativa la relación con la longitud y la altitud es negativa y es moderada, lo que se traduce en que los cambios de elevación de la cuenca afectan el comportamiento de los vientos de Santa Ana en la zona.

En cuanto a los valores de las asimetrías las correlaciones entre las variables de temperatura, velocidad del viento, dirección del viento, humedad relativa y presión varían de nulas a débiles, siendo la correlación entre la velocidad del viento la más representativa con respecto a los valores geográficos.

Para el caso de los valores de α_0 la humedad relativa, la velocidad del viento y la presión con respecto a la altitud poseen correlaciones inversas y significativas para el caso de las dos primeras variables mencionadas y débil en el caso de la presión; como se observó en los mapas de espacialización de α_0 la humedad relativa y la velocidad del viento sus valores aumentaban a medida que la altitud disminuía y viceversa; evidenciando la fina estructura de estos procesos y que la altura también afecta el comportamiento de estas variables en la misma zona de estudio.

Dentro de la matriz de correlación, Figura 32, las correlaciones más significativas que se encontraron fueron las siguientes: df y hq ; que es evidente al tener en cuenta que el cálculo de la dimensión fractal se realizó a partir del hq , por lo cual existe una correlación entre estos valores para todas las variables climáticas en estudio. De forma similar ocurre con el valor del α_{min} con respecto a la df y hq de las cinco variables analizadas, presentan correlaciones perfectas positivas con los hq y negativas con las df ; debido a que el espectro multifractal se genera a partir de los hq de ahí a su gran correlación, lo que indica que los eventos extremos de este proceso están relacionados con el exponente de Holder y la dimensión fractal; el mismo caso ocurre con los α_0 para todas las variables analizadas, pero para el caso de los α_{max} no todas las variables presentan relaciones significativas con los hq y df ; el valor de α_{max} esta relacionado con el evento más suave del proceso.

Con respecto a los valores del ancho del espectro ($\Delta\alpha$) se esperaría que la correlación fuera directa con los valores de los α_{max} y los α_{min} al ser estimada a partir de estos pero cada variable se relaciona con diferente intensidad con estos valores; la temperatura tiene una correlación positiva con el α_{max} , la velocidad del viento tiene una correlación negativa con el α_{min} y la presión tiene una correlación positiva con el α_{max} ; paralelo a esto la dirección

del viento y la humedad relativa tienen correlación positiva con el α_{max} y negativa con el α_{min} . En el caso de la asimetría (r) la presión y la dirección del viento no tienen una correlación lineal con el α_{max} y el α_{min} ; la asimetría de la velocidad del viento es la única que guarda correlación con el α_{min} y el α_{max} ; en el caso de la temperatura y la humedad relativa tienen correlación positiva con el α_{max} .

Adicionalmente entre se evidenciaron correlaciones entre variables como algunos parámetros multifractales de la humedad relativa y la velocidad del viento, la dirección del viento y la temperatura, la humedad relativa y la presión, la dirección del viento y la presión; lo que evidencia que los vientos de Santa Ana influyen en la dinámica climática de la región y que el comportamiento de una variable puede variar positiva o negativa con respecto a otra por ejemplo el parámetro ancho de la velocidad del viento y la dirección del viento ($\Delta\alpha$) posee una correlación positiva moderada con el α_0 de la temperatura es decir la predicción de la velocidad y la dirección del viento está relacionada linealmente con la temperatura en temporada de Santa Ana; así mismo sucede con la humedad relativa y la presión; y con la dirección del viento y la presión. Resultados que reflejan las características de los Vientos de Santa Ana: altas velocidades del viento, dirección del viento del noreste, baja humedad relativa y un fuerte gradiente de presión entre la Gran Cuenca y la costa de California, que a su vez se ve condicionado con la compleja topografía de la zona creando escenarios donde los vientos pueden entrar en remolinos o embudos hacia pasos de montaña y cañones, lo que obliga a variaciones locales en el flujo de viento de Santa Ana (Dye et al., 2020).

6.2 Análisis multicriterio

El análisis multicriterio (AMC) es un conjunto de métodos y técnicas utilizados para evaluar y tomar decisiones en situaciones complejas donde múltiples criterios o factores deben ser considerados. Este enfoque es particularmente útil en la toma de decisiones que involucran trade-offs entre diferentes objetivos que pueden ser conflictivos o no directamente comparables (Keeney & Raiffa, 1993)

En un análisis multicriterio intervienen más de dos criterios para tomar una decisión ante una problemática o modelación. Estos pueden ser de dos tipos: factores y restricciones (Morales Carranza, 2022).

- Un factor es un criterio que alza o reduce la viabilidad de una alternativa específica y se expresa en una escala continua.
- Una restricción es un criterio de exclusión que permite limitar las alternativas bajo consideración y adopta únicamente dos valores, los cuales son: (0 y 1) o (SI/NO).

A los criterios determinados se les aplica una regla de decisión, que es el proceso por el cual dos criterios son seleccionados y combinados para conseguir una evaluación determinada (Morales Carranza, 2022).

6.2.1 Reclasificación

Las reglas de decisión deben estructurarse en el contexto del objetivo específico perseguido, que en el caso de esta investigación son la determinación de las zonas más predecibles a partir del parámetro multifractal del ancho y la asimetría para las cinco variables asociadas a los vientos de Santa Ana: temperatura, humedad relativa, presión, velocidad y dirección del viento.

Se evalúa cada criterio concerniente al mismo, para después crear los mapas en formato ráster, con los cuales se determinan los objetivos previstos para el análisis multicriterio.

Para ello es necesario hacer una reclasificación de las variables de los ráster creados, con base a los criterios seleccionados. A cada celda del ráster se le asigna un valor de salida de 0 o 1 basado en los criterios técnicos, si el criterio cumple el valor de salida asignado es 1, y en caso contrario su valor asignado es 0 (Morales Carranza, 2022).

6.2.2 *Álgebra de mapas*

El álgebra de mapas consiste en el proceso de datos geográficos a través de la integración de capas cartográficas para el diseño de esquemas de análisis de datos espaciales a través de la aplicación de un conjunto de operadores que transforma una serie de entradas en una serie de salidas, dando como resultado la identificación de zonas poseedoras de ciertos rasgos de interés.

El álgebra de mapas permite tener acceso a herramientas, operadores, funciones y clases de análisis espacial a través del álgebra. En su forma más básica, se especifica un ráster de salida a la izquierda de un signo igual (=) y las herramientas, operaciones y sus parámetros a la derecha (ESRI, 2021b).

La calculadora de capas ráster (o simplemente calculadora ráster) está creada para ejecutar expresiones algebraicas utilizando varias herramientas y operadores mediante la interfaz de la herramienta de una calculadora simple (herramienta Raster Calculator). El rendimiento de las ecuaciones depende de las herramientas u operadores participantes en una

expresión. En general, el procesamiento de los datos es más rápido si se ejecutan cada uno de los operadores o herramientas de forma individual (ESRI, 2021a). La versatilidad del álgebra de mapas radica en su sencillez y potencia para realizar análisis geográfico (Pucha-Cofrep et al., 2017)

El álgebra de mapas puede ejecutar declaraciones simples, pero la potencia del lenguaje es evidente al crear declaraciones y modelos complejos. En los Sistemas de Información Geográfica existen tres maneras de utilizar álgebra de mapas:

- I. La herramienta calculadora ráster o calculadora de mapas.
- II. La ventana de Python.
- III. Su entorno de desarrollo integrado Python

Para esta investigación se utiliza la calculadora de mapas o ráster, esta herramienta ejecuta las expresiones del álgebra de mapas, es decir operadores de suma, resta, multiplicación, división e incluso booleanos (*AND*, *OR*, *NOT*). La herramienta tiene una interfaz de calculadora fácil de utilizar desde la cual se crean la materia de las declaraciones del álgebra de mapas simplemente al hacer clic en botones (Morales Carranza, 2022).

6.2.3 Solución del análisis multicriterio

Una vez concluida las reclasificaciones de las capas, mapas o rásteres para cada uno de los criterios técnicos seleccionados, se combinan utilizando el operador multiplicación o el booleano “*AND*”, con la ayuda de la herramienta calculadora de mapas o ráster, mencionada anteriormente (Morales Carranza, 2022). Al realizar el álgebra de mapas con la calculadora ráster, se obtiene un mapa final, en el cual se muestra la combinación de factores que intervienen en el análisis.

6.2.4 *Reclasificación de parámetros multifractales*

A los mapas de asimetría y de ancho del espectro de las variables de temperatura, presión, humedad relativa, velocidad y dirección del viento se les hizo reclasificación.

La reclasificación consiste en dar valores binarios de 0 y 1 a cada una de las celdas dentro de los modelos generados para cada variable de Santa Ana analizada. Se plantearon dos escenarios para el parámetro ancho del espectro ($\Delta\alpha$):

1) valores $\Delta\alpha > 0.4$, se les asigna el valor de 0 (cero), es decir zonas menos predecibles que corresponde a valores del espectro con valores grandes que corresponde a una situación *NEGATIVA (NO)*; y el valor de 1 (uno) para $\Delta\alpha < 0.4$, es decir zonas más predecibles, que corresponde cuando el criterio es una situación *POSITIVA (SI)*.

2) valores de $\Delta\alpha > 0.5$, se les asigna el valor de 0 (cero), es decir zonas menos predecibles que corresponde a valores del espectro con valores grandes que corresponde a una situación *NEGATIVA (NO)*; y el valor de 1 (uno) para $\Delta\alpha < 0.5$, es decir zonas más predecibles, que corresponde cuando el criterio es una situación *POSITIVA (SI)*.

Para el parámetro de la asimetría (r) se consideraron las siguientes condiciones para asignar el nuevo número (binario): 1) $r > 1$ donde el valor es 1 (uno) el criterio corresponde a una situación *POSITIVA (SI)* y $r < 1$, asimetrías a la izquierda, donde el valor es 0 (cero), es decir zonas donde predominan las pequeñas fluctuaciones, que corresponde a una situación *NEGATIVA (NO)*.

Con los parámetros y criterios de reclasificación mencionados anteriormente, se pasa al programa ArcMap 10.5 de ArcGIS donde están los mapas de los parámetros multifractales

de las variables de los vientos de Santa Ana y se generan los nuevos ráster de reclasificación que se pueden observar en las Figura 33, Figura 34 y Figura 35.

Al hacer la reclasificación de los anchos del espectro $\Delta\alpha < 0.4$, no todas las variables cumplen con este criterio o tienen valores dentro de ese rango, solo la temperatura, presión y dirección del viento cuentan con zonas dentro de este rango de valores; la humedad relativa y la velocidad del viento no cuentan con valores de anchos con este valor por lo que son descartadas para el algebra de mapas.

En el caso de los anchos del espectro, $\Delta\alpha < 0.5$, todas las variables tienen valores en ese rango. Lo mismo ocurre para los valores de las asimetrías.




Figura 33. Mapas de reclasificación para el parámetro del $\Delta\alpha$ para valores < 0.4 el primer escenario la variable de a) temperatura, b) presión y c) dirección del viento.




Figura 34. Mapas de reclasificación para el parámetro del $\Delta\alpha$ para valores < 0.5 de la variable de a) temperatura, b) humedad relativa, c) presión, d) dirección del viento y e) velocidad del viento.




Figura 35. Mapas de reclasificación para el parámetro del r para la variable de a) temperatura, b) humedad relativa, c) presión, d) dirección del viento y e) velocidad del viento.

Luego de la reclasificación de mapas, para ubicar las zonas más predecibles para las variables de vientos de Santa Ana en la cuenca de Guadalupe se realiza el álgebra de mapas superponiendo todas las capas reclasificadas de los rubros de interés (los anchos de las variables de temperatura, humedad relativa, dirección del viento, velocidad del viento y presión) con ayuda de la calculadora ráster, herramienta del *ArcMap* 10.5 de *ArcGIS*.

Se ejecuta una multiplicación de los valores en cada una de las celdas que contiene cada capa ráster involucrada; los valores de las celdas al haber sido reclasificadas son números binarios (0 y 1); si el producto final es igual a 1, se sombrea la celda dando lugar a las áreas más predecibles de la cuenca, por el contrario, si el producto es 0, se deja en blanco o sin sombreado, dando a entender que esa zona es más compleja de predecir debido a su multifractalidad. La Figura 36 muestra los resultados para $\Delta\alpha < 0.4$ y la Figura 37 para $\Delta\alpha < 0.5$. Al contrastar los dos escenarios, para los anchos menores a 0.4, el área climática más predecible es la cercana a la estación 2021-El Pinal, que es la segunda en altitud en la cuenca y hace parte de la subcuenca del Valle de Guadalupe; además tiene más extensión con respecto al área que se estima para $\Delta\alpha < 0.5$ donde la zona más predecible es un área mínima de la subcuenca de la Misión, cercana a una topografía no tan elevada; en este escenario esta predominando el criterio del ancho de espectro de la velocidad del viento de las estaciones 2001-Agua Caliente y 2114-Ejido Carmen Serdán. Al revisar la matriz de correlación de los anchos de los espectros la velocidad del viento tiene correlaciones débiles con la presión y la dirección del viento, pero tiene una correlación moderada e inversa con la latitud lo que explica porque en el escenario de los anchos de los espectros <0.5 , la zona más predecible esta más al oeste.




Figura 36. Mapa con el área más predecible de las variables de temperatura, presión y dirección del viento para $\Delta\alpha < 0.4$.

Al aplicar el álgebra de mapa, limitando los valores de los anchos del espectro a valores <0.4 , la humedad relativa y la velocidad del viento presentan mayor multifractalidad frente a la temperatura, la presión y la dirección del viento por lo que al cruzar la información de la reclasificación de los mapas de esas variables la zona con menor multifractalidad es la región cercana a la estación El Pinal (2021), es decir en esa área la predicción climática es más probable que sea predecible frente a las demás áreas de la cuenca. Lo interesante de este ejercicio es que al aumentar o disminuir el rango del espectro las áreas se van modificando y moviéndose internamente dentro de la cuenca reflejando esa variabilidad en la zona y como la multifractalidad también varía a nivel de estaciones en la cuenca, que hay una

heterogeneidad, no varía de manera homogénea la multifractalidad en la cuenca; de lo que se puede deducir que las zonas de producción agrícola de la región están en áreas donde predecir el clima para condiciones de vientos de Santa Ana es más compleja, es decir corresponde a zonas donde es más difícil de hacer predicciones certeras o más confiables.




Figura 37. Mapa de zona más predecible de acuerdo a los anchos de los espectros de las variables de temperatura, humedad relativa, presión, dirección y velocidad del viento para $\Delta\alpha < 0.5$.

Para el caso de las asimetrías, los valores $r < 1$ esta asociada a exponentes fractales bajos de pesos pequeños, lo que sugiere el predominio de grandes fluctuaciones, que pueden estar relacionadas con eventos extremos. Para el caso de $r > 1$, denota exponentes fractales

altos con pesos grandes, que son característicos de estructuras finas e indican un predominio relativo de las pequeñas fluctuaciones, que se observan en la Figura 38, los valores de asimetrías en general todas fueron espectros con ramas sesgadas a la derecha, solo algunas variables en algunas estaciones tuvieron valores $r < 1$, por lo que se puede afirmar que la multifractalidad en la cuenca se desarrolla por las pequeñas fluctuaciones en todas las variables analizadas.




Figura 38. Mapa de las zonas con asimetrías $r > 1$ para las variables de los vientos de Santa Ana.

7 Conclusiones Generales

A partir del análisis fractal y multifractal de las series de temperatura, presión, humedad relativa, velocidad y dirección del viento asociado a los vientos de Santa Ana en la cuenca hidrográfica de Guadalupe se pueden establecer las siguientes conclusiones:

- Las series de tiempo climáticas asociadas a los vientos de Santa Ana han exhibido fractalidad y multifractalidad en los momentos estadísticos analizados.
- Las variables de presión y humedad relativa han mostrado persistencia en ambos análisis en general; para el caso de las variables de temperatura, velocidad y dirección del viento su comportamiento es antipersistente reflejando las variaciones asociadas a los vientos de Santa Ana.
- De los mapas de geospacialización y la matriz de correlación de las variables climáticas en estudio, se observó y confirmó que existen correlaciones entre estas.
- El análisis fractal y multifractal confirmaron zonas dentro de la cuenca donde son más impredecibles ciertas variables y zonas donde son más predecibles. Evidenciando que el clima a nivel local predomina sobre los cambios a nivel regional.
- El estudio de la multifractalidad en series de tiempo meteorológicas ofrece una visión profunda de la complejidad inherente a los sistemas climáticos. La caracterización de estas propiedades puede mejorar significativamente la modelización y predicción de fenómenos meteorológicos, contribuyendo a una mejor preparación y mitigación de eventos extremos.

- La multifractalidad es una propiedad importante de las series de tiempo de variables climáticas que tiene diversas aplicaciones en la comprensión de los patrones climáticos, la predicción del clima y la detección de cambios climáticos.
- Los resultados producto de este tipo de investigaciones sirven como una herramienta base para generar iniciativas en cuanto a tener una legislación para el manejo de eventos extremos como los vientos de Santa Ana en la región en aras de mitigar los efectos causados por estos, tal es el caso de generar sistemas de alertas tempranas y planes de contingencia para minimizar el impacto de estos sobre la infraestructura como el caso de los postes de luz.
- El análisis multifractal de los vientos de Santa Ana en la cuenca de Guadalupe permite entender como se distribuye en tiempo y espacio este fenómeno lo cual es fundamental para la gestión de los recursos en la cuenca de Guadalupe; zona relevante para la región al ser un área vitivinícola y de uso agrícola; además que estos estudios son esenciales para la planificación de la infraestructura física de la zona y para una mejor explotación de los recursos de la zona como es el caso del viento para generar energía eólica.
- El pronóstico de condiciones de Santa Ana por medio de redes neuronales recurrentes genera predicciones más confiables, lo que se traduce en una mejor gestión de emergencias, una mejor asignación y distribución de los recursos físicos y humanos para atender estas; planificación en caso de requerirse evacuaciones. También implica una gestión eficiente de los incendios forestales asociados a esta condición al poder anticipar la intensidad de estos, permitiendo una mejor planificación y respuesta a estas situaciones.

8 Referencias

- Abatzoglou, J. T., Barbero, R., & Nauslar, N. J. (2013). Diagnosing Santa Ana Winds in Southern California with Synoptic-Scale Analysis. *Weather and Forecasting*, 28(3), 704–710. <https://doi.org/10.1175/WAF-D-13-00002.1>
- Adarsh, S., Nourani, V., Archana, D. S., & Dharan, D. S. (2020). Multifractal description of daily rainfall fields over India. *Journal of Hydrology*, 586(April), 124913. <https://doi.org/10.1016/j.jhydrol.2020.124913>
- Aguilar-Molina, A. M., Angulo-Brown, F., & Muñoz-Diosdado, A. (2019). Multifractal spectrum curvature of RR tachograms of healthy people and patients with congestive heart failure, a new tool to assess health conditions. *Entropy*, 21(6), 13–15. <https://doi.org/10.3390/e21060581>
- Akinsusi, J., Ogunjo, S., & Fuwape, I. (2022). Nonlinear dynamics and multifractal analysis of minimum–maximum temperature and solar radiation over Lagos State, Nigeria. *Acta Geophysica*, 70(5), 2171–2178. <https://doi.org/10.1007/s11600-022-00879-4>
- Álvarez, C. A., & Carbajal, N. (2019). Regions of influence and environmental effects of Santa Ana wind event. *Air Quality, Atmosphere and Health*, 12(9), 1019–1034. <https://doi.org/10.1007/s11869-019-00719-3>
- Anshul Jindal. (2019). Dimensionality Reduction using PCA on multivariate timeseries data. Retrieved May 17, 2021, from <https://medium.com/@ansjin/dimensionality-reduction-using-pca-on-multivariate-timeseries-data-b5cc07238dc4>
- Balkissoon, S., Fox, N., & Lupo, A. (2020). Fractal characteristics of tall tower wind speeds in Missouri. *Renewable Energy*, 154, 1346–1356.

<https://doi.org/10.1016/j.renene.2020.03.021>

- Baranowski, P., Gos, M., Krzyszczak, J., Siwek, K., Kieliszek, A., & Tkaczyk, P. (2019). Multifractality of meteorological time series for Poland on the base of MERRA-2 data. *Chaos, Solitons and Fractals*. <https://doi.org/10.1016/j.chaos.2019.07.008>
- Billmire, M., French, N. H. F., Loboda, T., Owen, R. C., & Tyner, M. (2014). Santa Ana winds and predictors of wildfire progression in southern California. *International Journal of Wildland Fire*, 23(8), 1119–1129. <https://doi.org/10.1071/WF13046>
- Broday, D. M. (2010). Studying the Time Scale Dependence of Environmental Variables Predictability Using Fractal Analysis. *Environmental Science & Technology*, 44(12), 4629–4634. <https://doi.org/10.1021/es903495q>
- Caldeira, R., Fernández, I., & Pacheco, J. M. (2007). On NAO's predictability through the DFA method. *Meteorology and Atmospheric Physics*, 96(3–4), 221–227. <https://doi.org/10.1007/s00703-005-0182-3>
- Cao, Y. (2015). *The Santa Ana Winds of Southern California in the context of Fire Weather*. University of California.
- Cao, Y., & Fovell, R. G. (2016). Downslope windstorms of San Diego County. Part I: A case study. *Monthly Weather Review*, 144(2), 529–552. <https://doi.org/10.1175/MWR-D-15-0147.1>
- Castro, R. (2003). Evolución y extensión de los vientos Santa Ana de febrero de 2002 en el océano , frente a California y la Península de Baja California Evolution and extension of the Santa Ana winds of February 2002 over the ocean , off California and the Baja California , 29(February 2002), 275–281.

- Chhetri, M., Kumar, S., Roy, P. P., & Kim, B. G. (2020). Deep BLSTM-GRU model for monthly rainfall prediction: A case study of Simtokha, Bhutan. *Remote Sensing*, 12(19), 1–13. <https://doi.org/10.3390/rs12193174>
- Conil, S., & Hall, A. (2006). Local regimes of atmospheric variability: A case study of Southern California. *Journal of Climate*, 19(17), 4308–4325. <https://doi.org/10.1175/JCLI3837.1>
- da Silva, H. S., Silva, J. R. S., & Stosic, T. (2020). Multifractal analysis of air temperature in Brazil. *Physica A: Statistical Mechanics and Its Applications*, 549, 124333. <https://doi.org/10.1016/j.physa.2020.124333>
- de Lima, M. I. P., & Grasman, J. (1999). Multifractal analysis of 15-min and daily rainfall from a semi-arid region in Portugal. *Journal of Hydrology*, 220(1), 1–11. [https://doi.org/10.1016/S0022-1694\(99\)00053-0](https://doi.org/10.1016/S0022-1694(99)00053-0)
- Deo, R. C., & Şahin, M. (2015). Application of the Artificial Neural Network model for prediction of monthly Standardized Precipitation and Evapotranspiration Index using hydrometeorological parameters and climate indices in eastern Australia. *Atmospheric Research*, 161–162, 65–81. <https://doi.org/10.1016/j.atmosres.2015.03.018>
- Devi, R. R., & Chattopadhyay, S. (2023). A modified multifractal detrended fluctuation analysis to study the precipitation across northeast India. *Dynamics of Atmospheres and Oceans*, 104(June), 101402. <https://doi.org/10.1016/j.dynatmoce.2023.101402>
- Diego, J. M., Martínez-González, E., Sanz, J. L., Mollerach, S., & Martínez, V. J. (1999). Partition function based analysis of cosmic microwave background maps. *Monthly Notices of the Royal Astronomical Society*, 306(2), 427–436.

<https://doi.org/10.1046/j.1365-8711.1999.02523.x>

Diodato, N., de Guenni, L. B., Garcia, M., & Bellocchi, G. (2019). Decadal oscillation in the predictability of Palmer Drought Severity Index in California. *Climate*, 7(1). <https://doi.org/10.3390/cli7010006>

Dos Santos, F. S., Do Nascimento, K. K. F., Jale, J. S., Xavier, S. F. A., & Ferreira, T. A. E. (2023). Multifractal analysis of solar radiation in the northeastern region of Brazil. *Fractals*, 31(3), 1–11. <https://doi.org/10.1142/S0218348X23500263>

Dye, A. W., Kim, J. B., & Riley, K. L. (2020). Spatial heterogeneity of winds during Santa Ana and non-Santa Ana wildfires in Southern California with implications for fire risk modeling. *Heliyon*, 6(6), e04159. <https://doi.org/10.1016/j.heliyon.2020.e04159>

Edinger, J. G., Helvey, R. A., & Baumhefner, D. P. (1964). SURFACE WIND PATTERNS IN THE LOS ANGELES BASIN DURING “SANTA ANA” CONDITIONS. Retrieved from <https://api.semanticscholar.org/CorpusID:128375981>

ESRI. (2021a). Cómo funciona Calculadora ráster. Retrieved from <https://desktop.arcgis.com/es/arcmap/latest/tools/spatial-analyst-toolbox/building-expressions-in-raster-calculator.htm>

ESRI. (2021b). Un recorrido rápido por el uso de Álgebra de mapas en Spatial Analyst—ArcMap | Documentación. Retrieved July 9, 2024, from <https://desktop.arcgis.com/es/arcmap/latest/extensions/spatial-analyst/map-algebra/a-quick-tour-of-using-map-algebra.htm>

García-Marín, A. P., Estévez, J., Jiménez-Hornero, F. J., & Ayuso-Muñoz, J. L. (2013). Multifractal analysis of validated wind speed time series. *Chaos: An Interdisciplinary*

Journal of Nonlinear Science, 23(1), 13133. <https://doi.org/10.1063/1.4793781>

Glickman, T. S., & American Meteorological Society. (2000). *Glossary of Meteorology*. (A. M. Society, Ed.) (2nd ed.).

Gómez-Gómez, J., Ariza-Villaverde, A. B., Gutiérrez de Ravé, E., & Jiménez-Hornero, F. J. (2023). Relationships between Reference Evapotranspiration and Meteorological Variables in the Middle Zone of the Guadalquivir River Valley Explained by Multifractal Detrended Cross-Correlation Analysis. *Fractal and Fractional*, 7(1). <https://doi.org/10.3390/fractalfract7010054>

Gómez-Gómez, J., Carmona-Cabezas, R., Sánchez-López, E., de Ravé, E., & Jiménez-Hornero, F. J. (2022). Multifractal fluctuations of the precipitation in Spain (1960–2019). *Chaos, Solitons & Fractals*, 157, 111909. <https://doi.org/10.1016/j.chaos.2022.111909>

Gómez-Gómez, J., Plocoste, T., Alexis, E., Jiménez-Hornero, F. J., Gutiérrez de Ravé, E., & Nuiro, S. P. (2023). Multifractal detrended fluctuation analysis of rainfall time series in the Guadeloupe archipelago. *Journal of Hydrology*, 626(October). <https://doi.org/10.1016/j.jhydrol.2023.130377>

Grassberger, P. (1981). On the Hausdorff dimension of fractal attractors. *Journal of Statistical Physics*, 26(1), 173–179. <https://doi.org/10.1007/BF01106792>

Guzman-Morales, J., Gershunov, A., Theiss, J., Li, H., & Cayan, D. (2016). Santa Ana Winds of Southern California: Their climatology, extremes, and behavior spanning six and a half decades, 2827–2834. <https://doi.org/10.1002/2016GL067887>.Received

Harrouni, S., & Guessoum, A. (2009). Using fractal dimension to quantify long-range

- persistence in global solar radiation. *Chaos, Solitons and Fractals*, 41(3), 1520–1530.
<https://doi.org/10.1016/j.chaos.2008.06.016>
- Hughes, M., & Hall, A. (2010). Local and synoptic mechanisms causing Southern California's Santa Ana winds. *Climate Dynamics*, 34(6), 847–857.
<https://doi.org/10.1007/s00382-009-0650-4>
- Hurst, H. E. (1951). Long-Term Storage Capacity of Reservoirs. *Transactions of the American Society of Civil Engineers*, 116(1), 770–799.
<https://doi.org/10.1061/TACEAT.0006518>
- Hurst, H. E. (1956). Methods of Using Long-Term Storage in Reservoirs. *Proceedings of the Institution of Civil Engineers*, 5(5), 519–543. <https://doi.org/10.1680/iicep.1956.11503>
- Jaroszewicz, S., Mariani, M. C., Tweneboah, O. K., & Beccar-Varela, M. P. (2024). Multifractal analysis of the Southern Oscillation Index. *Journal of Atmospheric and Solar-Terrestrial Physics*, 254(October 2023), 106161.
<https://doi.org/10.1016/j.jastp.2023.106161>
- Jiang, L., Zhang, J., Liu, X., & Li, F. (2016). Multifractal scaling comparison of the air temperature and the surface temperature over China. *Physica A: Statistical Mechanics and Its Applications*, 462, 783–792. <https://doi.org/10.1016/j.physa.2016.06.048>
- Jiménez-Carrión, M., Gutiérrez-Segura, F., & Celi-Pinzón, J. (2018). Modeling and prediction of el niño in piura using artificial neuronal networks. *Informacion Tecnologica*, 29(4), 303–318. <https://doi.org/10.4067/s0718-07642018000400303>
- Jonah, K., Wen, W., Shahid, S., Ali, M. A., Bilal, M., Habtemicheal, B. A., ... Tiwari, P. (2021). Spatiotemporal variability of rainfall trends and influencing factors in Rwanda.

- Journal of Atmospheric and Solar-Terrestrial Physics*, 219(November 2020), 105631.
<https://doi.org/10.1016/j.jastp.2021.105631>
- Jones, C., Fujioka, F., & Carvalho, L. M. V. (2010). Forecast skill of synoptic conditions associated with Santa Ana winds in Southern California. *Monthly Weather Review*, 138(12), 4528–4541. <https://doi.org/10.1175/2010MWR3406.1>
- Kalamaras, N., Philippopoulos, K., Deligiorgi, D., Tzanis, C. G., & Karvounis, G. (2017). Multifractal scaling properties of daily air temperature time series. *Chaos, Solitons and Fractals*, 98, 38–43. <https://doi.org/10.1016/j.chaos.2017.03.003>
- Kantelhardt, J. W., Zschiegner, S. A., Koscielny-Bunde, E., Havlin, S., Bunde, A., & Stanley, H. E. (2002). Multifractal detrended fluctuation analysis of nonstationary time series. *Physica A*, 316(1–4), 87–114. [https://doi.org/10.1016/S0378-4371\(02\)01383-3](https://doi.org/10.1016/S0378-4371(02)01383-3)
- Keeney, R. L., & Raiffa, H. (1993). *Decisions with Multiple Objectives: Preferences and Value Trade-Offs*. Cambridge University Press.
- Korvin, G., Boyd, D. M., & O'Dowd, R. (1990). Fractal characterization of the South Australian gravity station network. *Geophysical Journal International*, 100(3), 535–539. <https://doi.org/10.1111/j.1365-246X.1990.tb00705.x>
- Kreuzer, D., Munz, M., & Schlüter, S. (2020). Short-term temperature forecasts using a convolutional neural network — An application to different weather stations in Germany. *Machine Learning with Applications*, 2(September), 100007. <https://doi.org/10.1016/j.mlwa.2020.100007>
- Krzyszczak, J., Baranowski, P., Zubik, M., Kazandjiev, V., Georgieva, V., Sławiński, C., ... Nieróbca, A. (2019). Multifractal characterization and comparison of meteorological

- time series from two climatic zones. *Theoretical and Applied Climatology*, 137(3–4), 1811–1824. <https://doi.org/10.1007/s00704-018-2705-0>
- Laib, M., Golay, J., Telesca, L., & Kanevski, M. (2018). Multifractal analysis of the time series of daily means of wind speed in complex regions. *Chaos, Solitons and Fractals*, 109, 118–127. <https://doi.org/10.1016/j.chaos.2018.02.024>
- Li, M., Xia, J., & Meng, D. (2012). DFA based predictability indices analysis of climatic dynamics in Beijing area, China, 382, 60–64. <https://doi.org/10.4028/www.scientific.net/AMR.382.60>
- Lima, M. I. P. de. (1998). *Multifractals and the temporal structure of rainfall*. Wageningen Agricultural University.
- Liu, Z., Xu, J., Chen, Z., Nie, Q., & Wei, C. (2014). Multifractal and long memory of humidity process in the Tarim River Basin. *Stochastic Environmental Research and Risk Assessment*, 28(6), 1383–1400. <https://doi.org/10.1007/s00477-013-0832-9>
- López-Lambraño, A. A., Fuentes, C., López-Ramos, A. A., Mata-Ramírez, J., & López-Lambraño, M. (2018). Spatial and temporal Hurst exponent variability of rainfall series based on the climatological distribution in a semiarid region in Mexico. *Atmosfera*, 31(3), 199–219. <https://doi.org/10.20937/ATM.2018.31.03.02>
- López, A., Carrillo, E., Fuentes, C., López, A., & López, M. (2017). Una revisión de los métodos para estimar el exponente de Hurst y la dimensión fractal en series de precipitación y temperatura. *Revista Mexicana de Física*, 63(3), 244–267.
- López Lambraño, A. (2012). *Tesis de Doctorado: Análisis multifractal y modelación de la precipitación*. Universidad Autónoma de Querétaro.

- López Lambraño, A. A., Martínez, L., Gámez, E., Medrano, J. P., Remolina, J., & López Ramos, A. (2020). Supply and Demand Analysis of Water Resources . Case Study : Irrigation Water Demand in a Semi-Arid Zone in Mexico. *Agriculture*, 10(333), 20. <https://doi.org/10.3390/agriculture10080333>
- Mandelbrot, B. B. (1974). Intermittent turbulence in self-similar cascades: divergence of high moments and dimension of the carrier. *Journal of Fluid Mechanics*, 62(2), 331–358. <https://doi.org/10.1017/S0022112074000711>
- Maruyama, F., Kai, K., & Morimoto, H. (2017). Wavelet-based multifractal analysis on a time series of solar activity and PDO climate index. *Advances in Space Research*, 60(6), 1363–1372. <https://doi.org/10.1016/j.asr.2017.06.004>
- Méndez-Gordillo, A. R., & Cadenas, E. (2021). Wind speed forecasting by the extraction of the multifractal patterns of time series through the multiplicative cascade technique. *Chaos, Solitons and Fractals*, 143. <https://doi.org/10.1016/j.chaos.2020.110592>
- Meneveau, C., & Sreenivasan, K. R. (1991). The multifractal nature of turbulent energy dissipation. *J. Fluid Mech.*, 224, 429–484. https://doi.org/10.1007/978-3-642-84399-0_13
- Mianabadi, A., & Faridhosseini, A. (2011). The Investigation of Mashhad’s Heat Island by using Satellite Images and Fractal Theory (Box Counting method. Retrieved from <https://api.semanticscholar.org/CorpusID:128340386>
- Millán, H., Kalauzi, A., Cukic, M., & Biondi, R. (2010). Nonlinear dynamics of meteorological variables : multifractality and chaotic invariants in daily records from Pastaza , Ecuador, 75–85. <https://doi.org/10.1007/s00704-009-0242-6>

- Morales Carranza, G. (2022). *Redes Del Flujo Sub – Superficial Y Riesgo Geohidrológico En La Bahía Salsipuedes , Baja California , México* . Universidad Autónoma de Baja California.
- Muñoz-Diosdado, A., & Del Río-Correa, J. L. (2006). Further study of the asymmetry for multifractal spectra of heartbeat time series. *Conference Proceedings: ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2006*, 1450–1453. <https://doi.org/10.1109/IEMBS.2006.260166>
- Navarro-Olache, L. F., Castro, R., Durazo, R., Hernández-Walls, R., Mejía-Trejo, A., Flores-Vidal, X., & Flores-Morales, A. L. (2021). Influence of Santa Ana winds on the surface circulation of Todos Santos Bay, Baja California, Mexico. *Atmosfera*, 34(1), 97–109. <https://doi.org/10.20937/ATM.52719>
- Nguyen, M. H., Crawl, D., Li, J., Uys, D., & Altintas, I. (2018). Automated scalable detection of location-specific Santa Ana conditions from weather data using unsupervised learning, 1203–1212. <https://doi.org/10.1109/bigdata.2017.8258046>
- Pawelzik, K., & Schuster, H. G. (1987). Generalized dimensions and entropies from a measured time series. *Physical Review A*, 35(1), 481–484. <https://doi.org/10.1103/PhysRevA.35.481>
- Peñate, I., Martín-González, J. M., Rodríguez, G., & Cianca, A. (2013). Scaling properties of rainfall and desert dust in the Canary Islands. *Nonlinear Processes in Geophysics*, 20(6), 1079–1094. <https://doi.org/10.5194/npg-20-1079-2013>
- Philippopoulos, K., Kalamaras, N., Tzanis, C. G., Deligiorgi, D., & Koutsogiannis, I. (2019).

- Multifractal Detrended Fluctuation Analysis of Temperature Reanalysis Data over Greece. *Atmosphere*, 10(6), 336. <https://doi.org/10.3390/atmos10060336>
- Pucha-Cofrep, F., Fries, A., Cánovas-García, F., Oñate-Valdivieso, F., González-Jaramillo, V., & Pucha-Cofrep, D. (2017). *Fundamentos de SIG. Aplicaciones con ArcGIS*. Retrieved from www.acolita.com
- Rangarajan, G., & Sant, D. A. (1997). A climate predictability, 24(10), 1239–1242.
- Raphael, M. N. (2003). The Santa Ana Winds of California, 7, 1–13.
- Ratner, B. (2009). The correlation coefficient: Its values range between 1/1, or do they. *Journal of Targeting, Measurement and Analysis for Marketing*, 17(2), 139–142. <https://doi.org/10.1057/jt.2009.5>
- Reed, D., & Rodriguez-Herrera, A. (2019). Array Factor derived from a Correlation Matrix. *13th European Conference on Antennas and Propagation, EuCAP 2019*, 1–5.
- Rehman, S., & Siddiqi, A. H. (2009). Wavelet based correlation coefficient of time series of Saudi Meteorological Data. *Chaos, Solitons and Fractals*, 39(4), 1764–1789. <https://doi.org/10.1016/j.chaos.2007.06.054>
- Rehman, Shafiqur. (2009). Study of Saudi Arabian climatic conditions using Hurst exponent and climatic predictability index. *Chaos, Solitons and Fractals*, 39(2), 499–509. <https://doi.org/10.1016/j.chaos.2007.01.079>
- Rolinski, T., Capps, S. B., Fovell, R. G., Cao, Y., D’Agostino, B. J., & Vanderburg, S. (2016). The Santa Ana wildfire threat index: Methodology and operational implementation. *Weather and Forecasting*, 31(6), 1881–1897. <https://doi.org/10.1175/WAF-D-15->

- Rolinski, T., Capps, S. B., & Zhuang, W. (2019). Santa Ana Winds : A Descriptive Climatology. *Weather and Forecasting*, 34, 257–276. <https://doi.org/10.1175/WAF-D-18-0160.1>
- Sadegh Movahed, M., Jafari, G. R., Ghasemi, F., Rahvar, S., & Reza Rahimi Tabar, M. (2011). Erratum: Multifractal detrended fluctuation analysis of sunspot time series. *Journal of Statistical Mechanics: Theory and Experiment*, 2011(09), E09001. <https://doi.org/10.1088/1742-5468/2011/09/E09001>
- Sankaran, A., Plocoste, T., Geetha Raveendran Nair, A. N., & Mohan, M. G. (2024). Unravelling the Fractal Complexity of Temperature Datasets across Indian Mainland. *Fractal and Fractional*, 8(4). <https://doi.org/10.3390/fractalfract8040241>
- Sankaran, A., Plocoste, T., Nourani, V., Vahab, S., & Salim, A. (2023). Assessment of Multifractal Fingerprints of Reference Evapotranspiration Based on Multivariate Empirical Mode Decomposition. *Atmosphere*, 14(8), 1219. <https://doi.org/10.3390/atmos14081219>
- Santos, F. S. dos, Nascimento, K. K. F. do, Jale, J. da S., Stosic, T., Marinho, M. H. N., & Ferreira, T. A. E. (2021). Mixture distribution and multifractal analysis applied to wind speed in the Brazilian Northeast region. *Chaos, Solitons and Fractals*, 144. <https://doi.org/10.1016/j.chaos.2021.110651>
- Schwarz, L., Malig, B., Guzman-Morales, J., Guirguis, K., Ilango, S. D., Sheridan, P., ... Benmarhnia, T. (2020). The health burden fall, winter and spring extreme heat events in the in Southern California and contribution of Santa Ana Winds. *Environ. Res. Lett.*

15, 15. <https://doi.org/10.1088/1748-9326/ab7f0e>

Serpa-Usta, Y., López-Lambraño, A. A., Flores, D. L., Gámez-Balmaceda, E., Martínez-Acosta, L., Medrano-Barboza, J. P., ... López-Lambraño, M. (2022). Santa Ana Winds: Fractal-Based Analysis in a Semi-Arid Zone of Northern Mexico. *Atmosphere*, 13(1), 1–23. <https://doi.org/10.3390/atmos13010048>

Shang, P., & Kamae, S. (2005). Fractal nature of time series in the sediment transport phenomenon. *Chaos, Solitons & Fractals*, 26(3), 997–1007. <https://doi.org/https://doi.org/10.1016/j.chaos.2005.01.051>

Shi, H., Wei, A., Xu, X., Zhu, Y., Hu, H., & Tang, S. (2024). A CNN-LSTM based deep learning model with high accuracy and robustness for carbon price forecasting: A case of Shenzhen's carbon market in China. *Journal of Environmental Management*, 352(1), 120131. <https://doi.org/10.1016/j.jenvman.2024.120131>

Shimizu, Y. U., Thurner, S., & Ehrenberger, K. (2002). Multifractal spectra as a measure of complexity in human posture. *Fractals*, 10(1), 103–116. <https://doi.org/10.1142/S0218348X02001130>

Siegel, A. F., & Wagner, M. R. (2022). Chapter 11 - Correlation and Regression: Measuring and Predicting Relationships. In A. F. Siegel & M. R. Wagner (Eds.), *Practical Business Statistics (Eighth Edition)* (Eighth Edi, pp. 313–370). Academic Press. <https://doi.org/https://doi.org/10.1016/B978-0-12-820025-4.00011-7>

Sosa-ávalos, R., Durazo, R., & Mitchell, B. G. (2005). Efecto de los vientos Santa Ana en las propiedades bio-ópticas frente a Baja California Effect of Santa Ana winds on bio-optical properties off Baja California, 31, 339–348.

- Stosic, T., Stosic, B., Tošić, M., Lazić, I., Djurdjević, V., & Tošić, I. (2023). Climate Change Effects through MFDFA Study of Temperature in Serbia. *Atmosphere*, 14(10). <https://doi.org/10.3390/atmos14101532>
- Tan, X., & Gan, T. Y. (2017). Multifractality of Canadian precipitation and streamflow. *International Journal of Climatology*, 37(S1), 1221–1236. <https://doi.org/10.1002/joc.5078>
- Tatli, H. (2015). Detecting persistence of meteorological drought via the Hurst exponent, 769(November), 763–769. <https://doi.org/10.1002/met.1519>
- Telesca, L., Colangelo, G., Lapenna, V., & Macchiato, M. (2003). Monofractal and multifractal characterization of geoelectrical signals measured in southern Italy. *Chaos, Solitons and Fractals*, 18(2), 385–399. [https://doi.org/10.1016/S0960-0779\(02\)00655-0](https://doi.org/10.1016/S0960-0779(02)00655-0)
- Trasviña, A., Ortiz-Figueroa, M., Herrera, H., Cosío, M. A., & González, E. (2003). ‘ Santa Ana ’ winds and upwelling filaments off Northern Baja California, 37, 113–129. [https://doi.org/10.1016/S0377-0265\(03\)00018-6](https://doi.org/10.1016/S0377-0265(03)00018-6)
- Varotsos, C, & Kirk-Davidoff, D. (2006). Long-memory processes in ozone and temperature variations at the region 60°S–60°N. *Atmos. Chem. Phys.*, 6, 4093.
- Varotsos, Costas, Mazei, Y., Sarlis, N. V., Saldaev, D., & Efstathiou, M. (2024). On the Impacts of the Global Sea Level Dynamics. *Fractal and Fractional*, 8(1). <https://doi.org/10.3390/fractalfract8010039>
- Velásquez Valle, M. A., Medina García, G., Cohen, I. S., Klaudia Oleschko, L., Ruiz Corral, J. A., & Korvin, G. (2013). Spatial variability of the hurst exponent for the daily scale

- rainfall series in the state of zacatecas, Mexico. *Journal of Applied Meteorology and Climatology*, 52(12), 2771–2780. <https://doi.org/10.1175/JAMC-D-13-0136.1>
- Xiong, G., Yu, W., & Zhang, S. (2015). Singularity power spectrum distribution. *Physica A: Statistical Mechanics and Its Applications*, 431, 63–73. <https://doi.org/10.1016/j.physa.2015.02.025>
- Yang, Y., Cheng, Q., Tsou, J.-Y., Wong, K.-P., Men, Y., & Zhang, Y. (2023). Multiscale Analysis and Prediction of Sea Level in the Northern South China Sea Based on Tide Gauge and Satellite Data. *Journal of Marine Science and Engineering*, 11(6), 1203. <https://doi.org/10.3390/jmse11061203>
- Zamora, M., Lambert, A., & Montero, G. (2014). Effect of some meteorological phenomena on the wind potential of Baja California. *Energy Procedia*, 57, 1327–1336. <https://doi.org/10.1016/j.egypro.2014.10.086>
- Zeileke, T. B., & Bing, C. S. (2004). Scaling properties of topographic indices and crop yield: Multifractal and joint multifractal approaches. *Agronomy Journal*, 96(4), 1082–1090. <https://doi.org/10.2134/agronj2004.1082>
- Zeng, Z., Yang, H., Zhao, R., & Meng, J. (2013). Nonlinear characteristics of observed solar radiation data. *Solar Energy*, 87, 204–218. <https://doi.org/10.1016/j.solener.2012.10.019>
- Zhao, X., Shang, P., & Huang, J. (2017). Several fundamental properties of DCCA cross-correlation coefficient. *Fractals*, 25(2). <https://doi.org/10.1142/S0218348X17500177>

APÉNDICE A. GRAFICAS DE LOS ESPECTROS PARA CADA ESTACIÓN.

A continuación, se muestran las gráficas de la función de fluctuación, el exponente de Hurst, exponente de escalado de masa y el espectro multifractal para los días con vientos de Santa Ana de cada una de las estaciones para las variables de temperatura, humedad relativa, presión, velocidad del viento y dirección del viento para un q de orden de $-10, 10$.




Figura A 1. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10, q = 10$. Estación Agua Caliente.




Figura A 2. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 20 a 80 días.
Estación Agua Caliente




Figura A 3. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 20 a 80 días. Estación Agua Caliente.




Figura A 4. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100. días. Estación Agua Caliente.




Figura A 5. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100. Estación Agua Caliente.




Figura A 6. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100. Estación Ignacio Zaragoza Belén.




Figura A 7. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100. Estación Ignacio Zaragoza Belén.




Figura A 8. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ignacio Zaragoza Belén.




Figura A 9. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ignacio Zaragoza Belén.




Figura A 10. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ignacio Zaragoza Belén.




Figura A 11. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Boquilla Santa Rosa de la Misión.




Figura A 12. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Boquilla Santa Rosa de la Misión.




Figura A 13. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Boquilla Santa Rosa de la Misión.




Figura A 14. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Boquilla Santa Rosa de la Misión.




Figura A 15. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Boquilla Santa Rosa de la Misión.




Figura A 16. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Pinal.




Figura A 17. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Pinal.




Figura A 18. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación El Pinal.




Figura A 19. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Pinal.




Figura A 20. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Pinal.




Figura A 21. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10, q = 10$, escala de 10 a 100 días. Estación Ensenada (observatorio).




Figura A 22. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ensenada (observatorio).




Figura A 23. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ensenada (observatorio).




Figura A 24. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10, q = 10$, escala de 10 a 100 días. Estación Ensenada (observatorio).




Figura A 25. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ensenada (observatorio).




Figura A 26. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ojos Negros.




Figura A 27. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ojos Negros.




Figura A 28. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 40 días. Estación Ojos Negros.




Figura A 29. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ojos Negros.




Figura A 30. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ojos Negros.




Figura A 31. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Olivares Mexicanos.




Figura A 32. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Olivares Mexicanos.




Figura A 33. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Olivares Mexicanos.




Figura A 34. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Olivares Mexicanos.




Figura A 35. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Olivares Mexicanos.





Figura A 36. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 60 días. Estación San Juan de Dios Norte.




Figura A 37. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación San Juan de Dios Norte.




Figura A 38. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 60 días. Estación San Juan de Dios Norte.




Figura A 39. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación San Juan de Dios Norte.




Figura A 40. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación San Juan de Dios Norte.




Figura A 41. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 40 días. Estación Sierra de Juárez.




Figura A 42. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Sierra de Juárez.




Figura A 43. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 15 días. Estación Sierra de Juárez.




Figura A 44. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Sierra de Juárez.




Figura A 45. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Sierra de Juárez.




Figura A 46. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación La Misión.




Figura A 47. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación La Misión.




Figura A 48. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación La Misión.




Figura A 49. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación La Misión.




Figura A 50. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación La Misión.




Figura A 51. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Alamar.




Figura A 52. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Alamar.




Figura A 53. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación El Alamar.




Figura A 54. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Alamar.




Figura A 55. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Alamar.




Figura A 56. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Farito.




Figura A 57. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Farito.




Figura A 58. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación El Farito.




Figura A 59. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Farito.




Figura A 60. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación El Farito.





Figura A 61. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10, q = 10$, escala de 10 a 90 días. Estación Ejido Carmen Serdán.




Figura A 62. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ejido Carmen Serdán.




Figura A 63. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido Carmen Serdán.




Figura A 64. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ejido Carmen Serdán.




Figura A 65. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Ejido Carmen Serdán.





Figura A 66. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Valle de San Rafael.




Figura A 67. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Valle de San Rafael.




Figura A 68. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 25 días. Estación Valle de San Rafael.




Figura A 69. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Valle de San Rafael.




Figura A 70. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Valle de San Rafael.




Figura A 71. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Real del Castillo Viejo.




Figura A 72. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Real del Castillo Viejo.




Figura A 73. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Real del Castillo Viejo.




Figura A 74. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Real del Castillo Viejo.




Figura A 75. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 100 días. Estación Real del Castillo Viejo.




Figura A 76. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la temperatura, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido el Porvenir.




Figura A 77. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la humedad relativa, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido el Porvenir.




Figura A 78. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la presión, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido el Porvenir.




Figura A 79. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la velocidad del viento, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido el Porvenir.




Figura A 80. Función de fluctuación, exponente de Hurst, exponente de escalado de masa y espectro multifractal para la dirección del viento, $q = -10$, $q = 10$, escala de 10 a 80 días. Estación Ejido el Porvenir.