



**UNIVERSIDAD MICHOCANA DE SAN NICOLÁS
DE HIDALGO
FACULTAD DE INGENIERÍA CIVIL**



**MAESTRÍA EN INGENIERÍA DE LOS RECURSOS
HÍDRICOS**

**MODELACIÓN ESTOCÁSTICA MULTIVARIADA PARA PREDICCIÓN DE LLUVIA
A CORTO PLAZO MEDIANTE ESTIMACIONES DE SATELITE PARA LA CIUDAD
DE MORELIA, MICHOACÁN.**

TESIS

Para obtener el grado de

MAESTRA EN INGENIERÍA DE LOS RECURSOS HÍDRICOS

Presenta:

Ing. Claudia Lizeth García Pérez

Ingeniera Civil

Director de tesis:

Dr. Constantino Domínguez Sánchez

Doctor en Ingeniería de Caminos, Canales y Puertos

Co- Director

Dr. Joel Hernández Bedolla

Doctor en Ingeniería del Agua y Medio Ambiente

Marzo 2024

Morelia Michoacán, México.

AGRADECIMIENTOS

A la Maestría en Ingeniería de los Recursos Hídricos y la Universidad Michoacana de San Nicolás de Hidalgo por todos los conocimientos proporcionados en la etapa de posgrado, así como al Concejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCYT) por el apoyo económico para la realización del posgrado.

A la Dra Sonia Tatiana Sánchez Quispe por guiarme en esta investigación y por todo el conocimiento y apoyo compartido.

Al Dr. Joel Hernández Bedolla por la dedicación y conocimiento aportado para la realización de esta investigación.

Al Dr Constantino Domínguez Sánchez por su esfuerzo para esta investigación se realizara lo mejor posible.

A los doctores Julio César Orantes Ávalos y Ángel Gregorio Figueroa Soto por sus grandes comentarios, conocimiento y aportaciones a esta investigación.

A mi mamá por siempre creer en mi y apoyarme, así como a mi familia por quererme tanto.

A Ulises por acompañarme siempre y estar para mi incondicionalmente, gracias por tanto apoyo.



Contenido

1. INTRODUCCIÓN	8
2. OBJETIVOS	10
2.1. Objetivo general	11
2.2. Objetivos particulares	11
3. HIPÓTESIS	11
4. MARCO TEÓRICO	13
4.1. Modelación estocástica	13
4.2. Modelación estocástica de variables climáticas	13
4.3. Precipitación con teledetección	14
4.4. Validación de series de estimaciones de lluvia	24
4.5. Tipos de modelos estocásticos	24
4.5.1. Tipos de modelos estocásticos	25
5. ANTECEDENTES	32
6. JUSTIFICACIÓN	37
7. METODOLOGÍA	39
7.1. Recopilación y gestión de datos	40
7.1.1. Estaciones meteorológicas	40
7.1.2. Información satelital	42
7.2. Validación de series temporales de estaciones meteorológicas	47
7.2.3. Estadísticos para la validación de datos.	48
7.3. Análisis de correlaciones y validación para estimaciones y datos observados de lluvia	49
Caracterización de eventos de lluvia	51
7.4. Aplicación de modelo estocástico	52
7.5. Desarrollo de un análisis de componentes principales (ACP)	60
7.6. Series de precipitación de predicción	61
8. CASO DE ESTUDIO	61
9. RESULTADOS Y DISCUSIONES	63
9.1. Estaciones meteorológicas	63
9.1.1. Comparación de estadísticos en las estaciones	67
9.2. Obtención de series de estimaciones de precipitación mediante satélite	68



9.2.1.	CHRS Data Portal	68
9.2.2.	AWS GOES 16 Reader Software Version 1.0	73
9.2.3.	Integrated Multi-Satellite Retrievals for GPM (IMERG).....	75
9.3.	Comparación y validación de precipitaciones satelitales con estaciones meteorológicas.....	76
9.3.1.	Análisis 30 minutal.....	80
9.3.2.	Análisis diario	80
9.3.3.	Análisis semanal.....	80
9.3.4.	Análisis mensual.....	80
9.3.5.	Análisis anual	80
9.4.	Generación y caracterización de eventos de lluvia.....	81
9.5.	Modelación estocástica multivariada para eventos de lluvia a diferentes duraciones	91
9.5.1.	Análisis preliminar de los datos.....	92
9.5.2.	Normalización de eventos.....	93
9.5.3.	Parametrización con series de Fourier	95
9.5.4.	Análisis de correlaciones cruzadas	96
9.5.5.	Generación de series residuales.....	97
9.5.6.	Generación de series sintéticas	98
9.5.7.	Análisis de medias observadas y simuladas.....	99
9.6.	Series de predicción.....	100
10.	CONCLUSIONES.....	102
11.	RECOMENDACIONES Y LÍNEAS FUTURAS.....	104
12.	REFERENCIAS BIBLIOGRÁFICAS.....	105
13.	ANEXOS.....	111



ÍNDICE DE FIGURAS

Figura 1. Componentes de un sistema de teledetección	15
Figura 2.- Distribución del paquete de datos.	22
Figura 3.- Diagrama de flujo del programa principal.....	22
Figura 4. Ejemplo de la serie temporal obtenida a partir de datos de presión y humedad en el mismo momento en que se produce la lluvia. Fuente (Muñoz-mandujano et al., 2022).33	
Figura 5. Modelo de elevación Digital para la zona de estudio. Fuente (Velázquez-Ruiz et al., 2022).	34
Figura 6. Ruta metodológica para el desarrollo del sistema de predicción.....	40
Figura 7. Metodología para la obtención y análisis de estaciones meteorológicas.....	41



Figura 8. Metodología para obtención de datos del CHRS Data Portal.	43
Figura 9. Metodología para rutina de satélite GOES 16.	44
Figura 10. Ruta metodológica para la obtención de series de estimaciones de lluvia mediante IMERG.	45
Figura 11. Representación de la estimación del peso de las ubicaciones en una cuadrícula de 2 x 2. Tomado de (ud din et al., 2008).	46
Figura 12. Metodología para análisis de correlaciones y validación entre series de IMERG y de datos observados de lluvia.	50
Figura 13. Proceso de modelación estocástica.	53
Figura 14. Normalización para los datos de lluvia.	54
Figura 15. Metodología para ACP para variables climáticas.	60
Figura 16. Delimitación de la zona urbana de la ciudad de Morelia, Michoacán.	62
Figura 17. Series horarias para estaciones meteorológicas de OOAPAS.	63
Figura 18. Ubicación espacial de las estaciones meteorológicas de CONAGUA.	64
Figura 19. Series mensuales de las estaciones de la CONAGUA.	65
Figura 20. Series temporales para la estación MORE-UNAM y 76665-SMM.	66
Figura 21. Localización de estaciones MORE-UNAM y 76665-SMM en la ciudad de Morelia, Michoacán.	67
Figura 22. Precipitación acumulada del 19 al 24 de octubre del 2018 para el huracán Willa en Morelia del CHRS Data Portal.	69
Figura 23. Precipitación acumulada (mm) para el huracán Willa en octubre del 2018. (Climatología, 2018).	70
Figura 24. Precipitación acumulada para el huracán Carlos del CHRS Data Portal.	71
Figura 25. Precipitación acumulada (mm) para el huracán Carlos en junio del 2015. (Climatología, 2015).	71
Figura 26. Precipitación acumulada para huracán Dalila por CHRS Data Portal.	72
Figura 27. Precipitación acumulada (mm) para el huracán Dalila en junio del 2013.(Climatología, 2013).	73
Figura 28. Distribución de las carpetas necesarias para ejecución del código.	74
Figura 29. Total Precipitable Water 27/07/2022, 00 hrs 01 min, Domain: CONUS.	75
Figura 30. Esquema de análisis de IBP para la ciudad de Morelia, Michoacán.	76
Figura 31. Análisis gráfico a escala 30 minutal, diaria, semana, mensual y anual para la validación de la serie PP con datos observados de la estación MORE.	78
Figura 32. Análisis gráfico a escala 30 minutal, diaria, semana, mensual y anual para la validación de la serie IBP con datos observados de la estación MORE.	79
Figura 33. Eventos coincidentes para una duración de 6 horas de las estaciones MORE y 76665.	83
Figura 34. Análisis gráfico para ACP.	86
Figura 35. Varianza explicada mediante valores propios.	87
Figura 36. Distancia de Mahalanobis para valores atípicos.	88
Figura 37. Normalidad multivariada de los datos.	88
Figura 38. Análisis gráfico general de los CP.	89
Figura 39. Varianza explicada para las variables climáticas de la matriz depurada.	90
Figura 40. Matriz de correlaciones final.	90
Figura 41. Análisis de medias observadas y simuladas para eventos de 2 horas.	91



Figura 42. Distribución de frecuencias para eventos de lluvia con duraciones de 2, 3, 4, 5, 6 para las estaciones analizadas.	93
Figura 43. Ajuste de función de distribución para eventos de lluvia de 2 horas.	93
Figura 44. Intervalo de normalidad para eventos de 2 horas.	94
Figura 45. Parametrización para medias mediante series de Fourier para eventos de 2 horas.	95
Figura 46. Parametrización para desviaciones mediante series de Fourier para eventos de 2 horas.	96
Figura 47. Histograma para serie residual de eventos de 2 horas, condición de ruido blanco de normalidad.	97
Figura 48. Correlograma para serie residual de eventos de 2 horas, condición de ruido blanco de independencia.	98
Figura 49. Series sintéticas para eventos de lluvia de 2 horas.	99
Figura 50. Análisis de medias observadas contra simuladas para estación 76665.	100
Figura 51. Análisis de medias observadas contra simuladas para estación MORE.	100
Figura 52. Gráficas para eventos coincidentes de la estación MORE y 76665 a una duración de 2 horas.	115

ÍNDICE DE TABLAS

Tabla 1. Bandas utilizadas por GOES	17
Tabla 2.- Características del algoritmo IMERG, adaptado de (Huffman et al., 2020).	23
Tabla 3. Valores para estadísticos de la validación para estimaciones de lluvia.	51
Tabla 4. Resumen de características de diferentes estaciones meteorológicas analizadas.	67
Tabla 5. Comparación de estadísticos para estaciones de OOAPAS y CONAGUA.	68
Tabla 6. Validación estadística para las series de estimaciones de lluvia de IMERG mediante PP e IBP.	77
Tabla 7. Total de eventos registrados por la estación MORE Y 76665.	82



Tabla 8. Recopilación de eventos coincidentes para estación MORE-UNAM y 76665- CONAGUA.	82
Tabla 9. Desfase horario de ocurrencia de lluvia entre ambas estaciones.....	84
Tabla 10. Eventos horarios con lluvias de interés registrados por la estación MORE y 76665.....	84
Tabla 11. Matriz inicial de variables climáticas.....	86
Tabla 12. Matriz depurada de variables climáticas.	89
Tabla 13. Test de normalidad para eventos de lluvia analizados.	94
Tabla 14. Parámetros autorregresivos para $K = 3$	97
Tabla 15. Test de condición de ruido blanco para series residuales de los eventos de diferentes duraciones y AIC para el modelo.	98

RESUMEN

Los desastres naturales, como inundaciones, han ido aumentando a lo largo de los años. Esto ha despertado un interés por estudiar los factores que tienen gran influencia en la ocurrencia de las inundaciones, especialmente factores meteorológicos, como la intensidad y magnitud de las precipitaciones. Debido a esta problemática, se ha determinado que es importante conocer los comportamientos



de las precipitaciones, tanto pasadas como futuras, que perminta reaccionar con antelación ante un desastre natural.

La ciudad de Morelia Michoacán, ha presentado en las últimas décadas problemas de inundación en la zona urbana, que han causado una gran cantidad de daños en la población, debidas a las lluvias y los escurrimientos que se han generado con ellas.

El objetivo de este trabajo es desarrollar un modelo estocástico multivariado de predicción de lluvia a corto plazo. El trabajo se basa en la interpretación de información satelital de la zona de estudio, que permitan generar series de lluvia temporales, mismas que serán integradas a un modelo estocástico multivariado para generar predicciones de lluvia que puedan ser implementadas en la ciudad de Morelia, Michoacán.

Palabras clave: Modelación multivariada, precipitaciones, estimaciones de satélite, Morelia, Michoacán.

ABSTRACT

Natural catastrophes, such as floods, have been increasing over the years. This has generated an interest in studying the factors that have a great influence on the occurrence of floods, especially meteorological factors, such as the intensity and magnitude of rainfall. Due to this problem, it has been determined that it is important



to know the behavior of precipitation, both past and future, which allows us to react in advance to a natural disaster.

The city of Morelia, Michoacán, has presented in recent decades flooding problems in the urban area, which have caused a large amount of damage to the population, due to rainfall and runoff that have been generated with them.

The objective of this work is to develop a multivariate stochastic short-term rainfall prediction model. The work is based on the interpretation of satellite information of the study area, which allows the generation of time series of rainfall, which will be integrated into a multivariate stochastic model to generate rainfall predictions that can be implemented in the city of Morelia, Michoacán.

Key words: Multivariate modeling, rainfall, satellite estimates, Morelia, Michoacán.

1. INTRODUCCIÓN

La predicción a corto plazo de eventos de lluvia representa un componente crucial para mitigar riesgos y optimizar la resiliencia urbana. La utilización de estimaciones satelitales de variables climáticas en combinación con modelos



estocásticos representa una estrategia innovadora y eficaz para mejorar la precisión y confiabilidad de dichas predicciones en entornos urbanos específicos.

A menudo, se requiere obtener secuencias sintéticas de precipitaciones a diferentes escalas temporales con las mismas propiedades estadísticas que las históricas, así como predicciones de la misma variable. Estas secuencias de precipitaciones pueden utilizarse como entradas de modelos hidrológicos para producir caudales sintéticos con secuencias más largas que las históricas, así como también, para la predicción de la escorrentía de una cuenca (Jacques & M. Levent, 1978).

Se sabe que, en México, existe un déficit en cuanto a mediciones de precipitación en la superficie terrestre, provocando que se cuente con datos históricos insuficientes. Esto genera que no se tenga un conocimiento apto del comportamiento temporal de uno de los factores meteorológicos de suma importancia, como es la precipitación, a escalas temporales subdiarias.

Un factor importante en la ocurrencia de los desastres naturales, específicamente en las inundaciones, son sin duda las precipitaciones de gran intensidad o duración que se pueden presentar en una determinada zona. El año 2013 fue muy intenso en cuanto a precipitaciones, especialmente el mes de septiembre, la cantidad de las precipitaciones aumentó un 60% respecto a la media histórica, registrando una media mensual de 227,3 mm y superando el récord de 1955 de 212,1 mm (Gutierrez-Lopez et al., 2019b).

Según la Secretaría de Seguridad y Protección Ciudadana, 2021, a nivel mundial las inundaciones están aumentando más rápidamente que ningún otro desastre (SSPC et al., 2015).

En las últimas décadas, se han presentado problemáticas de inundaciones en la ciudad de Morelia Michoacán debido a la mala localización de asentamientos, el crecimiento de población, área urbana, las condiciones de la población y como tema de interés las precipitaciones de gran intensidad y magnitud (Hernández & Vieyra, 2010).



La predicción es esencial para prevenir riesgos en las actividades económicas y el sector urbano (Magaña et al., 2013). Entonces, resulta de suma importancia y necesidad contar con registros fiables ante los eventos naturales extremos, que pueden reducir los daños causados. Sin embargo, la predicción precisa de las precipitaciones a un corto plazo es un reto debido a la complejidad de su ocurrencia, por su variabilidad espacial y temporal que depende de las diferentes condiciones meteorológicas (Kashiwao et al., 2017).

La presente investigación plantea desarrollar un sistema de predicción de precipitaciones a corto plazo (escala subdiaria) el cual se desarrollará con series de precipitación obtenidas de información satelital. Dichas series alimentarán un modelo estocástico determinado que generará predicciones que sean lo suficientemente confiables y precisas. Además, integrar esta herramienta a un Sistema de Alerta Temprana para la ciudad de Morelia lo cual permita corroborar que la metodología aplicada dará alertas fiables.

2. OBJETIVOS



2.1. Objetivo general

Desarrollar un modelo estocástico multivariado alimentado con estimaciones de lluvia de satélite que genere predicciones fiables para la ciudad de Morelia, Michoacán.

2.2. Objetivos particulares

1. Obtener series de estimaciones de lluvia para la zona de estudio mediante un algoritmo de procesamiento de productos satelitales.
2. Validar estadísticamente la información de satélite para la zona de estudio.
3. Analizar alternativas de modelos estocásticos con base en el ajuste de los datos de lluvia.
4. Desarrollar el modelo estocástico elegido.
5. Generar y validar las series de predicción de precipitaciones arrojadas por el modelo.

3. HIPÓTESIS



El modelo estocástico multivariado alimentado con estimaciones de lluvia de satélite, proporcionará predicciones a corto plazo que serán fiables para su utilización en la ciudad de Morelia, Michoacán.



4. MARCO TEÓRICO

4.1. Modelación estocástica

La modelación estocástica se utiliza para modelar fenómenos que presentan un cierto grado de aleatoriedad o incertidumbre para su ocurrencia. Esta técnica es de suma importancia debido a que incorpora la propia aleatoriedad, incorpora la incertidumbre, además se utiliza ampliamente en la gestión de los riesgos, lo cual permite analizar diversos escenarios y obtener un número considerable de resultados, así como optimizar los procesos con base en la teoría de probabilidad y estadística, tomando en cuenta la variabilidad de los fenómenos analizados.

Como menciona (Salas et al., 1980), si el resultado de una variable X puede predecirse con un cierto grado de certeza, la variable es llamada como variable determinista, sin embargo, si el resultado de la variable X no puede predecirse con certeza, entonces X es una variable aleatoria. Entonces, con base en este concepto, se define el principio de una modelación estocástica, la cual tiene una certeza matemática estructurada y un conjunto de parámetros que describen el comportamiento de la variable analizada.

4.2. Modelación estocástica de variables climáticas

Los modelos estocásticos de variables climáticas capturan la aleatoriedad e incertidumbre del clima. Dichos modelos se utilizan para simular, predecir o generar diferentes aspectos del clima, es decir, diferentes variables climáticas como la temperatura, humedad, velocidad del viento y como una de las variables más importante, la precipitación o lluvia. Según (Salas et al., 1980), las series temporales de lluvia, por lo general se encuentran sesgados a la derecha, o sea, presentan un sesgo positivo, por lo que se debe trabajar con series normalizadas.



4.3. Precipitación con teledetección

Para entender las estimaciones de lluvia de satélite, primeramente, debemos conocer un término que es la base de dicho proceso.

La teledetección es una técnica bastante utilizada que permite adquirir imágenes de la superficie terrestre, de la atmósfera y de los objetos presentes, sin estar en contacto directo con ellos, desde sensores instalados en plataformas espaciales. Esta técnica no engloba solamente los procesos que permiten obtener una imagen desde el espacio, sino también su tratamiento posterior, en el contexto que se requiera (Chuvieco, 1990).

Un sistema de teledetección espacial concibe los siguientes elementos:

- a) Fuente de energía: proveniente de la luz solar o emitida por el propio sensor.
- b) Objeto a observar: el cual puede estar presente en la superficie terrestre, atmósfera y/ espacio.
- c) Sistema sensor: compuesto por el sensor propiamente dicho y la plataforma o satélite que lo transporta.
- d) Sistema de recepción: estación en Tierra en donde se recibe la información proveniente del sensor.
- e) Intérprete o usuario final: analiza la información orientándola a facilitar el problema de estudio.

Dichos elementos se presentan en la figura 1.




Figura 1. Componentes de un sistema de teledetección

Principio físico de la Teledetección

Según Chuvieco, (1990), para que la teledetección sea posible debe existir una interacción entre los objetos y el sensor. En primera instancia, el sensor capta la energía emitida por el objeto, lo cual constituye una forma de energía electromagnética, además, de contar con un modelo armónico y continuo. Las características más importantes de los sensores son dos: longitud de onda y frecuencia. Debido a esto, se establece una serie de bandas con longitud de onda continuas. A la organización de bandas de longitudes de onda o frecuencia se le denomina espectro electromagnético.

Las aplicaciones de teledetección en los ámbitos climatológicos son posibles gracias a la variedad de formas en que la atmósfera y los demás sistemas terrestres interactúan con el espectro electromagnético. Los sensores satelitales miden la energía de longitudes de onda específicas que se denominan “canales” y se



numeran en orden ascendente desde la longitud de onda corta hasta la longitud de onda larga. En meteorología se utilizan principalmente las longitudes de onda visible (0.4 a 0.7 μm), infrarroja (0.7 a 14 μm) y de microondas (a partir de 1mm).

Obtención de precipitaciones satelitales

Se mencionan a continuación, algunas de las misiones o algoritmos satelitales más empleados actualmente.

El Tropical Rainfall Measuring Mission (TRMM), fue el primer radar de precipitación, lanzado en 1997 a bordo de un satélite como parte de la misión de medición de la lluvia tropical. Este generó las primeras mediciones continuas de la precipitación para todas las regiones tropicales, generando mejores descripciones de la estructura vertical de las tormentas (Program, 2008).

Por otro lado, el Observatorio Central de Medición de la Precipitación Global (GPM), una misión conjunta de los Estados Unidos y Japón, lanzado en 2014, mejora las mediciones que se tienen por parte del TRMM. Lleva instrumentos de microondas pasivos y activos de alta calidad diseñados para observar la estructura e intensidad de las precipitaciones y nevadas que caen (Levizzani et al., 2020)

La misión CloudSat que tiene el radar de Perfil de nubes (CPR), siendo el primer radar espacial con banda W, el cual contribuye al sistema de observación global a través de la detección precisa de la precipitación, la cuantificación de la tasa de nevadas, la cuantificación de la caída de lluvia ligera y la delineación estratiforme/convectiva (Ali et al., 2014)

Los datos de CloudSat han demostrado que sobre la tierra no se identifica más del 50% de la ocurrencia de precipitaciones hacia el ecuador de 40 y el 20% hacia el polo de 40 es identificado por otros sensores de medición de la precipitación (Ali et al., 2014)

En diversas investigaciones, se ha utilizado como base de datos el satélite GOES, mismo que emplea imágenes infrarrojas.



El satélite GOES, por sus siglas (Geostationary Operational Environmental Satellite), es un satélite meteorológico y una de las claves de programa estadounidense de la NOAA (National Oceanic and Atmospheric Administration). Los datos del satélite son continuos y proveen información necesaria para obtener el pronóstico del tiempo, el seguimiento de tormentas severas y para investigaciones en meteorología. Estos satélites operan en órbita geoestacionaria, es decir que orbitan en el plano ecuatorial con la velocidad de rotación de la Tierra. Además, monitorea nubes, temperatura superficial y vapor de agua, realizándolo mediante “canales” o bandas” del espectro electromagnético, especialmente las del visible e infrarrojo, como se presenta en la tabla 1 (Paz & Ríos, 2021).

Tabla 1. Bandas utilizadas por GOES

Canal	Onda	Longitud de onda (μm)	Resolución espacial (pixel) (km)
1	Visible	0.65	1
2	Onda corta	3.9	4
3	Vapor de agua	6.5	8
4	Onda larga	10.7	4
5	Infrarroja sensible	12	4
6	Temp, de bajo nivel	13.3	8

Con base en la investigación de Paz & Ríos, (2021), se presentan las aplicaciones de los canales del GOES a continuación.

- Canal 1: 0.52 a 0.71 μm (GOES 13 a 15), centrado en 0.63 μm

Consideraciones de aplicación:

- Sólo está disponible durante el día.
- Detecta la energía dispersada y reflejada.
- Detecta las nubes y la superficie terrestre.
- Es sensible a las diferencias entre el suelo, el agua y los tipos de nubes.



- Detecta la niebla durante el día.

- Canal 2: 3.78 a 4.03 μm , centrado en 3.9 μm

Consideraciones de aplicación:

- Detecta la radiación solar reflejada más la radiación térmica emitida.
- Debido a la radiación solar reflejada, los toques de las nubes y la superficie del suelo tienen un aspecto más cálido durante el día, en comparación a las imágenes del canal de la ventana infrarroja de onda larga de 10,7 μm .
- Exhibe poca atenuación atmosférica.
- Percibe la superficie terrestre y las nubes.
- Es sensible a zonas urbanas calientes y a cursos fluviales y lagos menores relativamente cálidos.
- Permite detectar niebla y nubes de agua por la noche cuando se utiliza junto con el canal de la ventana infrarroja de onda larga.
- Permite distinguir entre las nubes de agua y de hielo de día basándose en la reflectividad solar.
- Durante la noche permite la identificación de nieblas y discriminación entre nubes de agua y nieve.

- Canal 3: 5.77 a 7.33 μm (GOES 12 a 15), centro en 6.5 μm

Consideraciones de aplicación:

- Es muy sensible a la humedad atmosférica.
- Normalmente detecta la mitad superior de la troposfera.
- 1. Detecta las regiones húmedas a mayor altura.
- 2. Detecta las regiones secas a menor altura.
- El seguimiento de las estructuras en las secuencias de imágenes de vapor de agua es útil para inferir los movimientos atmosféricos.



- Canal 4: 10.2 a 11.2 μm , centrado en 10.7 μm

Consideraciones de aplicación:

- Poca atenuación atmosférica
 - Revela las temperaturas en la superficie y en los topes de las nubes
 - Se utiliza en combinación con el canal infrarrojo de onda corta de 3,9 μm para: estimar la fase del agua en las nubes, detectar capas de niebla y estratos bajos, distinguir entre las nubes de agua y el manto de nieve
 - Se usa para estimar la intensidad de las tormentas y la lluvia
 - Se usa para observar las estructuras nubosas a lo largo del tiempo y para estimar los movimientos atmosféricos.
- Canal 5: 11.5 a 12.5 μm , centrado en 12.0 μm (disponible en el GOES 8 a 11). Estimación del movimiento de nubes, identificación de tormentas severas y localización de probables lluvias intensas.
 - Canal 6: 12.9 a 13.7 μm , centrado en 13.3 μm (disponible en el GOES 12 a 15). Determinación de características de las nubes, por ejemplo: presión del tope.

Consideraciones de aplicación:

- Es sensible a dióxido de carbono, nubes y superficie.
- Normalmente detecta nubes y la mitad inferior de la troposfera.
- Permite una mejor determinación de la altura y la cubierta nubosa (producto nubes del satélite) y de los vientos que arrastran las nubes.

CHRS Data Portal

Según (Nguyen et al., 2019), el Centro de Hidrometeorología y Teledetección (CHRS) ha creado el Portal de Datos CHRS para facilitar el acceso a los tres conjuntos de datos de precipitación basados en satélites con licencia de datos abiertos generados por un sistema de Estimación de Precipitación a partir de



Información de Percepción Remota usando Redes Neuronales Artificiales (PERSIANN): PERSIANN, PERSIANN-Sistema de clasificación de nubes (CCS) y PERSIANN-Registro de datos climáticos (CDR).

PERSIANN utiliza la técnica de aprendizaje automático conocida como redes neuronales artificiales (ANN, por sus siglas en inglés) para determinar la relación entre la temperatura de la cima de la nube detectada remotamente, medida por sensores infrarrojos (IR) de onda larga en satélites GEO, y las tasas de lluvia, con corrección de polarización a partir de lecturas de microondas pasivas (PMW) medidas por satélites en órbita terrestre baja (Hsu et al., 1997).

A partir de PERSIANN, los investigadores crearon dos algoritmos adicionales:

- PERSIANN-CCS estima la precipitación global casi en tiempo real y con una resolución espacial más alta que PERSIANN a través de su algoritmo de agrupamiento de nubes y su uso de datos IR como única entrada (Hong et al., 2004). El algoritmo tiene registro de datos del año 2003 al presente, también tiene una resolución de 4 km por 4 km y se pueden descargar datos a una escala horaria, de 3 horas, 6 horas, diaria, mensual y anual.
- PERSIANN-CDR emplea el algoritmo PERSIANN con datos IR históricos a partir de 1983, el primer año en que los científicos registraron regularmente datos de detección remota con un alcance global, para construir un conjunto de datos consistente para estudios de tendencias climáticas (Ashouri et al., 2015). El algoritmo tiene registro de datos del año 1983 al presente, también tiene una resolución de 25 km por 25 km y se pueden descargar datos a una escala horaria, de 3 horas, 6 horas, diaria, mensual y anual.

AWS GOES 16 Reader Software Version 1.0

El Amazon Web Server facilita la exploración del conjunto de datos GOES en dicha página, así como la descarga de los datos.



El paquete de software Reader Software Version 1.0 está pensado para permitir al usuario leer y visualizar casi todos los tipos de datos creados y descargados desde cualquiera de las plataformas, con una salvedad importante. Todo el software disponible en esta versión se ha diseñado específicamente para funcionar con el satélite GOES-16. Se ha señalado anteriormente que el alcance de este paquete de software se limita a leer casi todos los tipos de productos de datos del GOES-16 y a permitir al usuario realizar gráficos de primer orden de los datos.

Las plataformas de observación del GOES producen un auténtico tsunami de productos de datos en un día normal. Si el usuario tuviera que descargar los resultados de un día normal, necesitaría más de 500 Gb al día. Se necesitarían muchas horas para descargar esta producción, por lo que no es práctico para el usuario típico mantener más de unos pocos días de producción en un ordenador personal. La herramienta de software se ha configurado para que el usuario pueda crear una carpeta estándar que contenga los datos de un día en carpetas con nombres específicos, independientemente de si esas carpetas están llenas de datos. Cada carpeta/subcarpeta contendrá exactamente un tipo de datos para evitar el caos. El lector GOES16 sólo necesita el paquete básico Matlab y la Mapping Toolbox para funcionar (Forczyk, 2021).

Es importante mencionar que para la ejecución correcta del código se necesitan descargar las carpetas mostradas en la figura 1.



Item	# Files	Size-Mb	Comments
Code	247	6.25	Matlab Code Only
Country_Maps	197	219	Country Boundaries
CountryShapeFiles	7621	6200	Country ShapeFiles
Documents	43	172	GOES Docs
DTED	83	30	Tiny Subset Of Database
Forczyk_Python	195	29	Python Scripts
Gov_Jpeg	30	3.1	Gov Supplied Art
Grids	73	3890	Grids For Plotting
Imagery	449	3750	Aug 26 Data Sampler
InterstateSigns	256	276	Road Signs
Mat_Files_Geographic	42	8.1	Assorted Geographic Data
Matlab_Data	310	985	More Geographic Data
Military Bases	26	0.5	Military Base Locations
NationalShapeFiles	33	135	National Level US ShapeFiles
NaturalEarth	629	140	Additional Shapefiles
ShapeFiles	7	522	Additional ShapeFiles
USStateBoundaryFinalFiles	51	4.45	Best US State Boundary Files
USStateShapeFiles	1282	8899	US State Level ShapeFiles

Figura 2.- Distribución del paquete de datos.

El funcionamiento principal del lector del GOES se muestra en la figura 2.




Figura 3.- Diagrama de flujo del programa principal.



Integrated Multi-SatellitE Retrievals (IMERG) for Global Precipitation Measurement (GPM)

Este algoritmo tiene por objeto intercalibrar, fusionar e interpolar "todas" las estimaciones satelitales de precipitación por microondas, junto con estimaciones satelitales infrarrojas (IR) calibradas por microondas infrarrojas (IR) calibradas por microondas, los análisis de los pluviómetros y, potencialmente, otros a escalas temporales y espaciales finas para las eras TRMM y GPM en todo el planeta, cubriendo la mayor parte de del planeta desde los meridianos 60 S a 60 N. El sistema se ejecuta varias veces para cada tiempo de observación, proporcionando primero una estimación rápida y sucesivamente mejores estimaciones a medida que llegan más datos. En la última etapa se utilizan los datos mensuales de los aforos para crear productos a nivel de investigación (Huffman et al., 2020).

Se presentan a continuación algunas de las características principales del algoritmo IMERG.

Tabla 2.- Características del algoritmo IMERG, adaptado de (Huffman et al., 2020).

Característica	Descripción
Resolución	0.1° (11 km x 11 km)
Intervalo de tiempo	30 min
Dominio espacial	Global
Periodo de registro	1998 al presente
Disponibilidad de información	Early: 4 h después de la observación
	Late: 14 h después de la observación
	Final: 3.5 meses después de la información
Datos de salida	Instantánea para 30 min
	Acumulada para mensual
Calibración de precipitación	Sensor CORRA
	Errores en estimaciones
Formatos de salida	NetCDF

Plataforma de Google Eart Engine

Google Earth Engine es una plataforma informática que permite a los usuarios ejecutar análisis geoespaciales en la infraestructura de Google. La plataforma cuenta con un amplio catálogo de productos satelitales, los cuales permite procesar



sin necesidad de descargar las imágenes directamente del satélite, esto mediante la ejecución de rutinas en el lenguaje Python y Java Script permitiendo descargar la información en diversos formatos (Google, 2023).

Google Engine cuenta con el producto de la misión Global Precipitation Measurement (GPM) la cual es una misión satelital internacional para proporcionar observaciones de próxima generación de lluvia y nieve en todo el mundo cada tres horas. Integrated Multi-satellitE Retrievals for GPM (IMERG) es el algoritmo unificado que proporciona estimaciones de lluvia combinando datos de todos los instrumentos de microondas pasivos en la constelación GPM.

4.4. Validación de series de estimaciones de lluvia

Para evaluar el desempeño de los productos satelitales y compararlos con datos de precipitación de estaciones meteorológicas es necesario aplicar estadísticos descriptivos (Aslami et al., 2019; Tan & Duan, 2017).

El coeficiente de correlación de Pearson (R) el cual evalúa el grado de concordancia entre las estimaciones y los datos observados, que varía entre -1 y 1.

La raíz del error medio cuadrático (RMSE) representa la desviación estándar de la muestra de las diferencias entre los valores estimados y los valores observados.

El sesgo estadístico (BIAS) que es la diferencia promedio entre las estimaciones y los datos observados; mismo que se utiliza para estimar el porcentaje de subestimación o sobrestimación entre las variables.

4.5. Tipos de modelos estocásticos

Es una realidad que se necesitan modelos de predicción de precipitación que nos permitan conocer el comportamiento temporal y futuro de las mismas.

Citando a Scheidereite & Faure, (2015), una serie temporal es una sucesión de n observaciones x_t tomadas secuencialmente en el tiempo. Entonces, la predicción es posible a partir de la confección de un modelo matemático que se formula en términos de los valores pasados de la serie.



Lage González, (2018) expone que los modelos matemáticos permiten llevar a una mejor comprensión los fenómenos de compleja naturaleza. Por otro lado, permiten llevar a cabo simulaciones en periodos largos de tiempo, con base en periodos históricos, como vía para evaluar la respuesta hidrológica y el propio comportamiento del sistema hidrológico.

Los modelos matemáticos pueden dividirse en dos grandes grupos: deterministas y estocásticos.

En este trabajo, se emplearán los modelos estocásticos, conocidos también como modelos probabilísticos, mismos que se formulan sobre la base de la probabilidad y procesos estocásticos.

Un modelo estocástico tiene al menos un componente o variable de carácter aleatorio (con una distribución de probabilidad), que no está explícito en la entrada del modelo, enfatizando la dependencia espacial y temporal de las variables hidrológicas relacionadas por el modelo. Por otro lado, si las variables de entrada no tienen variación aleatoria, que no tienen una distribución probabilística, el modelo es considerado como determinista (B. Abbott & Refsgaard, 1996).

4.5.1. Tipos de modelos estocásticos

- Modelos autorregresivos (AR (p))

Una forma de encontrar una ecuación que represente la influencia que los acontecimientos pasados tienen sobre el presente (y sobre el futuro), es escribir el valor actual del proceso como dependiente de forma lineal de valores pasados del propio proceso, más una perturbación aleatoria que hace que el modelo no sea determinista. Esta expresión caracteriza a los procesos autorregresivos (Scheidereite & Faure, 2015).

Como explican Shumway & Stoffer, (2021), los modelos autorregresivos se crean con la idea de que el valor presente de la serie X_t , puede expresarse como



una función de p valores pasados X_{t-1} , X_{t-2} , X_{t-p} , más una perturbación aleatoria en el tiempo, donde p determina el número de pasos en el pasado necesarios para predecir el valor actual.

La medida en que es posible predecir una serie de datos reales a partir de sus propios valores pasados puede evaluarse observando la función de autocorrelación, que muestra la correlación lineal entre dos valores cualesquiera de la serie; y las matrices de dispersión, donde el comportamiento de la serie presente un movimiento afín hacia algún valor constante.

Entonces, una forma “sencilla” de expresar la ecuación del AR(p) es utilizando el operador de retardo B , por lo que resulta:

$$\varphi(B)y_t = A_t \quad (1)$$

Donde y_t es un proceso estacionario, variable referida a un tiempo t , φ son constantes del modelo autorregresivo 0.

- Modelos de medias móviles (MA(q))

En el caso de los modelos autorregresivos se asume que y_t está dado como una combinación lineal (expresada en el lado derecho de la ecuación que define al proceso autorregresivo) de los valores y_{t-k} de la serie. Como alternativa, en el modelo de media móvil, se asume que los ruidos blancos A_t se combinan linealmente para conformar una representación del modelo (Shumway & Stoffer, 2021).

Los modelos MA son una combinación lineal ponderada entre los términos presentes y los q valores pasados de los residuales (Zhiña et al., 2017).

Utilizando el operador de media móvil, la ecuación resulta:

$$y_t = \theta(B)A_t \quad (2)$$

Donde $\theta(B) = 1 + \theta_1(B) + \theta_2(B^2) + \theta_q(B^q)$, $\theta \neq 0$ y B es el operador de media móvil.



Nótese que por ser suma de $q + 1$ procesos estacionarios un modelo MA (q) siempre es estacionario.

- Modelos autorregresivos de medias móviles (ARMA)

Los modelos Autoregresivos (AR) se los puede acoplar a los modelos de Media Móvil (MA) formando así un nuevo modelo llamado Autoregresivo de Media Móvil (ARMA (p, q)), pueden ser usados cuando los datos son estacionarios (parámetros estadísticos constantes) (Zhiña et al., 2017).

Por lo tanto, la ecuación se presenta en función de los operadores AR y MA:

$$\varphi(B)y_t = \theta(B)A_t \quad (3)$$

Cuando $q = 0$, el modelo se denomina modelo autorregresivo de orden p , AR(p), y cuando $p = 0$, el modelo se denomina modelo de media móvil de orden q , MA(q) (Shumway & Stoffer, 2021).

Citando a Lage González, (2018), la precipitación es considerada como un proceso estocástico en el tiempo, pudiendo así ser estudiada como estacionaria (lo cual conlleva a que sus propiedades estadísticas sean invariantes en el tiempo) o no dependiendo de la escala temporal considerada.

La modelación estocástica contiene varios apartados para poder realizar una aplicación adecuada, principalmente para los modelos autorregresivos (AR(p)) que son los más empleados.

- **Ocurrencia de precipitación**

Para definir el proceso estocástico de las ocurrencias de precipitación es necesario determinar las probabilidades de que se presente precipitación en un tiempo dado. Para un modelo de Markov de dos estados que es un proceso de función bivariada la cual depende de las probabilidades condicionales de transición, para el modelo se planteó la probabilidad de que ocurra precipitación dado que el minuto o minutos se presentó precipitación (p_{11}), la probabilidad que en el tiempo de análisis se no se presente precipitación (p_{00}), las probabilidades de que se presente precipitación si en los minutos anteriores no hubo lluvia (p_{01}) y la



probabilidad de que no se presente precipitación si en minutos anteriores se presentó precipitación (p_{10}).

En la siguiente ecuación se presentan las relaciones entre las diferentes probabilidades condicionales de transición.

$$p_{00} = 1 - p_{01} \quad (4)$$

$$p_{10} = 1 - p_{11} \quad (5)$$

- **Normalización**

Según Salas et al., 1980, para la modelación estocástica en series hidrológicas es necesario asumir que la variable de comporta de manera normal, es decir con distribución Gaussiana y sesgo 0.

Esta fase consiste en transformar las series originales mediante los distintos tipos de transformaciones con el fin de que se conviertan en series normalizadas (AQUATOOL, 2023).

- **Análisis de variabilidad temporal: Series de Fourier**

Una de las características más importantes del proceso de precipitación es la variabilidad estacional. La cantidad de precipitación cambia periódicamente con la escala temporal de análisis. Parámetros como media, desviación estándar y coeficientes autorregresivos también presentan periodicidad (Papalexiou, 2018).

El número de parámetros depende directamente de la variabilidad de la precipitación. Si se considera los parámetros variables en escala diaria, se tiene un gran número de parámetros que se debe estimar. Es necesario reducir su número con el objetivo preservar la parsimonia estadística del modelo. Cuando diferentes parámetros muestran la periodicidad se pueden analizar con series de Fourier (Matínez & Salas, 2004); el objetivo principal de estas series es reducir el número de parámetros cuando éstos son periódicos o estacionales. Presentándose a continuación la ecuación de Fourier.

$$\hat{f} = \bar{u} + \sum_{j=1}^h \left[A_j \cos\left(\frac{2\pi\tau}{w}\right) + B_j \sin\left(\frac{2\pi\tau}{w}\right) \right] \quad (6)$$

Donde $\hat{f}$ son los vectores de parametrizados por la serie de Fourier, $\bar{u}$ son los vectores de los valores observados y normalizados de precipitaciones ($O_\tau > \text{cero}$), que se aplican a la media y desviación estándar, además de las probabilidades de ocurrencia de precipitación (p_{01}, p_{11}, μ y s).

$$\bar{u} = \frac{1}{w} \sum_{\tau=1}^w y_\tau; \quad O_\tau > \text{cero} \quad (7)$$

Donde A_j es el vector de coeficientes cosenoidales de Fourier, su ecuación es la siguiente:

$$A_j = \frac{2}{w} \sum_{t=1}^w u_t \cos\left(\frac{2\pi t}{w}\right) \quad (8)$$

Donde B_j es el vector de coeficientes senoildales de Fourier que se obtiene

$$B_j = \frac{2}{w} \sum_{t=1}^w u_t \sin\left(\frac{2\pi t}{w}\right) \quad (9)$$

Donde j es el armónico, y h es el número total de armónicos, que es Igual a $w/2$ cuando el número de armónicos es par y $(w-1)/2$ cuando el número de armónicos es impar. Por ejemplo, para la simulación cada 10 minutos se tienen 144 intervalos, para el caso de 5 minutos 288 intervalos por finalmente t es el tiempo de simulación (minutos).

- **Estandarización**

Una vez reducido el número de parámetros de la serie, se procede a convertir la serie en homogénea; esto mediante la estandarización, la cual permite el análisis de las propiedades de dependencia temporal; además una serie homogénea sirve para generar series residuales y para determinar la serie residual para los diferentes modelos estocásticos de cantidad. La estandarización transforma la serie con una

media y desviación estándar dada, por lo que se tiene que remover la media a cero y la varianza a uno $\mu \cong 0$ and $\sigma \cong 1$. Para la estandarización de las series se realiza mediante las medias y desviaciones parametrizadas en cada caso. La periodicidad de la serie se eliminó mediante la ecuación **¡Error! No se encuentra el origen de la referencia..**

$$z_{\tau} = \frac{y_{\tau} - \hat{\mu}}{\hat{\sigma}}; \quad O_{\tau} \geq \text{cero}; \quad (10)$$

Donde z_{τ} es la serie estandarizada $\hat{\mu}$ y $\hat{\sigma}$ son vectores de medias y desviaciones estándar respectivamente para las duraciones en minutos τ con precipitación.

- **Análisis de correlación temporal**

La autocorrelación de la serie es importante debido a que, con base en este proceso se puede elegir el tipo y orden de modelo estocástico que mejor se adapte a las condiciones de dependencia del tiempo, es decir, el retraso se utilizará para la correcta representación del modelo. Las series de corta memoria presentan una correlación que rápidamente decae a cero mientras que los modelos de larga memoria tienden a decaer lentamente hasta cero (Salas et al., 1980).

Para la eficiencia de los algoritmos se plantea la modelización con el menor número de parámetros capaces de representar la variabilidad temporal de las series de precipitación. La función de autocorrelación para la serie normalizada y estandarizada se presenta en la siguiente ecuación.

$$r_k(z) = \frac{\sum_{t=1}^{N-k} (z_t - \bar{z}_t) (z_{t+k} - \bar{z}_{t+k})}{\sqrt{\sum_{t=1}^N (z_t - \bar{z})^2 \sum_{t=1}^N (z_{t+k} - \bar{z}_{t+k})^2}} \quad (11)$$

Donde $r_k(z)$ es el coeficiente de autocorrelación con retraso de tiempo k , z_t es el vector normalizado y estandarizado, $\bar{z}_t$ es el promedio de z_t , z_{t+k} es el vector normalizado y estandarizado para minutos siguientes y N es el número de datos en estudio.

- **Generación de series residuales**



El objetivo de la modelación estocástica es la generación de series de precipitación y que estas preserven las características estadísticas dentro de los límites de confianza. Durante la modelación se determinan diferentes parámetros, lo cuales tienen que presentar un buen ajuste. El objetivo de la generación de series es la adecuada representación de las características de las series hidrológicas con el menor número de parámetros. La modelación debe ser capaz de preservar la variabilidad temporal, interanual de los análisis realizados. Es necesario que un modelo estocástico sea capaz de representar la media, desviación estándar, el sesgo y la correlación temporal (Ababaei et al., 2014; Pulkkinen & Chandrasekar, 2019). Para la verificación de los modelos estocásticos autorregresivos $AR(p)$ se evaluarán las diferentes pruebas que permitan indicar que el modelo estocástico es el adecuado para generar series sintéticas. La serie residual debe satisfacer la normalidad de los residuos ($\varepsilon \cong 0$, $s_\varepsilon \cong 1$), que no están correlacionados ($r_k(\varepsilon) \cong 0$) e insesgados ($g_\varepsilon \cong 0$), es decir que se cumpla con la condición de ruido blanco.

4.6. Análisis de componentes principales (ACP)

La técnica de análisis de componentes principales (PCA) es una herramienta estadística que generalmente se aplica para ajustar modelos en los que las variables explicativas tienden a estar altamente correlacionadas. En estos casos, el procedimiento metodológico consiste en una transformación ortogonal en la que las variables posiblemente correlacionadas se convierten en un nuevo conjunto de variables linealmente independientes, denominadas componentes principales (PC). PC son combinaciones lineales de las variables originales y pueden interpretarse como tales. El número de componentes retenidos es menor o igual que el número de variables originales, donde la primera PC explica la mayor parte de la varianza total de los datos. Así, esta técnica se utilizó para eliminar correlaciones entre variables explicativas del conjunto de datos utilizado, evitando la multicolinealidad de los datos y mejorando el ajuste e interpretación de los modelos estadísticos propuestos (Ribeiro et al., 2021).



5. ANTECEDENTES

Existe una gran cantidad de modelos de predicción para el clima, específicamente para la previsión de lluvia, a nivel mundial, sin embargo, se ha encontrado que en México se han aplicado muy pocos, los cuales se mencionan en los siguientes párrafos. De manera particular, para modelos de predicción basados en estimaciones de satélite de lluvia a escalas subhorarias en México, no existe evidencia bibliográfica de alguna aplicación. Se describen entonces las investigaciones realizadas con base en sistemas de predicción, modelos estocásticos y utilización de información satelital de lluvia.

Davolio et al., (2008) proponen un sistema de previsión meteo-hidrológica multi- modelo en tiempo real para varios episodios de precipitaciones intensas, asociados a eventos de inundación, que afectan la cuenca del río Reno, mostrando que la problemática proviene de la descarga, tanto en términos de cantidad como de tiempo. La simulación muestra que el sistema acoplado es prometedor en la predicción de picos de descarga con fines de alerta.

Kashiwao et al., (2017) desarrollaron un sistema de predicción basado en redes neuronales artificiales (RNA) en regiones de Japón, que obtiene los datos meteorológicos directamente de internet para realizar la predicción de precipitaciones, utilizando los modelos RNA Perceptrón multicapa (MLP) y una red de funciones de base radial (RBFN). Los resultados mostraron que el volumen de las precipitaciones podía predecirse con precisión y que la tasa de acumulación de las precipitaciones intensas era elevada. Esto sugiere que el sistema propuesto puede predecir fuertes precipitaciones locales inesperadas.

En su investigación, Gutierrez-Lopez et al., (2019a) proponen un modelo sencillo de previsión de precipitaciones a partir de datos monitorizados a cada minuto, como humedad, temperatura superficial, presión atmosférica y punto de rocío. Con acceso a una base de datos base de datos histórica de 1237 tormentas, el modelo propuesto permite utilizar la combinación adecuada de estas variables

para hacer una previsión precisa del momento de inicio de la tormenta. Los resultados indican que la metodología propuesta fue capaz de predecir el inicio de la precipitación en función de la presión atmosférica la humedad y el punto de rocío.

Por otro lado, Muñoz-mandujano et al., 2022, propusieron un modelo de predicción de precipitaciones denominado CRHUDA, el cual es un modelo autorregresivo (ARMA) añadiendo un componente de medias móviles (MA), a partir de datos monitorizados cada minuto el cual demostró que la precipitación puede predecirse en función de la presión atmosférica, la humedad y el punto de rocío, como se muestra en la figura 4. El modelo fue capaz de predecir el inicio de la precipitación implementándose como herramienta hidroeinformática en la Red de Monitoreo de Precipitaciones Extremas de la ciudad de Querétaro, México (RedCIAQ).




Figura 4. Ejemplo de la serie temporal obtenida a partir de datos de presión y humedad en el mismo momento en que se produce la lluvia. Fuente (Muñoz-mandujano et al., 2022).

También, Benevides et al., (2019), realizaron una metodología para determinar la predicción a corto plazo de lluvias intensas, misma que se basa en una red neuronal integrada con datos del Sistema Global de Navegación por Satélite (GNSS) en Lisboa, Portugal, recopilando también datos de la cima de las nubes del Spinning Enhanced Visible and Infrared Imager (SEVIRI) que proporciona información cada hora. Los resultados indicaron que el vapor de agua precipitable no contiene suficiente información para inferir lluvias futuras.

En México, el Centro de Ciencias de la Atmósfera de la UNAM, utiliza un Modelo de Investigación y Pronóstico del Agua para obtener pronósticos del clima

para todo el país. Velázquez-Ruiz et al., 2022, realizaron una comparación entre datos de pronóstico arrojados por el modelo y datos observados registrados para lluvia en la Bahía de Banderas, figura 5, en el que pudieron observar que el modelo predijo solo el 25.7% de los días de lluvia que se observaron.




Figura 5. Modelo de elevación Digital para la zona de estudio. Fuente (Velázquez-Ruiz et al., 2022).

Por otro lado, R. Johnson, 1980, realizó un modelo multivariado de predicción de lluvia, mediante un modelo no- estacionario, en él incluyó la velocidad y la dirección de la tormenta como variables externas, así como el tiempo de llegada de la tormenta, alimentado con datos de pluviómetros telemétricos, en el cuál concluyó que la parte más crítica es la capacidad de predecir la llegada de las tormentas, así como que la precisión de la predicción aumenta con el tiempo real.

Con base en la decisión de qué modelo estocástico multivariado aplicar, se realizó una comparación entre técnicas multivariadas y univariadas autorregresivas para la aplicación de lluvia- escorrentía, determinando que los pronósticos para modelos multivariados autorregresivos son más precisos que las predicciones univariadas basadas en AR.



En cuestión de investigaciones relacionadas a estimación de datos de precipitaciones mediante teledetección, en su investigación, Giovannettone & Barros, (2008) utilizaron datos del satélite TRMM de la NASA, con el sensor pasivo TRMM Microwave Imager (TMI) y de los satélites GOES de la NOAA. Se utilizaron para estudiar la organización orográfica de las precipitaciones nubosas en el centro y sur de México. Todos los rasgos de precipitación se encontraron predominantemente a lo largo de las crestas de los valles durante las horas de la tarde. También, los datos del GOES muestran un aumento de la nubosidad sobre la Sierra Madre Occidental (SMO), la Sierra Madre del Sur (SMS) y el Cinturón Volcánico Trans-mexicano (TMVB) durante la tarde y sobre la Cuenca del Balsas y la RGS durante la madrugada. Por último, concluyen que realizar un estudio con datos sólo del TRMM y GOES no es suficiente debido a la corta historia del conjunto de datos.

Teniendo en cuenta la investigación de Paz & Ríos, (2021), en la cual se desarrolló un algoritmo que permite estimar la precipitación mediante la relación de datos de precipitación obtenidos de estaciones hidrometeorológicas en la Provincia de Córdoba, y las temperaturas del tope de las nubes obtenidas a partir de información satelital proporcionadas por el satélite GOES 13. Dicho hidroestimador no resultó muy adecuado para eventos a corto plazo debido al error promedio del análisis del 6%.

De Goncalves et al., (2006) realizan una comparación entre tres diferentes productos para estimaciones de precipitación del Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN), National Environmental Satellite, Data and Information Service (NESDIS), y Tropical Rainfall Measuring Mission (TRMM) con las calculadas por el modelo CPTEC Eta para Sudamérica. Los resultados mostraron que los datos calculados por el modelo CPTEC Eta superan a los productos de teledetección comparados.

Macharia et al., (2020) exponen que los datos de precipitación obtenidos mediante teledetección muestran un gran potencial para complementar los datos de estaciones meteorológicas que se ven acompañados por la inconsistencia y la



escasez, pues determinaron la precisión de cuatro productos basados en teledetección, CHIRPS 2.0, TMPA-TRMM, Global Precipitation Climatology Project (GPCC) y MERRA, para Kenia, los cuales sobrestiman o subestiman la precipitación de acuerdo a determinadas áreas.

Por otro lado, Pombo et al., (2015) examinaron el rendimiento de cuatro productos satelitales en Angola; TRMM versión 6, GPCP, Precipitation Estimation from Remotely Sensed Information using Artificial Neural Networks (PERSIANN) y la técnica de morphing (CMORPH). Determinaron que las estimaciones del TRMM son más precisas que las de los otros productos.

Con base en la aplicación y desarrollo de modelos estocásticos, Scheidereite & Faure, (2015) desarrollaron un modelo autorregresivo integrado de media móvil (ARIMA) para cada serie de datos histórico de registros pluviométricos esto para describir adecuadamente su comportamiento, encontrando entonces, un modelo particular para cada serie de lluvia, aunque en algunos casos no fue demasiado satisfactorio debido a que los parámetros estacionales, en algunas series, son significativamente distintas de cero.

Por otra parte, Calderón, (2018), expone que los modelos híbridos estocásticos-determinísticos constituyen una interesante y potencial herramienta de simulación y predicción a escalas espacio-temporales empleadas en la actualidad para la gestión de los recursos hidráulicos.

Zhiña et al., (2017) desarrollaron un modelo de pronóstico de sequías para seis meses en adelante mediante un ARIMA en la microcuenca del río Chulco, en Ecuador, para el cual se construyeron 6 modelos en los que se obtuvieron mejores pronósticos para tres meses en el futuro.

Por último, respecto a los sistemas de alerta temprana, Saucedo, (n/d.), desarrollará un sistema de alerta temprana para el pronóstico a corto plazo de lluvias intensas en la ciudad de Morelia, usando una Red Neuronal Artificial (RNA), la cual ante la detección de lluvias intensas, emitirá alertas, mismas que serán integradas en una plataforma digital de consulta para el público en general.



6. JUSTIFICACIÓN

Los fenómenos extremos asociados a parámetros hidrometeorológicos, como las inundaciones, y la falta de información de mediciones en dichos parámetros, pueden tener efectos perjudiciales y ser una fuente de peligro a escala regional y mundial (Michaelides et al., 2009).

Según Hernández & Vieyra, (2010), en la ciudad de Morelia Michoacán, los antecedentes muestran que el aumento del área urbana, malos asentamientos de viviendas, las precipitaciones de gran intensidad y magnitud han incrementado el riesgo de desastre por inundaciones en la periferia de la ciudad.

Esto indica que, resulta imperativo y necesario tener un conocimiento anticipado de las variables extremas, refiriéndonos a lluvias intensas, que podrían desencadenar dichos desastres naturales. Para esto se propone desarrollar un sistema de predicción de precipitaciones, el cual nos permitirá conocer, a un corto plazo (escala subdiaria) el comportamiento futuro de las mismas, realizándose con una metodología diferente a las ya existentes, que implica obtener dichas precipitaciones mediante información satelital, integrándola en un modelo estocástico que nos arrojará series de predicción.

Cabe mencionar que, ante la falta de información de mediciones de precipitación a escalas pequeñas (subdiarias), así como la cobertura insuficiente de aparatos de medición en la superficie terrestre, específicamente en México, se requiere recurrir a otro método que proporcione mediciones de precipitación a escalas temporales y espaciales constantes y de mayor cobertura como es la información satelital, lo cual marca una ventaja ante la información escasa de precipitaciones.

Actualmente, existen procesamientos de estimación y predicción de precipitación basada en algoritmos diferentes a los modelos estocásticos, como redes neuronales artificiales, por mencionar alguno; también se han aplicado



metodologías que emplean algoritmos combinados con los ya mencionados. Por tales motivos la metodología que se aplicará permitirá demostrar la confiabilidad de los modelos estocásticos alimentados con información satelital como modelo de predicción.

No obstante, no es suficiente con tener un sistema de predicción de precipitaciones en una zona de interés, por lo cual, es necesario aplicarlo a un sistema que emita alertas a un muy corto plazo, del orden de minutos, que permita a la población tener un tiempo de evacuación suficiente ante una inundación, haciendo contrapeso a los sistemas de alerta actuales en Morelia, mismos que son emitidos en tiempo real, por lo que no proveen de un tiempo de reacción a la población.



7. METODOLOGÍA

La metodología general empleada en esta investigación se plantea en el siguiente esquema metodológico, presentado en la figura 6.

Dicha metodología se llevó a cabo en varias etapas para poder cumplir con los objetivos propuestos. La primera etapa consiste en la recopilación de datos de variables climáticas, especialmente de lluvia, tanto observadas (estaciones meteorológicas) como de mediciones indirectas (satélite o de percepción remota (PR)), así como la validación de la información climática de PR para su aplicación, el cual es uno de los principales objetivos de esta investigación.

La siguiente etapa consiste en el tratamiento de los datos climáticos para su reconocimiento y conocer el comportamiento de la lluvia para realizar un modelo estocástico multivariado (MEM) que nos de paso a la realización de la predicción de lluvia.




Figura 6. Ruta metodológica para el desarrollo del sistema de predicción.

7.1. Recopilación y gestión de datos

7.1.1. Estaciones meteorológicas

Se muestra la metodología para la obtención y análisis de las estaciones meteorológicas a emplear en la figura 7.




Figura 7. Metodología para la obtención y análisis de estaciones meteorológicas.

Para las series de precipitación obtenidas de estaciones meteorológicas se tomará en cuenta que las estaciones brinden información en escala temporal pequeña (minutal u horaria), esto debido a los requerimientos del modelo a corto plazo.

Para esto, se obtendrán datos de precipitación de las estaciones del Organismo Operador de Agua Potable y Saneamiento de Morelia (OOAPAS) (OOAPAS, 2022), debido a que cuentan con mediciones a los 5 minutos, también se descargarán series de precipitación de la base de datos de la Comisión Nacional del Agua (CONAGUA) (CONAGUA, 2022), estos datos se encuentran en escala diaria, que permitirá realizar un análisis de validación para las estaciones de OOAPAS que permitirá aceptar la utilización de sus datos climáticos.

De ambas bases de datos, se descargan las estaciones meteorológicas que se encuentren cercanas a la zona de estudio, en este caso la mancha urbana de la



ciudad de Morelia, para poder ubicarlas espacialmente y así determinar las que tengan mayor influencia espacial en la zona.

Así mismo se lleva a cabo la gestión de los datos mediante una rutina de Matlab (Casado Fernández, n.d.), la cual permite comparar las dos bases de datos de información para validarlos. Dicha rutina permite uniformizar los datos en cuestión de escala temporal, así como obtener las series horarias, diarias y mensuales de las estaciones meteorológicas para su posterior comparación.

Finalmente, se realiza una comparación de los datos, que permita validar los mismos, por medio de los estadísticos de media, desviación estándar y sesgo.

Como parte complementaria a las mediciones de datos de precipitación minutales u horarias de las estaciones meteorológicas, se analiza la estación de la Red Universitaria de Observatorios Atmosféricos (RUOA) de la Universidad Autónoma de México (UNAM, 2023), misma que cuenta con mediciones de variables climáticas a cada minuto.

Asimismo, contando con los datos climáticos de la estación del Servicio Meteorológico de Morelia (SMM) de la CONAGUA, se lleva a cabo la uniformización de datos a la escala deseada, de ser necesario.

De la misma manera, se obtienen los registros de las variables climáticas que midan las diferentes estaciones meteorológicas con las que se cuenta.

7.1.2. Información satelital

Para la obtención de información de precipitación de satélite se analizan varios algoritmos de misiones satelitales, lo cuales se presentan a continuación.

- **CHRS Data Portal:**

Se presenta el proceso de obtención de datos para con el CHRS en el esquema presente en la figura 8.




Figura 8. Metodología para obtención de datos del CHRS Data Portal.

Se eligen eventos de tormentas o lluvias intensas y atípicas que han ocurrido en la ciudad de Morelia, esto debido a que serán los datos que se procesarán en el modelo estocástico a realizar posteriormente.

En el portal de CHRS, se toma en cuenta el área de estudio, el algoritmo a aplicar, así como los días en los cuales se requiera obtener la información para posteriormente proceder a descargar los productos.

A continuación, se procesan los datos en un SIG, el cual nos permitirá obtener una malla con los datos de precipitación para cada pixel en el tiempo requerido, generando una tabla de recopilación de datos.

- **AWS GOES 16 Reader Software Version 1.0.**

La metodología a seguir para la obtención de la información mediante el código de AWS se presenta en la siguiente figura.




Figura 9. Metodología para rutina de satélite GOES 16.

Primeramente, es de suma importancia descargar las carpetas necesarias de Dropbox para ejecutar la rutina, estas se descargarán una a una para evitar problemas en los archivos y se ordenarán de manera similar a la del archivo de origen en Dropbox.

Posteriormente, se descargan los días de archivos necesarios por medio de una rutina de Python para después, colocarla en la carpeta Imagery correspondiente.

Finalmente, se ejecuta el código del GOES 16, colocando las rutas correspondientes, para posteriormente, obtener los datos procesados en una carpeta generada externa.

- **Integrated Multi-satellitE Retrievals for GPM (IMERG) del Global Precipitation Measurement (GPM) v6.**

Se presenta en la figura 10, la metodología para la obtención de series de estimación de lluvia mediante el algoritmo satelital IMERG.




Figura 10. Ruta metodológica para la obtención de series de estimaciones de lluvia mediante IMERG.

Se obtienen series temporales de estimación de precipitación mediante la plataforma de Google Earth Engine (GEE), del algoritmo IMERG de la GPM, mediante una rutina de descarga, en lenguaje PYTHON y Java Script, las cuales se obtienen con base en el periodo histórico con que se cuente en las estaciones meteorológicas a utilizar y a escala temporal horaria.

Para la investigación, se propusieron dos metodologías para obtener las series de estimaciones de lluvia, esto para poder comparar ambos métodos y determinar el mejor. Uno de ellos es la descarga de la serie de estimación por Punto-Pixel (PP), que básicamente consiste en localizar geográficamente un punto que coincida con la ubicación espacial de la estación meteorológica, que se vaya a

utilizar para la validación, en el mapa de trabajo de GEE, lo cual permite descargar la información en ese punto establecido.

La otra metodología consiste en aplicar una Interpolación Bilineal Ponderada (IBP) aplicada por (ud din et al., 2008). La metodología implementada consiste en calcular el promedio de cuatro píxeles contiguos para una ubicación específica de interés (Kuehl & Sacchi, 2020). Se presenta el siguiente ejemplo en la figura 11, la cual representa una cuadrícula de 2 x 2, representando el punto de interés (X, Y) y los pesos de las ubicaciones de los puntos contiguos. En el contexto de la interpolación bilineal, se adopta un enfoque simplificado, en el cual se determina el valor del píxel en una posición específica (X, Y) mediante la consideración de cuatro valores de píxeles contiguos. La contribución de cada píxel al cálculo es ponderada según su proximidad a la posición (X, Y) (ud din et al., 2008).




Figura 11. Representación de la estimación del peso de las ubicaciones en una cuadrícula de 2 x 2. Tomado de (ud din et al., 2008).

Entonces, los pesos de IBP se pueden calcular de la siguiente manera según (Arnold et al., 2002).

$$X = S_x X_1 + (1 - S_x) X_2 \quad (12)$$



$$S_x = \frac{X - X_1}{X_2 - X_1} \quad (13)$$

$$Y = S_y Y_1 + (1 - S_y) Y_2 \quad (14)$$

$$S_y = \frac{Y - Y_1}{Y_2 - Y_1} \quad (15)$$

Donde $0 \leq S \leq 1$, $X_1 \leq X \leq X_2$.

Con esto se calcula el valor actual del pixel de interés $I(X, Y)$, el cual resulta de:

$$I(X, Y) = (1 - S_x)(1 - S_y)I(X_1 Y_1) + S_x(1 - S_y)I(X_2 Y_1) + (1 - S_x)S_y I(X_1 Y_2) + S_x S_y I(X_2 Y_2) \quad (16)$$

De esta manera, se obtienen las series temporales de estimaciones con ambas metodologías para realizar una validación mediante un análisis de correlaciones posterior.

7.2. Validación de series temporales de estaciones meteorológicas

Primeramente, se comparan los datos de las estaciones meteorológicas de OOAPAS, las cuales, en un inicio, cuentan con mayor incertidumbre de calidad en los datos, con los datos diarios de lluvia de las estaciones de CONAGUA, calculando diversos estadísticos que permitirán corroborar la calidad de los datos, los cuales se presentan a continuación.

Para los registros de lluvia provenientes de las estaciones de la RUOA y del SMM se llevará a cabo una validación solo si existe un número considerable de vacíos o mala calidad en los datos, caso contrario, se tomará la información como válida.

7.2.3. Estadísticos para la validación de datos.

- *Media:*

La media es prácticamente el promedio de los datos que se tienen, se calcula con:

$$M = \frac{\sum_{i=1}^N x_i}{N} \quad (17)$$

Donde M es la media aritmética, x_i representa la observación número i de la variable medida y N el número total de datos (Bacchini et al., 2018)

- *Desviación estándar:*

Nos indica qué tan dispersos están los datos con respecto a la media, calculándose como:

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - M)^2}{N}} \quad (18)$$

Donde σ representa la desviación estándar, x_i observación número i de la variable medida, M es la media de la variable y N el número total de datos en la variable (Bacchini et al., 2018).

- *Sesgo:*

Se conoce también como asimetría, e indica la simetría de la distribución en los datos con respecto a la media, se calcula como sigue:

$$g_1 = \frac{\frac{1}{n} \sum (x_i - M)^3 * n_i}{\frac{1}{n} \sum (x_i - M)^2 * n_i^{\frac{3}{2}}} \quad (19)$$

Donde g_1 representa el coeficiente de asimetría de Fisher, x_i observación número i de la variable medida, M la media de los datos de la variable y n_i la frecuencia de cada valor.

Para el coeficiente de asimetría pueden resultar tres valores: positivo, negativo y simétrico.



Cuando resulta un coeficiente de asimetría positivo indica que la mayoría de los datos se encuentran por encima del valor de la media. De igual manera, cuando el coeficiente de asimetría es negativo, la mayor cantidad de datos se aglomeran en los valores menores a la media. Por último, si el coeficiente de asimetría es cero, hay el mismo número en la izquierda y en la derecha de la media (Bacchini et al., 2018)

Entonces, mediante gráficos, se compararán, ambas series con respecto a los estadísticos calculados, observando cómo se comportan y qué tanta variación existe entre ellos.

Asimismo, se realiza una uniformización de escala temporal en las series de datos de las estaciones, debido a la variación temporal con que cada organismo realiza las mediciones de las variables climáticas.

7.3. Análisis de correlaciones y validación para estimaciones y datos observados de lluvia

Para este análisis, se aplicará la metodología descrita en la figura 12, entre las series de estimación de lluvia PP y de IBP validando con los datos de series temporales de una estación meteorológica, llamados en esta investigación como datos observados de lluvia.




Figura 12. Metodología para análisis de correlaciones y validación entre series de IMERG y de datos observados de lluvia.

Para la validación de las series de estimación de lluvia de IMERG, se realizará un análisis de correlaciones mediante el coeficiente de correlación de Pearson (r), BIAS relativo (RB) y la raíz cuadrada media del error (RMSE), a las series de estimación de precipitación del satélite con respecto a los datos observados. Se presentan en la siguiente tabla las fórmulas de cada estadístico y los valores aceptables tomado de (Blanco & Demaria, 2023).

$$r = \frac{\sum_{k=1}^m (S_n - S')(O_n - O')}{\sqrt{\sum_{k=1}^m (S_n - S')^2} \sqrt{\sum_{k=1}^m (O_n - O')^2}} \quad (20)$$

$$RMSE = \sqrt{\frac{1}{m} \sum_{k=1}^m (S_n - O_n)^2} \quad (21)$$

$$BIAS = \frac{\sum_{k=1}^m (S_n - O_n)}{\sum_{k=1}^m O_n} \times 100 \quad (22)$$

Donde m es el tamaño de la muestra; S_n son las estimaciones de precipitación satelital; O_n son las observaciones de la estación meteorológica; S' es la media de las estimaciones de precipitación satelital; O' es la media de las observaciones de la estación meteorológica.

Asimismo, se presentan los valores y rubros para la validación de las estimaciones con base en los estadísticos descritos.

Tabla 3. Valores para estadísticos de la validación para estimaciones de lluvia.

Estadístico	Valor perfecto	Valores	
Coeficiente de correlación de Pearson	1	$r(+)$: Relación directa	$r(-)$: Relación indirecta
BIAS relativo	0	RB(+): Sobreestimación	RB(-): Subestimación
Raíz del error cuadrático medio	0	RMSE > 0 mayores errores en las estimaciones de precipitación	

Dicho análisis determinará la validez de las estimaciones de satélite de IMERG mediante correlaciones, la cual permitirá realizar la corrección de sesgo con base en las mediciones directas de la estación meteorológica para así poder utilizar los pixeles que cubran la ciudad de Morelia.

Caracterización de eventos de lluvia

Para las series que cumplan con la validación, tanto de lluvias observadas como de estimaciones de satélite, después de contar con las series a una escala temporal



horaria, se determinan los eventos de lluvia con base en la ocurrencia de la misma y todas las duraciones en horas que se tengan registradas en el periodo histórico analizado.

Con base en las duraciones registradas para lluvia, se determinará si existe algún patrón, así como cuál es el comportamiento de la lluvia en la ciudad de Morelia.

7.4. Aplicación de modelo estocástico

Se sabe que, para un modelo de predicción se utilizan datos a escalas más pequeñas como horarias, minútales o en tiempo real (Katz & Parlange, 1995; Koch & Naveau, 2015)

Para esta investigación, el objetivo principal es desarrollar un modelo estocástico multivariado, el cual se realiza con información de eventos de lluvia a diferentes duraciones, que tome en cuenta la variabilidad espacio-temporal de los datos de lluvia, basados en series horarias, de acuerdo a la distribución y variabilidad de la lluvia que se determine con base en los datos con que se cuente.

Se presenta la metodología del modelo estocástico en la figura 13.




Figura 13. Proceso de modelación estocástica.

7.4.1. Ocurrencia y cantidad de precipitación

Para la aplicación de modelos estocásticos de lluvia, ha sido ampliamente utilizado el modelo Markoviano de dos estados para análisis de corta memoria (húmedo o seco) (Wilks, 1998), para el cual, el primer estado representa la no ocurrencia de precipitación y el segundo los periodos donde ocurre precipitación.

Para definir la ocurrencia o no ocurrencia de precipitación entonces, es importante definir las probabilidades de que estas se presenten en un tiempo dado, así como las probabilidades de que no se presente. Sin embargo, para esta

investigación, debido a que se realizará con eventos de lluvia horarios, solo se tomará en cuenta la probabilidad de que estos ocurran, es decir, un modelo Markoviano de un estado (húmedo).

7.4.2. Normalización

Debido a que las técnicas estadísticas aplicadas a series temporales en hidrología se desarrollan suponiendo que las variables se distribuyen normalmente (Salas et al., 1980).

Entonces el proceso estocástico se lleva a cabo mediante funciones de distribución. Por ello se deberá aplicar alguna transformación estadística para que las series se asemejen a la distribución normal y se reduzca el sesgo a cero, práctica útil para modelar la cantidad de precipitación.

Aplicando transformaciones de normalización se realizará el proceso de la figura 14.




Figura 14. Normalización para los datos de lluvia.

Se han modelado transformaciones de la función gamma, logarítmica y el doble logaritmo normal, gamma, log gamma (Bardossy & Plate, 1992; Krishnamoorthy et al., 2008; Qian et al., 2008; Salas et al., 1980), transformaciones



no paramétricas y transformaciones paramétricas como la Box-Cox (Box & Cox, 1964), estas transformaciones se aplicarán a las series utilizadas en este proyecto, buscando asemejar los datos a la distribución normal, mostrándose así las ecuaciones de cada transformación con base en (Salas et al., 1980).

$$y_t = \text{Log} (Pr_t + 1) \quad (23)$$

$$y_t = \text{Log}(\text{Log} (Pr_t + 1) + 1) \quad (24)$$

$$y_t = \sqrt[3]{Pr_t} \quad (25)$$

$$y_t = \text{Log} (\sqrt[3]{Pr_t} + 1) \quad (26)$$

$$y_t = \text{Log} (\sqrt[3]{Pr_t} + 1) \quad (27)$$

Donde y_t es un vector de la precipitación normalizada para el minuto t , Pr_t son vectores originales de las diferentes series.

7.4.3. Análisis de dependencia temporal

Series de Fourier

La dependencia temporal se describe a través de la correlación con los datos previos al dato bajo análisis. Debido a la corta memoria en las variables climáticas, se sugiere la aplicación del modelo autorregresivo AR(p) con un nivel reducido de dependencia, como AR(1) o AR(2) (Hernández Bedolla, 2021).

Una de las características más importantes del proceso de precipitación es la variabilidad estacional. La cantidad de precipitación cambia periódicamente con el año (minuto, hora, día, semana, mes, etc); parámetros como media, desviación estándar y coeficientes autorregresivos también presentan periodicidad (Papalexiou, 2018), cantidad de parámetros que se define con base en la escala temporal estudiada, la cual es necesario reducir con series de Fourier para preservar la parsimonia del modelo.



7.4.4. Estandarización

Una vez que se reduzcan los parámetros del modelo se procederá a homogeneizar la serie mediante el proceso de estandarización.

La estandarización transforma la serie con una media y desviación estándar dada, por lo que se tiene que remover la media a cero y la varianza a uno $\mu \cong 0$ y $\sigma \cong 1$. Se realiza entonces mediante las medias y desviaciones parametrizadas en cada caso eliminando la periodicidad de la serie. Se presenta la ecuación 12 a utilizar para este proceso.

$$z_{\tau} = \frac{y_{\tau} - \hat{\mu}}{\hat{s}} \quad (28)$$

Donde z_{τ} es la serie estandarizada $\hat{\mu}$ y $\hat{s}$ son vectores de medias y desviaciones estándar respectivamente para las duraciones en minutos τ con precipitación.

7.4.5. Análisis de correlación temporal y espacial

Se analizará la correlación y autocorrelación de la serie, proceso importante debido a que permite seleccionar el orden y tipo de modelo que mejor se adapte a las condiciones de dependencia de la información con que se cuente, para un modelo univariado.

Sin embargo, una vez tomando en cuenta la correlación espacial según (Hernández Bedolla, 2021), pueden cambiar varios aspectos en el modelo. Uno de ellos es que la ocurrencia de precipitación además de tener relación con lo sucedido en un desfase de tiempo $t-1$, tiene relación con el comportamiento de la lluvia en los puntos cercanos donde se tenga información climática, así como para la cantidad de lluvia.

La función de autocorrelación para la serie normalizada y estandarizada univariada se presenta en la ecuación.

$$r_k(z) = \frac{\sum_{t=1}^{N-k} (z_t - \bar{z}_t) (z_{t+k} - \bar{z}_{t+k})}{\sqrt{\sum_{t=1}^N (z_t - \bar{z})^2 \sum_{t=1}^N (z_{t+k} - \bar{z}_{t+k})^2}} \quad (29)$$

Donde $r_k(z)$ es el coeficiente de autocorrelación con retraso de tiempo k , z_t es el vector normalizado y estandarizado, $\bar{z}_t$ es el promedio de z_t , z_{t+k} es el vector normalizado y estandarizado para horas siguientes y N es el número de datos en estudio.

Con base en la metodología de (Hernández Bedolla, 2021), otro caso para el análisis de dependencia espaciotemporal se calcula la correlación cruzada con los puntos de información climática que se tengan, calculada por la ecuación 30, la cual da como resultado una matriz de correlación cruzada (31).

$$r_k^{ij}(z) = \frac{\sum_{\tau=1}^{N-k} (Z_{\tau}^i - z'_{\tau}^i) (Z_{\tau+k}^j - z'_{\tau+k}^j)}{\sqrt{\sum_{\tau=1}^N (Z_{\tau}^i - z'_{\tau}^i)^2 \sum_{\tau=1}^N (Z_{\tau+k}^j - z'_{\tau+k}^j)^2}} \quad (30)$$

$$[MC_k] = \begin{bmatrix} r_k^{(1,1)} & \dots & r_k^{(1,n)} \\ \dots & \dots & \dots \\ r_k^{(n,1)} & \dots & r_k^{(n,n)} \end{bmatrix} \quad (31)$$

Donde $[MC_k]$ es la matriz de correlación cruzada para la estaciones o puntos que se tengan, para los distintos lags o desfases temporales k , r_k^{ij} es el coeficiente de correlación entre las series i, j con que se cuente y n es el número de estaciones o puntos con que se cuente.

Así pues, el modelo multivariado autorregresivo de orden se obtiene mediante la siguiente ecuación.

$$\{z\}_t = [\Phi]_1 \{z\}_{t-1} + [\Phi]_2 \{z\}_{t-2} + [\Phi]_3 \{z\}_{t-3} + \dots + [\Phi]_p \{z\}_{t-p} + [\Phi]_0 \{\varepsilon\}_t \quad (32)$$

Donde $\{z\}_t$ es el vector de series estandarizadas en el tiempo t , $[\Phi]_p$ es la matriz de coeficientes autorregresivos multivariados de orden p , $[\Phi]_0$ es la matriz de correlación espacial de orden 0 y $\{\varepsilon\}_t$ es el vector de residuos.

Con base en la memoria de las series analizadas se determinará el orden del modelo, ya que las que poseen corta memoria, decaen rápidamente a cero, caso contrario las de larga memoria.

7.4.6. Generación de series residuales y validación del modelo

Para la generación de series residuales del modelo se parte del análisis de correlación temporal y espacial, con la cual se determina el orden del modelo y con ello los parámetros estocásticos adecuados que permiten generar la serie de predicción del modelo, la cual se resta a la serie histórica generando la serie de residuos, como se muestra en la ecuación 33.

$$\{\varepsilon\}_t = [\Phi]_0^{-1}(\{z\}_t - [\Phi]_1\{z\}_{t-1} - [\Phi]_2\{z\}_{t-2} - \dots - [\Phi]_p\{z\}_{t-p}) \quad (33)$$

Donde $\{\varepsilon\}_t$ es el vector de la serie residual en t , $\{z\}_t$ son las series normalizadas y estandarizadas y $[\Phi]_p$ es la matriz de coeficientes autorregresivos para el modelo multivariado.

El proceso se acepta si la serie residual se comporta como un ruido blanco, es decir, no debe presentar dependencia temporal y comportarse como una distribución normal, así como tener media igual a cero.

Además, para determinar el desempeño del modelo se aplica el criterio de Akaike, que depende de la varianza del error y nos indica si el modelo empleado es el más adecuado para representar las propiedades estadísticas de las series históricas.

7.4.7. Generación de series sintéticas

Dicho proceso se realizará aplicando de forma inversa la modelación estocástica, generando primeramente números aleatorios que tengan distribución normal. Para el presente caso se generarán series sintéticas de igual longitud al



periodo histórico. Entonces, con la ecuación 14 se obtienen las series estandarizadas.

$$\hat{z}_t = \phi_1 \hat{z}_{t-1} + \phi_2 \hat{z}_{t-2} + \phi_3 \hat{z}_{t-3} + \dots + \phi_p \hat{z}_{t-p} + \varepsilon s_\varepsilon \quad (30)$$

Donde $\hat{z}_t$ es la serie estandarizada generada para la escala temporal en estudio o $\hat{z}_{t-p}$ anteriores, ϕ_p son los parámetros autorregresivos, s_ε la varianza del error y ε la serie normal estándar o ruido blanco. Posteriormente se desestandarizan las series mediante la ecuación 15.

$$\hat{y}_t = \hat{\mu}_t + \hat{s}_t \hat{z}_t \quad (31)$$

Donde $\hat{y}_t$ es la serie desestandarizada para la escala temporal de estudio con ocurrencia de precipitación, $\hat{\mu}_t$ y $\hat{s}_t$ son las medias y desviaciones estándar de las duraciones con precipitación.

Y posteriormente, se obtendrán las series sintéticas finales mediante la normalización inversa de las funciones de transformación logarítmica, doble logarítmica, gamma, log-gamma y raíz cuadrada ecuaciones 16 a 20 de acuerdo a la transformación aplicada inicialmente en el modelo.

$$\widehat{Pr}_t = e^{\hat{y}_t} - 1 \quad (32)$$

$$\widehat{Pr}_t = e^{(e^{\hat{y}_t} - 1)} - 1 \quad (33)$$

$$\widehat{Pr}_t = \hat{y}_t^3 \quad (34)$$

$$\widehat{Pr}_t = (e^{\hat{y}_t} - 1)^3 \quad (35)$$

$$\widehat{Pr}_t = \hat{y}_t^2 \quad (36)$$

Las series sintéticas deberán tener la misma longitud de la serie histórica analizada, aunado a que se debe tener un periodo de calentamiento (Hernández Bedolla, 2021).

Para validar las series se calculará la media de las series observadas modeladas y de las series sintéticas, estas mostrarán si las series sintéticas guardan las características estadísticas de la serie temporal analizada, las cuales se graficarán en un diagrama de dispersión determinando la relación proporcional que tienen ambas medias.

7.5. Desarrollo de un análisis de componentes principales (ACP)

Se presenta el esquema de metodología para el desarrollo de un ACP en la figura 15, esto para determinar las variables climatológicas importantes presentes en meses húmedos, debido a que se aplicarán para la generación de las series de predicción.




Figura 15. Metodología para ACP para variables climáticas.

Primeramente, se elegirá una estación de OOAPAS que tenga una mayor cantidad de datos para calcular series mensuales de precipitaciones.

Las variables climáticas a utilizar, que conformarán la matriz inicial, se elegirán de las variables que mida dicha estación.



Se realizará el ACP en el software JMP mismo en el que se analizará de manera gráfica y de suma importancia, la varianza explicativa de las variables, así como la correlación para determinar la redundancia en la información y proceder a depurar dicha matriz que nos permita observar qué variables juegan un papel importante en la ocurrencia de precipitación.

7.6. Series de precipitación de predicción

Para obtener un dato de predicción, se utilizará la ecuación general del modelo estocástico multivariado a utilizar, dicha ecuación relaciona el valor pasado, así como los parámetros del modelo con base en las series históricas analizadas y por último, la serie de ruido blanco, que representa el error entre los datos observados y la simulación.

Para determinar la predicción con el modelo se utiliza la siguiente ecuación:

$$\{Z_t\} = [\theta]_1\{Z_{t-1}\} + [\theta]_0\{\varepsilon_t\}$$

Donde $\{Z_t\}$ es el vector estandarizado de precipitaciones, $[\theta]_1$ es la matriz de parámetros autorregresivos con desfase de 1 hora, $[\theta]_0$ es la matriz de parámetros autorregresivos. $\{\varepsilon_t\}$ es el vector de ruido blanco con distribución normal con media cero y desviación estándar 1, $\{Z_{t-1}\}$ es el dato de entrada normalizado de la hora previa a analizar. Posteriormente se procede a la desnormalización para obtener el valor real de la precipitación.

8. CASO DE ESTUDIO

La ciudad de Morelia se localiza en el Estado de Michoacán, en la región central de la República mexicana. La zona comprende un área urbana de 85 km² y se encuentra entre las coordenadas 19°38' y 19°50' N y los 101°06' y 101°18' W, con una altitud de 1920 msnm.

Las corrientes superficiales principales son el río Grande y el río Chiquito, como también en la temporada de lluvias se presenta el afluente Arroyo de Tierras.

El clima en la zona es templado subhúmedo con temperaturas que van desde los 5 a los 29°C. La precipitación media anual que se presenta es de 780 mm (Hernández et al., 2014).




Figura 16. Delimitación de la zona urbana de la ciudad de Morelia, Michoacán.

9. RESULTADOS Y DISCUSIONES

9.1. Estaciones meteorológicas

Se obtuvieron datos de precipitación y otras variables climáticas de 4 estaciones de OOAPAS las cuales se encuentran a una escala temporal de 5 min, las cuales se muestran en la figura 17, así como series de precipitación de 5 estaciones de CONAGUA mismas que se encuentran a una escala temporal diaria y que cubren la zona de la ciudad de Morelia, debido a que, primeramente, solo se contaba con la información de estos dos organismos mencionados.

Para las estaciones de OOAPAS, se tuvo que realizar una rutina en Matlab la cual permitiera trabajar con el tipo de formato de tiempo de los datos y así poder uniformizarlas a registros de 30 minutos. Posteriormente, se calcularon las series horarias, diarias y mensuales, como se observa en la siguiente figura. Dichas gráficas permitieron observar la gran falta de datos de registro en un periodo del




Figura 17. Series horarias para estaciones meteorológicas de OOAPAS.

2010 al 2015 para dichas estaciones.

Posteriormente se calcularon las series mensuales de las estaciones de CONAGUA, las cuales se presentan en la figura 19, en las cuales se pueden observar un periodo de registro más completo, sin embargo, la estación Cointzio es la que tiene una mayor falta de datos de precipitación, se muestran espacialmente las estaciones en la figura 18.




Figura 18. Ubicación espacial de las estaciones meteorológicas de CONAGUA.




Figura 19. Series mensuales de las estaciones de la CONAGUA.

Una vez contando con la información climatológica de la estación MORE de la RUOA UNAM, la cual se uniformizó a escala 30 minutal, así como de la estación 76665 del SMM y debido a la gran cantidad de vacíos en las estaciones de OOAPAS, se analizaron los datos de ambas nuevas estaciones, presentándose las series temporales a escala 30 minutal para MORE y horaria para 76665 en la figura 20, así como su localización geográfica en la figura 21.




Figura 20. Series temporales para la estación MORE-UNAM y 76665-SMM.




Figura 21. Localización de estaciones MORE-UNAM y 76665-SMM en la ciudad de Morelia, Michoacán.

Finalmente se presenta un resumen de las características de los registros por estaciones meteorológicas que se analizaron, en la tabla 4, observando que en la ciudad de Morelia aún hay una gran falta de mediciones a escalas horarias o minutales que permitan obtener información tanto espacial como temporal de las variables climáticas, especialmente de las precipitaciones.

Tabla 4. Resumen de características de diferentes estaciones meteorológicas analizadas.

Estación u organismo	Periodo analizado	Ubicación	Años de vacíos
OOAPAS	2006 - 2021	Morelia	5
CONAGUA	2006 - 2021	Morelia	S/v en el periodo
MORE	2015-2018	Campus UNAM, Morelia	Sin vacíos
76665	2015-2018	SMM	Sin vacíos

9.1.1. Comparación de estadísticos en las estaciones

Para las estaciones primeramente analizadas (OOAPAS y CONAGUA) se determinaron las precipitaciones mensuales para cada estación de ambos



organismos, salvo para la estación Cointzio debido a la falta de datos, y se determinaron la precipitación mensual promedio, precipitación promedio anual, desviación estándar y sesgo, para calcular un promedio de cada estadístico para todas las estaciones.

Se puede observar en la tabla 5 que las precipitaciones promedio anual difieren alrededor de los 280 mm, también los valores de los estadísticos de las estaciones de OOAPAS presentan valores bajos en comparación a las estaciones de CONAGUA, razón por la cual no se tomó como válida la información de OOAPAS con base en CONAGUA que es la base de datos oficial que se toma actualmente.

Tabla 5. Comparación de estadísticos para estaciones de OOAPAS y CONAGUA.

ESTADÍSTICO	PROMEDIOS DE ESTACIONES	
	OOAPAS	CONAGUA
Media mensual	41.78	65.34
Media Anual	501.39	784.02
Desviación estándar	42.22	64.18
Sesgo	0.79	0.90

Como se mencionó, debido a que las estaciones MORE y 76665 no tienen vacíos, se decidió tomar la información como válida.

9.2. Obtención de series de estimaciones de precipitación mediante satélite

9.2.1. CHRS Data Portal

Se descargaron los datos de precipitación del portal por eventos de lluvia de interés mediante el algoritmo PERSIANN-CCS, la cual cubre la zona de la ciudad de Morelia Michoacán.

Se eligió primeramente el evento del huracán Willa en Morelia en el año 2018, para el periodo del 19 al 24 de octubre, mismo que presentó grandes daños en la ciudad

de Morelia, esto para corroborar que los datos de precipitación que marca el CHRS coincidan con los datos reales informados por CONAGUA.

Posteriormente, se realizó el manejo y proceso de la imagen en el SIG Qgis, el cual permitió visualizar la malla de pixeles en la zona de estudio, mismas que están a una resolución de 4 km por 4 km, así como obtener los datos de precipitación por pixel.

En la figura 22, se presenta la precipitación acumulada de 66 mm para el periodo de ocurrencia del huracán Willa.

Por otra parte, se obtuvo el informe de la CONAGUA en la cual muestra el mapa de precipitación acumulada (figura 23) para las áreas afectadas por el huracán Willa, en el cual se observa que para la ciudad de Morelia se presentó una precipitación de 70 mm.




Figura 22. Precipitación acumulada del 19 al 24 de octubre del 2018 para el huracán Willa en Morelia del CHRS Data Portal.




Figura 23. Precipitación acumulada (mm) para el huracán Willa en octubre del 2018. (Climatología, 2018).

Con base en la comparación de los datos del PERSIANN-CCS para el huracán Willa (de 66 mm) y el informe de CONAGUA (de 70 mm) se puede observar que el CHRS subestimó la precipitación para dicho evento.

Posteriormente, se recopilaron datos de precipitación del Portal para los siguientes eventos:

- Huracán Carlos (Climatología, 2015): del 14 al 18 de junio del 2015.
- Huracán Dalila (Climatología, 2013): del 30 de junio al 03 de julio del 2013.
- Tormentas (Pública & Civil, 2015): durante el mes de septiembre del año 2003, Michoacán sufrió inundaciones que afectaron 29 colonias de Morelia y 17 municipios.
- Tormentas y lluvias (Pública & Civil, 2015): en el mes de agosto y septiembre del año 2005, por lluvias atípicas se registraron fuertes desbordamientos de ríos en el poblado de Aguililla y en Morelia los ríos Grande y Chiquito afectando a 25 colonias.

Se presentan las precipitaciones acumuladas para el huracán Carlos y Dalila en las siguientes figuras, mismas que se compararon con los informes de CONAGUA para su validación.




Figura 24. Precipitación acumulada para el huracán Carlos del CHRS Data Portal.




Figura 25. Precipitación acumulada (mm) para el huracán Carlos en junio del 2015. (Climatología, 2015).

La CONAGUA muestra una precipitación acumulada para el evento de aproximadamente 15 mm mientras que el PERSIANN-CCS muestra 11 mm, como se observa, el algoritmo muestra una subestimación en este evento.

Para el huracán Dalila, se presenta la precipitación acumulada por PERSIANN-CCS en la figura 26, así como el mapa emitido por la CONAGUA en la figura 27.




Figura 26. Precipitación acumulada para huracán Dalila por CHRS Data Portal.




Figura 27. Precipitación acumulada (mm) para el huracán Dalila en junio del 2013.(Climatología, 2013).

Se pudo observar que para el huracán Dalila, el PERSIANN-CCS marca una precipitación de 10 mm, mientras que la CONAGUA marca una precipitación acumulada para el evento de 15 mm, por lo que se estima que el algoritmo subestima la precipitación para dicho evento.

Con base en este análisis se pudo observar que, el algoritmo PERSIANN-CCS subestima los eventos de lluvia con respecto a los registros de CONAGUA.

Sin embargo, debido a que el algoritmo genera problemas al descargar información de estimaciones de lluvia por series temporales, únicamente permite descargar datos seleccionando un día o un intervalo de días, no resulta usable para la investigación por lo que, se determinó no utilizar la información del algoritmo.

9.2.2. AWS GOES 16 Reader Software Version 1.0

Para la ejecución del código, primeramente se descendieron las carpetas necesarias para que pueda ser ejecutado. Estas se descendieron una por una para evitar problemas en las mismas, así como también, se ordenaron como lo indica el manual de usuario (Forczyk, 2021), como se muestra en la figura 28.

Nuevo vol (F:) > Goes16 >

Nombre	Fecha de modificación	Tipo
Code5	9/10/2022 09:35	Carpeta de archivos
Country_Maps	7/7/2021 09:09	Carpeta de archivos
CountryShapefiles	7/7/2021 09:17	Carpeta de archivos
Distribution	9/10/2022 09:39	Carpeta de archivos
Documents	7/6/2021 14:32	Carpeta de archivos
Forczyk_Python	7/6/2021 15:01	Carpeta de archivos
Grids	7/7/2021 08:52	Carpeta de archivos
Imagery	1/2/2023 16:58	Carpeta de archivos
InterstateSigns	7/7/2021 08:58	Carpeta de archivos
Mat_Files_Geographic	7/7/2021 12:10	Carpeta de archivos
Matlab_Data	7/7/2021 13:22	Carpeta de archivos
Matlab_Maps	7/7/2021 13:23	Carpeta de archivos
MilitaryBases	7/7/2021 16:59	Carpeta de archivos
Missing_Maps	3/4/2022 14:41	Carpeta de archivos
NationalShapefiles	7/7/2021 17:00	Carpeta de archivos
Natural_Earth	7/7/2021 17:04	Carpeta de archivos
USStateBoundaryFinalFiles	7/8/2021 08:34	Carpeta de archivos
USStateShapeFiles	7/7/2021 22:22	Carpeta de archivos

Figura 28. Distribución de las carpetas necesarias para ejecución del código.

Se descargó el producto ABI L2 Total Precipitable Water con la rutina de descarga en Python, el cual se guardó en la carpeta Imagery que contiene los productos a estimar.

Posteriormente se ajustaron las rutas del código coincidentes con el procesador y se ejecutó la rutina en Matlab lector de productos del GOES 16.

Se obtuvieron imágenes en dominio CONUS, elegido por ser el tipo de formato de dominio que es más fácil de trabajar y tiene un nivel de detalle medio (Forczyk, 2021). Dichas imágenes se descargaron en formato. netCDF, y se procesaron en el software QGIS obteniendo diversos mapas como el que se muestra en la figura 29.




Figura 29. Total Precipitable Water 27/07/2022, 00 hrs 01 min, Domain: CONUS.

Sin embargo, se ha decidido no utilizar los datos proporcionados por el GOES 16 Reader Software Version 1.0, debido a que se necesita un procesador potente con gran capacidad de almacenamiento, ya que se necesitan más de 500 GB para obtener información de un día, según (Forczyk, 2021). Debido a esto, el procesador únicamente permitió guardar 2 días de información, siendo esto insuficiente para los requerimientos de la investigación.

También, el AWS GOES 16 no cuenta con un registro de datos históricos, debido a que es una plataforma relativamente actual, teniéndose registro a partir del año 2017 a la actualidad.

9.2.3. Integrated Multi-Satellite Retrievals for GPM (IMERG)

Primeramente, se obtuvo la serie temporal de estimaciones de lluvia mediante PP con base en la ubicación de la estación MORE debido a que es la estación con la que se validó la información satelital, a una escala de 30 minutos.

Con base en el punto ubicado, se obtuvo la serie mediante IBP, colocando los puntos adyacentes a este, como se muestra en la figura 30.




Figura 30. Esquema de análisis de IBP para la ciudad de Morelia, Michoacán.

Llevando a cabo dicha metodología, se obtuvo la serie temporal de estimaciones a cada 30 minutos, con influencia de los 4 puntos con mayor peso para con el punto de interés.

Con base en que la obtención de datos mediante el IMERG fue rápida y sencilla, se decidió utilizar esta base de datos como principal para determinar la fiabilidad para la ciudad de Morelia.

9.3. Comparación y validación de precipitaciones satelitales con estaciones meteorológicas.

Una vez obtenidas las series temporales de estimaciones por PP e IBP, se realizó la validación con respecto a la serie temporal de datos observados de lluvia de MORE aplicando los estadísticos descritos, para escala 30 minutal, diaria, semanal, mensual y anual obteniéndose la siguiente tabla. Se piensa que el uso de diferentes escalas temporales proporcionan detalles más completos de las características del producto de precipitación IMERG (Mayor et al., 2017).

Tabla 6. Validación estadística para las series de estimaciones de lluvia de IMERG mediante PP e IBP.

ANÁLISIS PUNTO-PIXEL			ANÁLISIS POR INTERPOLACIÓN BILINEAL PONDERADA		
ESCALA 30 MINUTAL					
Estadístico	Valor	Característica	Estadístico	Valor	Característica
R	0.28	Relación directa, correlación débil	R	0.31	Relación directa, correlación débil
RB	1.91	Sobreestimación para IMERG	RB	1.95	Sobreestimación para IMERG
RMSE	0.73	Mayor error en IMERG	RMSE	0.69	Mayor error en IMERG
ESCALA DIARIA					
R	0.98	Relación directa, correlación fuerte	R	0.58	Relación directa, correlación fuerte
RB	-0.01	Subestimación para IMERG	RB	-0.66	Subestimación para IMERG
RMSE	2.08	Mayor error en IMERG	RMSE	11.35	Mayor error en IMERG
ESCALA SEMANAL					
R	0.73	Relación directa, correlación fuerte	R	0.75	Relación directa, correlación fuerte
RB	1.91	Sobreestimación para IMERG	RB	1.95	Sobreestimación para IMERG
RMSE	47.95	Mayor error en IMERG	RMSE	47.98	Mayor error en IMERG
ESCALA MENSUAL					
R	0.9	Relación directa, correlación fuerte	R	0.91	Relación directa, correlación fuerte
RB	1.91	Sobreestimación para IMERG	RB	1.95	Sobreestimación para IMERG
RMSE	172.97	Mayor error en IMERG	RMSE	177.04	Mayor error en IMERG
ESCALA ANUAL					
R	0.95	Relación directa, correlación fuerte	R	0.95	Relación directa, correlación fuerte
RB	1.91	Sobreestimación para IMERG	RB	1.95	Sobreestimación para IMERG
RMSE	1256.25	Mayor error en IMERG	RMSE	1286.78	Mayor error en IMERG

A continuación, se presenta un análisis gráfico de las series de lluvia observadas y estimadas, que permitió observar las tendencias de ambas series, tanto para el análisis PP en la figura 31, como para IBP en la figura 32.




Figura 31. Análisis gráfico a escala 30 minutal, diaria, semana, mensual y anual para la validación de la serie PP con datos observados de la estación MORE.

Con base en la figura 31 se puede decir que el IMERG detecta de manera correcta la ocurrencia de precipitación para la estación MORE para escala 30 minutal, sin embargo, en cuestión de cantidad de precipitación sobreestima dicho valor, debido a que el satélite registra precipitación antes y después de que la estación detecte lluvia, debido a que se base en las características de las nubes, pudiendo introducir mayor error en las estimaciones.

Derivado del análisis gráfico para la metodología PP, se observa que las series siguen la misma tendencia, sin embargo, existen subestimaciones y sobreestimaciones en los datos.




Figura 32. Análisis gráfico a escala 30 minutal, diaria, semana, mensual y anual para la validación de la serie IBP con datos observados de la estación MORE.

Con base en el análisis gráfico de la figura 32, para la metodología de IBP, se aprecia que se tiene un comportamiento similar al de PP.



Analizando entonces la tabla 6, se puede decir que:

9.3.1. Análisis 30 minutal

Se pudo observar que las estimaciones de IMERG sobreestiman mínimos de lluvia, pero sin embargo existe una subestimación en cuanto a la mayoría de máximos para ambas metodologías (PP e IBP), también, se observa que existe una mayor correlación (r) con el método de IBP, sin embargo, sigue siendo una correlación débil, así como también un menor error en las estimaciones con base en las observadas para IBP.

9.3.2. Análisis diario

Se observa que la correlación aumenta para ambas metodologías, es decir cuando aumenta la escala temporal, en especial para PP, sin embargo, se presenta, en caso contrario, una subestimación para las estimaciones de IMERG con ambos métodos en esta escala, resultando mejor el análisis PP, con menor subestimación y error en la medición.

9.3.3. Análisis semanal

Existe una mayor sobreestimación en las estimaciones de lluvia, con base en los valores de RB promedio de 1.92, así como una correlación fuerte y directa, cercana a valores del 0.7 para ambos métodos, lo cual significa que ambas series tienen una tendencia similar, sin embargo, con ello se observa un aumento potencial en el error de medición de dichas estimaciones.

9.3.4. Análisis mensual

Se presentan valores de correlación fuertes con relación directa promedio de 0.9, con tendencia de la serie evidente, así como, se sigue presentando sobreestimación para ambas manteniendo los mismos valores de 1.92, también, un valor medio de error de 175, lo cual significa que incrementó la medición para IMERG de la mano con la sobreestimación.

9.3.5. Análisis anual

Se observa una correlación fuerte con correlación directa, con valores de 0.95, tanto para PP como para IBP, también sobreestimación en IMERG, así como resultados



desfavorables para el RMSE con un valor promedio de 1265, un incremento muy grande de error en las mismas, como se pudo observar en la figura 31, sin embargo, una similitud fuerte en la tendencia de las series.

De una primera instancia, se logró determinar que se presenta mejor similitud en tendencia para escalas diarias, semanales, mensuales y anuales.

Con base en el análisis de validación para las diferentes escalas temporales, se optó por no utilizar la información a escala 30 minutal de estimaciones de lluvia de IMERG, ya que las metodologías de PP e IBP presentan correlación muy débiles para poder tomarse como datos válidos para la investigación, debido a que no se podría realizar una corrección del sesgo en las estimaciones para que puedan representar correctamente la variabilidad y cantidad de lluvia, corroborando los resultados de (Mayor et al., 2017).

9.4. Generación y caracterización de eventos de lluvia

Una vez determinando la información de la estación MORE a utilizar, así como la de la estación 76665, se uniformizaron las series de datos a la misma escala temporal, en este caso, mediante una rutina de Matlab, se procedió a calcular la serie horaria de MORE con base en los datos 30 minutales, con base en la escala horaria de la estación 76665, teniendo así, las mismas escalas temporales para el análisis, comprendiendo el periodo del 08 de agosto del 2015 al 31 de diciembre del 2012.

Con las series horarias de ambas estaciones se calcularon, en Matlab, todos los eventos de lluvia presentes en ambas series a las diferentes duraciones registradas, los cuales se muestran en la siguiente tabla.



Tabla 7. Total de eventos registrados por la estación MORE Y 76665.

Estación 76665			Estación MORE		
Duración	Total de eventos	%	Duración	Total de eventos	%
2	294	43.5	2	382	56.5
3	179	47.6	3	197	52.4
4	74	45.7	4	88	54.3
5	60	53.1	5	53	46.9
6	29	47.5	6	32	52.5
7	22	56.4	7	17	43.6
8	10	38.5	8	16	61.5
9	7	50.0	9	7	50.0
10	6	60.0	10	4	40.0
11	4	57.1	11	3	42.9
12	4	66.7	12	2	33.3
13	4		14	1	
15	1		19	2	66.7
18	1		24	1	
19	1	33.3			

Como se puede observar en la tabla, los eventos de 2 a 4 horas tienen un mayor porcentaje de ocurrencia para la estación MORE, al sur de Morelia, por el contrario, para eventos de 9 a 11 horas, hay un mayor porcentaje de ocurrencia para la estación 7665, al norte de la ciudad.

Con base en ello, se determinaron entonces los eventos que coinciden en ambas estaciones, esto para poder alimentar el modelo estocástico con eventos que hayan ocurrido al mismo tiempo para determinar la relación entre ambas zonas, obteniéndose entonces la cantidad de eventos coincidentes de la siguiente tabla.

Tabla 8. Recopilación de eventos coincidentes para estación MORE-UNAM y 76665-CONAGUA.

Duración (horas)	Total de eventos coincidentes
	Estaciones CONAGUA y UNAM
2	105
3	51
4	20
5	15
6	6
7	6
8	3
10	1
12	2

Debido a que para duraciones mayores a 6 horas existe un total de eventos pequeño, el modelo se realizará únicamente con las duraciones de 2 a 6 horas, tomando en cuenta los de 6 horas debido a que ocurre un evento de interés en la ciudad de Morelia, el cual ocasionó grandes daños en la sociedad, que es el huracán Willa, ocurrido el 22 de octubre del 2018.

Se presentan entonces, los eventos coincidentes para ambas estaciones de manera gráfica, para duración de 6 horas, el cual permitió observar las desfases temporales entre eventos, así como eventos extremos que se tienen en el periodo analizado. Debido a la gran cantidad de eventos, se presentan las gráficas de las duraciones de 2 a 5 horas en el anexo A, para cualquier revisión.




Figura 33. Eventos coincidentes para una duración de 6 horas de las estaciones MORE y 76665.

Se presentan los desfases horarios para los eventos de lluvia de la estación MORE, en la tabla 9, con respecto a la 76665, es decir, cuánto tardan los eventos de lluvia en registrarse de la zona sur de la ciudad a la zona norte.

Tabla 9. Desfase horario de ocurrencia de lluvia entre ambas estaciones.

Duración (horas)	2	3	4	5	6
Total de eventos coincidentes	105	51	20	15	6
Primera ocurrencia y % de eventos	MORE (81.9%)	MORE (66.67%)	MORE (95%)	MORE (86.67%)	MORE (66.67%)
Desfase de ocurrencias (MORE con respecto a 76665)					
Horas	%				
0	4.70	5.9	5.3	7.69	0
1	37.20	26.5	36.8	46.15	0
2	19.80	14.7	10.5	30.77	75
3	12.80	14.7	31.6	0	0
Otras	25.50	38.2	15.8	15.4	25

Se observa que, en general, existe un desfase de ocurrencia de 2 horas en promedio, que se presenta la lluvia al sur de la ciudad y después al norte.

Con esto, se pudo seleccionar eventos con lluvias de interés, debido a la cantidad que llovió, los cuales se presentan en la siguiente tabla.

Tabla 10. Eventos horarios con lluvias de interés registrados por la estación MORE y 76665.

Periodo: 2015-2022		Lluvia (mm)	
Fecha ocurrencia	Duración	Estación MORE	Estación 76665
04/07/2019 21:00	2	30.1	6.9
05/08/2019 22:00		26.5	18.2
07/09/2019 19:00		30	1.3
04/06/2022 02:00		41.5	7.5
13/07/2022		25.3	15.1
05/08/2017 01:00	3	18.8	32
23/06/2018 20:00		26.4	11.1
14/08/2022 01:00		43.5	14
29/05/2017 22:00	4	23.5	53.4
08/06/2022 23:00		56.2	6.3
30/06/2018 20:00	5	26.6	13.8
22/10/2018 02:00	6	46	47.4
05/06/2019 15:00		29.7	1.3

Se puede observar que la mayor cantidad de lluvia se presenta en la estación MORE, al sur de Morelia, como se corroboró anteriormente.



De manera particular, se analiza un evento de lluvia de importancia para la ciudad, el cual generó grandes daños debidos a una inundación por el huracán Willa, que tuvo fecha el 22 de octubre del 2018, mismo que des desplazó del norte al sur con la misma cantidad de lluvia, variando a 1.4 mm.

- **Análisis de componentes principales para variables climáticas.**

Se realizó un ACP para determinar la influencia de variables climáticas en los meses en los cuales se presenta mayor precipitación, así como en qué condiciones se presentan para que ocurra.

Primeramente, se determinó la matriz inicial de variables, tabla 10, con base en una estación de OOAPAS la cual fue Buena Vista, eligiendo dicha estación debido a que miden diversas variables climáticas, en comparación a las de CONAGUA que solo miden 3 variables.

Las variables analizadas fueron:

- Precipitación
- Humedad
- Índice de calor
- Presión
- Punto de rocío
- Radiación solar
- Sensación térmica
- Temperatura
- Velocidad del viento

Tabla 11. Matriz inicial de variables climáticas

Mes	Precipitación (mm)	Humedad (%)	Índice de calor (°C)	Presión (mmhg)	Punto de rocío (°C)	Radiación solar (W/m2)	Sensación térmica (°C)	Temperatura (°C)	Velocidad del viento (m/s)
Enero	1.2	59.50	14.55	755.96	6.52	167.78	15.20	15.20	0.43
Febrero	18	60.22	17.09	753.94	8.95	203.28	17.58	17.58	0.47
Marzo	9.6	56.84	19.76	752.82	10.48	239.06	20.21	20.21	0.76
Abril	5.8	43.98	21.29	751.29	8.28	271.12	22.16	22.16	0.53
Mayo	36.4	46.85	20.56	751.33	8.17	276.47	21.39	21.39	0.77
Junio	78	64.91	21.21	751.15	13.51	259.76	21.21	21.22	1.14
Julio	149	76.49	19.82	752.37	14.94	236.02	19.55	19.55	0.44
Agosto	123.4	82.13	19.04	752.44	15.34	205.12	18.69	18.69	0.39
Septiembre	77.6	79.68	19.11	752.18	14.93	207.31	18.81	18.81	0.60
Octubre	11.2	67.73	18.01	753.09	11.20	225.48	18.20	18.20	0.68
Noviembre	0.4	66.46	17.06	754.66	10.32	193.22	17.33	17.33	0.79
Diciembre	0.2	67.42	15.45	754.72	9.10	163.11	15.79	15.79	0.41

Se realizó el análisis en el software JMP, obteniendo primeramente un análisis gráfico general, que se presenta en la figura 34.




Figura 34. Análisis gráfico para ACP.

Se pudo observar que los meses húmedos se encuentran en el primer cuadrante que son de junio a septiembre, en los cuales las variables de precipitación, humedad, punto de rocío e índice de calor tienen mayor importancia. En los meses secos, que se encuentran en el cuarto cuadrante, las variables de mayor importancia son la temperatura, radiación solar y velocidad del viento. Por último, para los meses de octubre a febrero se presenta la presión como variable de mayor peso, lo cual corresponde debido a que son los meses en los cuales la temperatura baja, por consiguiente, la presión aumenta.

Posteriormente se verifico la variación explicativa mediante los valores propios, figura 35, en la cual se observó que en el segundo componente se presenta una variación explicada muy grande, del 89%, lo cual indica que existe redundancia en la información de las variables.




Figura 35. Varianza explicada mediante valores propios.

También, se determinó la matriz de correlaciones la cual permitió observar la redundancia en las variables, es decir, qué variables me están dando la misma información con base en este parámetro. Se observaron las variables que tengan un coeficiente de correlación mayor al 0.8, las cuales fueron:

- Precipitación con punto de rocío
- Humedad con punto de rocío
- Índice de calor con presión, radiación solar, sensación térmica y temperatura

Entonces, se pudo corroborar que existe mucha redundancia en las variables que conforman la matriz inicial, lo cual nos indicó que se pudieron eliminar variables que no son medidas directas del clima, debido a que mostraban la misma información que otras variables.

Posteriormente se calcularon los valores atípicos mediante la distancia de Mahalanobis, figura 36, lo cual mostró que no existen valores por encima de la línea, lo cual significó que no existen valores atípicos en los datos analizados.




Figura 36. Distancia de Mahalanobis para valores atípicos.

Finalmente, se calculó la normalidad multivariada (figura 37), la cual mostró que existe normalidad multivariada debido a que son datos climáticos y presentan similitud con la distribución normal.




Figura 37. Normalidad multivariada de los datos.

Debido a la gran redundancia presente en la primera matriz de variables elegidas se realizó una depuración de matriz eligiendo solamente, en su mayoría, las variables de medida directa, quedando la matriz como se muestra en la tabla 11.

Tabla 12. Matriz depurada de variables climáticas.

Mes	Precipitación (mm)	Humedad (%)	Presión (mmhg)	Punto de rocío (°C)	Temperatura (°C)
Enero	1.2	59.50	755.96	6.52	15.20
Febrero	18	60.22	753.94	8.95	17.58
Marzo	9.6	56.84	752.82	10.48	20.21
Abril	5.8	43.98	751.29	8.28	22.16
Mayo	36.4	46.85	751.33	8.17	21.39
Junio	78	64.91	751.15	13.51	21.22
Julio	149	76.49	752.37	14.94	19.55
Agosto	123.4	82.13	752.44	15.34	18.69
Septiembre	77.6	79.68	752.18	14.93	18.81
Octubre	11.2	67.73	753.09	11.20	18.20
Noviembre	0.4	66.46	754.66	10.32	17.33
Diciembre	0.2	67.42	754.72	9.10	15.79

Se procedió a calcular el análisis gráfico general de los componentes principales, el cual se muestra en la figura 38.




Figura 38. Análisis gráfico general de los CP.

Se observó que en los meses de julio a septiembre las variables con mayor peso o importancia son humedad, punto de rocío y precipitación, mientras que para los meses de octubre a febrero tiene mayor peso la presión y para el mes de junio la temperatura tiene mayor peso.

Se calcularon los valores propios (figura 39) que mostraron la variación explicada de las variables, en el cual resultó que para el segundo componente se tiene una variación explicada del 95%, lo cual indica que las variables elegidas explican muy bien el fenómeno deseado.




Figura 39. Varianza explicada para las variables climáticas de la matriz depurada.

Asimismo, se analizaron las correlaciones de las variables, obteniéndose que disminuyeron notablemente las correlaciones entre las variables, lo cual indicó que es un mejor análisis que el realizado primeramente, así como que las variables de precipitación, presión, temperatura, humedad y punto de rocío pueden representar adecuadamente el fenómeno analizado en los meses húmedos, tomando en cuenta la investigación de (Shaw, et al., 2011) en la cual utilizaron las variables de presión, humedad, punto de rocío y temperatura.

Se presenta la matriz de correlaciones para las variables de la matriz depurada en la figura 40.

Correlaciones					
	Precipitacion (mm)	Humedad (%)	Presion (mmhg)	Punto de rocío (°C)	Temperatura (°C)
Precipitacion (mm)	1.0000	0.6454	-0.4773	0.8524	0.2872
Humedad (%)	0.6454	1.0000	0.1253	0.8119	-0.3783
Presion (mmhg)	-0.4773	0.1253	1.0000	-0.4490	-0.9412
Punto de rocío (°C)	0.8524	0.8119	-0.4490	1.0000	0.2295
Temperatura (°C)	0.2872	-0.3783	-0.9412	0.2295	1.0000

Figura 40. Matriz de correlaciones final.

9.5. Modelación estocástica multivariada para eventos de lluvia a diferentes duraciones

Para el análisis estocástico, primeramente, se desarrolló un modelo autorregresivo univariado, debido a que solo se tenía información de la estación MORE, el cual dio resultados coherentes, además de generar 100 series sintéticas que representan series que tienen la misma probabilidad de ocurrir en un tiempo futuro, ya que se ajustó de manera adecuada a las series de eventos de 1 a 6 horas, como se muestra en la figura 41, con el análisis de medias simuladas contra observadas.




Figura 41. Análisis de medias observadas y simuladas para eventos de 2 horas.

Se puede observar en la figura 41, que las medias se ajustan con un error de 0.01 mm aproximadamente a la línea de ajuste a 45°, lo cual indica que las series sintéticas obtenidas por el modelo representan de manera estadísticamente adecuada las series históricas de los eventos modelados.

Sin embargo, para obtener resultados representativos de lluvia en una zona de estudio, es necesario tomar en cuenta la dependencia espaciotemporal que condiciona a dicha variable.

Para esto, se realizó un modelo autorregresivo multivariado de orden 1, adecuando un modelo ya existente llamado MASCV, en el software Matlab, el cual es un modelo




generador estocástico para variables climáticas, de dos estados (húmedo y seco) (Hernández-Bedolla et al., 2022).

Se ajustó el MASCV a la escala temporal requerida en esta investigación, horaria, y se modeló con las estaciones MORE y 76665 conjuntamente, tomando en cuenta la dependencia espacio temporal entre ambas.

9.5.1. Análisis preliminar de los datos

Primeramente, se obtuvo la distribución de frecuencia de los datos, misma que permitió observar que los eventos de lluvia para la estación MORE para cada duración se encuentran sesgados con una cola larga hacia la derecha, se presentan los histogramas en la figura 42.






Figura 42. Distribución de frecuencias para eventos de lluvia con duraciones de 2, 3, 4, 5, 6 para las estaciones analizadas.

Posteriormente se determinó, por medio de Matlab, qué función de distribución se ajusta a las series de eventos, información útil para definir la transformación a aplicar para normalizar dichos datos posteriormente. Se ajustaron diversas funciones de distribución obteniendo que la Inversa Gaussiana fue la que ajusta mejor a cada duración, se muestra en la figura 43 el ajuste para eventos de 1 hora, presentándose en el anexo F los ajustes para las duraciones 2, 3, 4, 5 y 6 horas.




Figura 43. Ajuste de función de distribución para eventos de lluvia de 2 horas.

9.5.2. Normalización de eventos

Primeramente, se aplicaron test de normalidad a los eventos de cada duración determinando si son simétricas o asimétricas, presentado en la tabla12.

Tabla 13. Test de normalidad para eventos de lluvia analizados.

Test de normalidad				
Duración (horas)	Media	Desv. Estánd	Shapiro-Wilks	Chi cuadrada
1	1.03	1.90	Asimétrica	Asimétrica
2	1.17	2.24	Asimétrica	Asimétrica
3	1.59	2.86	Asimétrica	Simétrica
4	0.92	1.02	Asimétrica	Asimétrica
5	0.96	1.38	Asimétrica	Asimétrica
6	2.16	2.88	Asimétrica	Asimétrica

Con base en la función de distribución se aplicaron diversas transformaciones no paramétricas para transformar la muestra a una normal, aplicando la transformación triple logarítmica a los eventos de todas las duraciones analizadas, debido a que se encuentran fuertemente sesgados hacia la derecha.

Para corroborar la normalización se aplicó el intervalo de normalidad para el coeficiente de sesgo de los eventos normalizados de Snedecor & Cochran, 1967, citados por (Salas et al., 1980), presentándose los límites de normalidad para eventos de 2 hora en la figura 44. Se presenta la normalización para las duraciones de 3 a 6 horas en el anexo B.




Figura 44. Intervalo de normalidad para eventos de 2 horas.

Se observa que para eventos de 2 horas la normalidad no cumple con los límites, sin embargo, se eligió la que mejor se ajustó debido a que ninguna transformación propuesta normalizó completamente los eventos de 2 horas, sin embargo, para duraciones de 3 a 6 horas la normalización cumplió con los límites, caso interesante ya que son las duraciones que presentan los eventos de interés.

9.5.3. Parametrización con series de Fourier

Se aplicó la parametrización con series de Fourier para reducir el número de parámetros (medias y desviaciones estándar) para preservar la parsimonia del modelo, esto para remover la periodicidad de los eventos horarios, se presenta en la figura 45 y 46 la parametrización de las medias y desviaciones estándar, respectivamente, para eventos de 2 horas y se presentan las parametrizaciones para eventos de 3 a 6 horas en el anexo B.




Figura 45. Parametrización para medias mediante series de Fourier para eventos de 2 horas.




Figura 46. Parametrización para desviaciones mediante series de Fourier para eventos de 2 horas.

Una vez reducido el número de parámetros se procedió a aplicar la estandarización para la serie de eventos de las diferentes duraciones mismo que permitió el análisis de dependencia temporal posterior. Dicho proceso transformó la serie con una media igual a cero y desviación estándar de 1.

9.5.4. Análisis de correlaciones cruzadas

Se determinó primeramente la correlación temporal para las series de eventos de cada duración con un desfase de 10 ($k=10$), esto permitió determinar el orden y tipo de modelo a aplicar, se presenta la tabla 21 que contiene los coeficientes de correlación para $k=3$, misma que permitió determinar el orden del modelo ya que se puede observar que para un $k=2$, para todas las duraciones, el valor de correlación es cercano a cero o decae a cero, asumiendo así, que el mejor es un modelo autorregresivo de orden 1, que se adapta a las condiciones de dependencia del tiempo y espacio.

Tabla 14. Parámetros autorregresivos para $K = 3$.

Eventos (duración)	Parámetros autorregresivos		
	1	2	3
1	0.167	0.063	0.008
2	0.403	0.126	-0.016
3	0.351	0.108	0.099
4	0.466	0.076	0.041
5	0.408	0.068	0.005
6	0.426	0.064	0.009

9.5.5. Generación de series residuales

Con base en el parámetro del modelo se calcularon las series de residuos, dicha serie debe cumplir con la condición de ruido blanco para que el modelo sea válido, es decir que la serie sea independiente, tenga distribución normal y que sean insesgados. Para esto, se aplicaron los test de normalidad a la serie residual, así como las correlaciones cruzadas temporales y espaciales, para determinar la independencia mediante un correlograma. Se presenta el histograma para visualizar la normalidad de los eventos de 2 horas en la figura 47, así como el correlograma para los eventos con la misma duración en la figura 46. La condición de ruido blanco para eventos con duración de 3 a 6 horas se presenta en el anexo B.




Figura 47. Histograma para serie residual de eventos de 2 horas, condición de ruido blanco de normalidad.




Figura 48. Correlograma para serie residual de eventos de 2 horas, condición de ruido blanco de independencia.

Se presenta la tabla 14 la cual muestra los estadísticos para la serie residual, así como los test de normalidad corroborando que para los eventos con duración de 3 a 6 horas cumplen con dicho criterio. Asimismo, se presenta el criterio de Akaike (AIC) mostrando el resultado más favorable para el modelo autorregresivo multivariado aplicado, demostrando que es el que mejor se ajusta a los datos de eventos de lluvia.

Tabla 15. Test de condición de ruido blanco para series residuales de los eventos de diferentes duraciones y AIC para el modelo.

Eventos (duración)	Estadísticos de serie residual			Test normalidad		AIC
	Media	Desv Est	Sesgo	Chi cuadrado	Shapiro-Wilks	
1	0.007	0.998	0.895	No cumple	No cumple	-11.45
2	0.004	0.925	0.999	No cumple	No cumple	-54.6712
3	0.003	0.934	0.762	Cumple	Cumple	-20.87
4	0.004	0.865	0.244	Cumple	Cumple	-18.989
5	0.031	0.888	0.687	Cumple	Cumple	-12.7737
6	0.018	0.875	0.140	Cumple	Cumple	-7.2247

9.5.6. Generación de series sintéticas

El objetivo del modelo estocástico multivariado aplicado tiene como fin la generación de series sintéticas, las cuales son escenarios equiprobables que pueden ocurrir en cierto tiempo, mismas que preservan propiedades estadísticas de las series históricas analizadas.

Para esto, se realizó el proceso inverso del modelo autorregresivo multivariado aplicado, se generaron números aleatorios del tamaño de la serie de eventos de lluvia analizados para posteriormente desestandarizar y aplicar la inversa de la normalización aplicada inicialmente obteniendo los escenarios de series sintéticas.

Se aplicó un periodo de calentamiento de 50 series de datos, obteniendo 200 series sintéticas de eventos, mostrándose en la figura 49, los escenarios para los eventos de lluvia de 2 horas.




Figura 49. Series sintéticas para eventos de lluvia de 2 horas.

Finalmente, el modelo autorregresivo multivariado de orden 1 se ajustó de manera adecuada a los eventos analizados pudiendo reproducir estadísticamente las características de las series históricas.

9.5.7. Análisis de medias observadas y simuladas

Con base en las medias observadas, de la serie histórica de eventos, y las medias simuladas, obtenidas de las series sintéticas generadas con el modelo multivariado, se realizó un análisis para observar las variaciones de lo real y lo simulado, mostrando en la siguiente figura para cada duración y cada estación.




Figura 50. Análisis de medias observadas contra simuladas para estación 76665.




Figura 51. Análisis de medias observadas contra simuladas para estación MORE.

Como se observa en las gráficas, existe un error para las medias de las series simuladas de aproximadamente 0.1 mm, lo cual muestra que el modelo representa correctamente las características estadísticas del proceso.

9.6. Series de predicción

En un primer acercamiento, se cuenta con las series generadas por el modelo autorregresivo multivariado, las cuales son series que tienen la misma probabilidad de ocurrir en un tiempo futuro, sin embargo, este enfoque no nos da con certeza una predicción conocida y única para un valor pasado de lluvia, es por eso que se propone utilizar una Red Neuronal Artificial (RNA) que esté alimentada con las



series de lluvia y variables climáticas con que se cuente información en las estaciones analizadas, la cual podrá dar un mejor resultado en cuanto a predicción de lluvia.



10. CONCLUSIONES

En el presente trabajo se han abordado dos líneas importantes de investigación, por un lado corroborar si las estimaciones de lluvia de satélite son válidas para poder utilizarse en la ciudad de Morelia y por otro lado, realizar un modelo estocástico multivariado a una escala horaria, modelo innovador para México y específicamente para la ciudad de Morelia debido a la escala temporal subdiaria utilizada, que pueda representar la variabilidad y relación de la lluvia en diferentes puntos importantes de la ciudad para así poder generar predicciones de lluvia que puedan ayudar a actuar anticipadamente ante un desastre o simplemente a tratar de conocer el comportamiento de la lluvia.

Entonces, en esta investigación se han evaluado los datos de estimaciones de lluvia provenientes del algoritmo IMERG para la ciudad de Morelia durante el periodo 2015 al 2022, realizando un análisis de validación a diferentes escalas, utilizando datos de estaciones meteorológicas como datos de validación, en la cual se encontró que no se recomienda la utilización de estimaciones a escala de 30 minutos para la ciudad de Morelia, debido a la baja correlación con datos observados reales ya que se sugiere que el satélite aún no es tan preciso para capturar eventos de lluvia de corta duración. Sin embargo, para escalas diarias, semanales, mensuales y anuales, se dan muy buenas correlaciones con datos observados, así como una tendencia similar. Se puede decir que, a medida que aumenta la escala temporal, la correlación entre los datos de pluviómetros y los datos satelitales mejora, sin embargo, la sobreestimación en las estimaciones de lluvia también aumenta. Entonces, podemos decir que el satélite es capaz de capturar patrones de lluvia en periodos más extensos. Por último, debido a la tendencia que siguen las estimaciones y las observaciones de lluvia, se puede recomendar realizar una corrección de sesgo para las estimaciones, lo cual sería muy útil para zonas como Morelia, en la cual no se cuentan con las suficientes mediciones de la lluvia, para escalas semanales, mensuales y anuales.

Del modelo autorregresivo multivariado implementado, alimentado con series temporales de eventos de lluvia de 2, 3, 4, 5 y 6 horas de dos estaciones, ha



demostrado un ajuste satisfactorio para reproducir las características estadísticas de las series históricas de eventos. Este rendimiento positivo se refleja en la capacidad del modelo para generar series sintéticas que pueden ser utilizadas efectivamente como series de predicción y que cuentan con la influencia de las dos estaciones ubicadas al sur y al norte de la ciudad de Morelia, reproduciendo la correlación y dependencia para la ocurrencia de lluvia con base en ambas zonas. La eficacia del modelo en la reproducción y predicción de eventos de lluvia en diferentes escalas temporales sugiere su utilidad potencial en aplicaciones de pronóstico hidrometeorológico. Sin embargo, es importante continuar evaluando el modelo frente a nuevos datos y escenarios para validar su robustez y generalización en diferentes condiciones climáticas.

Con el modelo se obtuvieron 500 series sintéticas, mismas que pueden ser de gran utilidad en la ciudad de Morelia, debido a la falta de registros de lluvia en la zona, pudiendo utilizar dichas series sintéticas como escenarios para diferentes estudios hidrológicos.

Con base en la predicción que se generó con el modelo estocástico multivariado, se obtuvo que es capaz de reproducir la correlación entre los registros de la zona sur y zona norte de la ciudad, así como el comportamiento estadístico de estas correlaciones. Concluyendo que el modelo estocástico multivariado representa, dentro de los límites de confianza del análisis, la variabilidad climática de la lluvia en Morelia. Obteniéndose un retraso para la predicción de 1 hora, así como un error de sobreestimación en la cantidad de lluvia de 5 mm.

Dicho modelo es de gran aporte a la ciudad de Morelia, Michoacán, debido a que se puede conocer, con un cierto margen de error, si se presentará algún evento de importancia para la zona que pudiera generar algún desastre natural, así como también, ser útil para los tomadores de decisiones para el uso de la población.



11. RECOMENDACIONES Y LÍNEAS FUTURAS

Es evidente que, en México, y específicamente en Michoacán, no existe una medición correcta y basta de las variables climáticas.

La implementación de equipos de medición para variables climáticas, así como nuevas técnicas de mediciones, como es el caso del satélite, en este caso hablando de la lluvia, es una necesidad que demanda el desconocimiento del clima en nuestro país. Aunado a ello herramientas que permitan conocer dicho comportamiento tanto pasado como futuro.

Debido a todas estas necesidades y a la investigación realizada, se generan nuevas líneas futuras de investigación. Las cuales se pueden dirigir al uso de modelos de predicción de lluvia para implementarse en ciudades en desarrollo, que sirvan para sistemas de alerta que ayuden a la población a reaccionar con antelación a las desastres naturales y daños que estos puedan causar.

Por otro lado, utilizar los modelos generadores de series sintéticas para contrarrestar la falta de datos de variables climáticas en nuestro país.



12. REFERENCIAS BIBLIOGRÁFICAS

- Ababaei, B., Etedali, H. R., Ababaei, B., & Etedali, H. R. (2014). *Comparing Different Weather Generator Algorithms for Daily Temperature*. 21877–21889.
- Ali, B., Yudong, T., Bjorn H, L., & Graeme L, S. (2014). *What does CloudSat reveal about global land precipitation detection by other spaceborne sensors?* 5375–5377. <https://doi.org/10.1002/2013WR014979>.Reply
- AQUATOOL. (2023). *Modelo de análisis de series hidrológicas (MASHWIN): Manual de usuario*.
- Arnold, D. N., Boffi, D., & Falk, R. S. (2002). Approximation by quadrilateral finite elements. *Mathematics of Computation*, 71(239), 909–922. <https://doi.org/10.1090/s0025-5718-02-01439-4>
- Ashouri, H., Hsu, K. L., Sorooshian, S., Braithwaite, D. K., Knapp, K. R., Cecil, L. D., Nelson, B. R., & Prat, O. P. (2015). PERSIANN-CDR: Daily precipitation climate data record from multisatellite observations for hydrological and climate studies. *Bulletin of the American Meteorological Society*, 96(1), 69–83. <https://doi.org/10.1175/BAMS-D-13-00068.1>
- B. Abbott, M., & Refsgaard, J. C. (1996). Distributed hydrological modelling. In *Distributed hydrological modelling*.
- Bacchini, R. D., Vázquez, L. V., & García Fronti, J. I. (2018). Introducción a la probabilidad y estadística. In *Cengage Learning*.
- Bardossy, A., & Plate, E. J. (1992). *Space-Time Model for Dily Rainfall Using Atmospheric Circulation Patterns*. 28(5), 1247–1259.
- Benevides, P., Catalao, J., & Nico, G. (2019). Neural network approach to forecast hourly intense rainfall using GNSS precipitable water vapor and meteorological sensors. *Remote Sensing*, 11(8). <https://doi.org/10.3390/rs11080966>
- Blanco, M., & Demaria, E. (2023). *Validación y corrección de estimaciones de precipitación satelital utilizando observaciones en superficie en la región pampeana argentina Validation and correction of satellite-estimated precipitation using ground observations in the Pampean region of Arg.* 0(2), 110–168. <https://doi.org/10.24850/j-tyca-14-02-04>
- Box, G. E. P., & Cox, D. R. (1964). An Analysis of Transformations. *Journal of the Royal Statistical Society: Series B (Methodological)*, 26(2), 211–243. <https://doi.org/10.1111/j.2517-6161.1964.tb00553.x>
- Casado Fernández, M. C. (n.d.). *Manual Básico De Matlab*.
- Chuvieco, E. (1990). Fundamentos de teledetección espacial. Segunda edición. In



(Fundamentals of remote sensing from space.

Climatología, G. de M. y. (2013). *Reseña del huracán “Dalila ” del Océano Pacífico.*

Climatología, G. de M. y. (2015). *Reseña del huracán “Carlos” del Océano Pacífico.* México

Climatología, G. de M. y. (2018). *Huracán Willa.*

CONAGUA. (2022). *Información estadística climatológica.*
<https://smn.conagua.gob.mx/es/climatologia/informacion-climatologica/informacion-estadistica-climatologica>

Davolio, S., Miglietta, M. M., Diomede, T., Marsigli, C., Morgillo, A., & Moscatello, A. (2008). A meteo-hydrological prediction system based on a multi-model approach for precipitation forecasting. *Natural Hazards and Earth System Science*, 8(1), 143–159. <https://doi.org/10.5194/nhess-8-143-2008>

de Goncalves, L. G. G., Shuttleworth, W. J., Nijssen, B., Burke, E. J., Marengo, J. A., Chou, S. C., Houser, P., & Toll, D. L. (2006). Evaluation of model-derived and remotely sensed precipitation products for continental South America. *Journal of Geophysical Research Atmospheres*, 111(16), 1–13. <https://doi.org/10.1029/2005JD006276>

Forczyk, A. S. M. (2021). *GOES-16 Reader Software Version 1 . 0.*

Giovannettone, J. P., & Barros, A. P. (2008). A remote sensing survey of the role of land form on the organization of orographic precipitation in Central and Southern Mexico. *Journal of Hydrometeorology*, 9(6), 1267–1283. <https://doi.org/10.1175/2008JHM947.1>

Google. (2023). *Google Earth Engine.* <https://earthengine.google.com/platform/>

Gutierrez-Lopez, A., Cruz-Paz, I., & Mandujano, M. M. (2019). Algorithm to predict the rainfall starting point as a function of atmospheric pressure, humidity, and dewpoint. *Climate*, 7(11). <https://doi.org/10.3390/cli7110131>

Hernández-Bedolla, J., Solera, A., Paredes-Arquiola, J., Sanchez-Quispe, S. T., & Domínguez-Sánchez, C. (2022). A Continuous Multisite Multivariate Generator for Daily Temperature Conditioned by Precipitation Occurrence. *Water (Switzerland)*, 14(21). <https://doi.org/10.3390/w14213494>

Hernández Bedolla, J. (2021). Análisis Estocástico de datos climáticos como predictor para la gestión anticipada de sequías en recursos hídricos. *Universidad Politécnica de Valencia.*
[https://riunet.upv.es/bitstream/handle/10251/182095/Hernandez - ANALISIS ESTOCASTICO de datos CLIMATICOS como predictor PARA LA GESTION anticipada de....pdf?sequence=1](https://riunet.upv.es/bitstream/handle/10251/182095/Hernandez%20-%20ANALISIS%20ESTOCASTICO%20de%20datos%20CLIMATICOS%20como%20predictor%20PARA%20LA%20GESTION%20anticipada%20de....pdf?sequence=1)

Hernández, J., Mendoza, M. E., & Vieyra, A. (2014). Las inundaciones en Morelia. In *Monitoreo De Riesgo Y Desastre Asociado a Fenómenos*



Hidrometeorológicos Extremos Y Cambio Climático (Vol. 1, Issue October 2016).

https://www.researchgate.net/publication/267028798_IDENTIFICACION_DE_TENDENCIAS_DE_CAMBIO_CLIMATICO_A_NIVEL_LOCAL_USANDO_MOCLIC_PREGUNTAS_Y_RESPUESTA

Hernández, J., & Vieyra, A. (2010). Riesgo por inundaciones en asentamientos precarios del periurbano. Morelia, una ciudad media mexicana. ¿el desastre nace o se hace? *Revista de Geografía Norte Grande*, 47, 45–62. <https://doi.org/10.4067/s0718-34022010000300003>

Hong, Y., Hsu, K. L., Sorooshian, S., & Gao, X. (2004). Precipitation estimation from remotely sensed imagery using an artificial neural network cloud classification system. *Journal of Applied Meteorology*, 43(12), 1834–1852. <https://doi.org/10.1175/jam2173.1>

Hsu, K. L., Gao, X., Sorooshian, S., & Gupta, H. V. (1997). Precipitation estimation from remotely sensed information using artificial neural networks. *Journal of Applied Meteorology*, 36(9), 1176–1190. [https://doi.org/10.1175/1520-0450\(1997\)036<1176:PEFRSI>2.0.CO;2](https://doi.org/10.1175/1520-0450(1997)036<1176:PEFRSI>2.0.CO;2)

Huffman, G. J., Gsfc, N., Bolvin, D. T., Braithwaite, D., Hsu, K., Joyce, R., Kidd, C., Nelkin, E. J., Sorooshian, S., & Tan, J. (2020). *Algorithm Theoretical Basis Document (ATBD) Version 06 NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG) Prepared by : January*.

Jacques, W. D., & M. Levent, K. (1978). Stochastic models dor monthly rainfall forecasting and synthetic generation. *Revista Brasileira de Linguística Aplicada*, 17(1), 1528–1535. <https://revistas.ufrj.br/index.php/rce/article/download/1659/1508%0Ahttp://hipatiapress.com/hpjournals/index.php/qre/article/view/1348%5Cnhttp://www.tandfonline.com/doi/abs/10.1080/09500799708666915%5Cnhttps://mckinseyonsociety.com/downloads/reports/Educati>

Kashiwao, T., Nakayama, K., Ando, S., Ikeda, K., Lee, M., & Bahadori, A. (2017). A neural network-based local rainfall prediction system using meteorological data on the Internet: A case study using data from the Japan Meteorological Agency. *Applied Soft Computing Journal*, 56, 317–330. <https://doi.org/10.1016/j.asoc.2017.03.015>

Katz, R. W., & Parlange, M. B. (1995). Generalizations of Chain-Dependent Processes: Application to Hourly Precipitation. *Water Resources Research*, 31(5), 1331–1341. <https://doi.org/10.1029/94WR03152>

Koch, E., & Naveau, P. (2015). A frailty-contagion model for multi-site hourly precipitation driven by atmospheric covariates. *Advances in Water Resources*, 78, 145–154. <https://doi.org/10.1016/j.advwatres.2015.01.001>

Krishnamoorthy, K., Mathew, T., & Mukherjee, S. (2008). Normal-based methods



- for a gamma distribution: Prediction and tolerance intervals and stress-strength reliability. *Technometrics*, 50(1), 69–78.
<https://doi.org/10.1198/004017007000000353>
- Kuehl, H., & Sacchi, M. D. (2020). *Constrained Least-Squares Wave-Equation Migration for AVP Inversion*. 68(1), 262–273. <https://doi.org/10.3997/2214-4609-pdb.5.b018>
- Lage González, A. (2018). Modelo híbrido estocástico-determinístico de series temporales de precipitación: Aplicación en simulación y predicción en cuencas peninsulares de influencia atlántica. In *Universidad Politécnica de Valencia. Tecnología de Alimentos*.
- Levizzani, V., Kidd, C., Kirschbaum, D. B., Kummerow, C. D., Nakamura, K., & Turk, J. F. (2020). Satellite Precipitation Measurement. In *Satellite Precipitation Measurement, Volume 1* (Vol. 67).
<http://link.springer.com/10.1007/978-3-030-24568-9>
- Macharia, J. M., Ngetich, F. K., & Shisanya, C. A. (2020). Comparison of satellite remote sensing derived precipitation estimates and observed data in Kenya. *Agricultural and Forest Meteorology*, 284(April 2019), 107875.
<https://doi.org/10.1016/j.agrformet.2019.107875>
- Magaña, V., Clemente López, L., & Vázquez, G. (2013). *El pronóstico de lluvias intensas para la Ciudad de México*. 16(1), 18–25.
- Matínez, A., & Salas, J. D. (2004). *Modelación estocástica de lluvias horarias*. 29–39.
- Mayor, Y. G., Tereshchenko, I., Fonseca-Hernández, M., Pantoja, D. A., & Montes, J. M. (2017). Evaluation of error in IMERG precipitation estimates under different topographic conditions and temporal scales over Mexico. *Remote Sensing*, 9(5), 1–18. <https://doi.org/10.3390/rs9050503>
- Michaelides, S., Levizzani, V., Anagnostou, E., Bauer, P., Kasparis, T., & Lane, J. E. (2009). Precipitation: Measurement, remote sensing, climatology and modeling. *Atmospheric Research*, 94(4), 512–533.
<https://doi.org/10.1016/J.ATMOSRES.2009.08.017>
- Muñoz-mandujano, M., Gutiérrez-lópez, M. A., & Vargas-díaz, J. A. (2022). *Modelo y algoritmo de pronóstico CRHUDA aplicado a las estaciones de la red de monitoreo RedCIAQ*. March.
- Nguyen, P., Shearer, E. J., Tran, H., Ombadi, M., Hayatbini, N., Palacios, T., Huynh, P., Braithwaite, D., Updegraff, G., Hsu, K., Kuligowski, B., Logan, W. S., & Sorooshian, S. (2019). The CHRS data portal, an easily accessible public repository for PERSIANN global satellite precipitation data. *Scientific Data*, 6, 1–10. <https://doi.org/10.1038/sdata.2018.296>
- OOAPAS. (2022). *Sistema de monitoreo de las estaciones meteorológicas de OOAPAS*. <https://prevencion.ooapas.gob.mx/sistmon.php>



- Papalexiou, S. M. (2018). Unified theory for stochastic modelling of hydroclimatic processes: Preserving marginal distributions, correlation structures, and intermittency. *Advances in Water Resources*, 115, 234–252. <https://doi.org/10.1016/j.advwatres.2018.02.013>
- Paz, M. S., & Ríos, D. L. (2021). *Estimación de precipitación mediante el empleo de imágenes satelitales*. http://pa.bibdigital.uccor.edu.ar/2959/1/TF_Paz_Rios.pdf
- Pombo, S., de Oliveira, R. P., & Mendes, A. (2015). Validation of remote-sensing precipitation products for Angola. *Meteorological Applications*, 22(3), 395–409. <https://doi.org/10.1002/met.1467>
- Program, T. C. (2008). *Aplicaciones de percepción remota en los trópicos*.
- Pública, S. de S., & Civil, D. E. de P. (2015). “*Plan de Atención a la Población ante Fenómenos Hidrometeorológicos 2015* .”
- Pulkkinen, S., & Chandrasekar, V. (2019). *Stochastic Spectral Method for Radar-Based Probabilistic Precipitation Nowcasting*. 971–985. <https://doi.org/10.1175/JTECH-D-18-0242.1>
- Qian, B., Gameda, S., & Hayhoe, H. (2008). Performance of stochastic weather generators LARS-WG and AAFC-WG for reproducing daily extremes of diverse Canadian climates. *Climate Research*, 37(1), 17–33. <https://doi.org/10.3354/cr00755>
- R. Johnson, E. (1980). Multivariate Short-Therm Rainfall Prediction. *Water Resources Research*, 16(0), 173–185.
- Ribeiro, M. S. M., Andrade, L. D. M. B., Spyrides, M. H. C., Lima, K. C., Da Silva, P. E., Batista, D. T., & De Lara, I. A. R. (2021). Environmental disasters in Northeast Brazil: Hydrometeorological, social, and sanitary factors. *Weather, Climate, and Society*, 13(3), 541–554. <https://doi.org/10.1175/WCAS-D-20-0132.1>
- Salas, J. D., Delleur, J. W., Yevjevich, V. M., & Lane, W. L. (1980). Applied modeling of hydrologic time series. In *Water Resource Publications* (p. 498).
- Saucedo, J. Á. (n.d.). Sistema de alerta temprana para el pronóstico a corto plazo de lluvias intensas en la ciudad de Morelia, Michoacán, México. In *Universidad Michoacana de San Nicolás de Hidalgo*.
- Scheidereite, G. D., & Faure, O. R. (2015). Aplicación de los Modelos Autorregresivos Integrados de Media Móvil (ARIMA) a las series de precipitaciones de lluvia. In *RInCE: Revista de Investigaciones del Departamento de Ciencias Económicas* (Vol. 6, Issue 12). <https://doi.org/10.54789/rince.12.1>
- Shumway, R. H., & Stoffer, D. S. S. (2021). Time series: a data analysis approach using R. In *Journal of Quality Technology* (Vol. 53, Issue 3). <https://doi.org/10.1080/00224065.2020.1714517>







- SSPC, CNPC, & CENAPRED. (2015). Inundaciones. In *Syria Studies* (Vol. 7, Issue 1, pp. 37–72).
[https://www.researchgate.net/publication/269107473_What_is_governance/link/548173090cf22525dcb61443/download%0Ahttp://www.econ.upf.edu/~reynal/Civil wars_12December2010.pdf%0Ahttps://think-asia.org/handle/11540/8282%0Ahttps://www.jstor.org/stable/41857625](https://www.researchgate.net/publication/269107473_What_is_governance/link/548173090cf22525dcb61443/download%0Ahttp://www.econ.upf.edu/~reynal/Civil%20wars_12December2010.pdf%0Ahttps://think-asia.org/handle/11540/8282%0Ahttps://www.jstor.org/stable/41857625)
- ud din, S., Al-Dousari, A., Ramdan, A., & Al Ghabban, A. (2008). Site-specific precipitation estimate from TRMM data using bilinear weighted interpolation technique: An example from Kuwait. *Journal of Arid Environments*, 72(7), 1320–1328. <https://doi.org/10.1016/j.jaridenv.2007.12.013>
- UNAM. (2023). *Red Universitaria de Observatorios Atmosféricos*. Base de Datos Atmosféricos y Ambientales En Estaciones.
<https://www.ruoa.unam.mx/index.php?page=home>
- Velázquez-Ruiz, A., Rodríguez-Urbe, M. C., Carrillo-González, F. M., Morales-Hernández, J. C., Cruz-Romero, B., & Bravo-Olivas, M. L. (2022). Assessment of Temperature and Precipitation Forecasts of the WRF Model in the Bahía de Banderas Region (Mexico). *Atmosphere*, 13(8).
<https://doi.org/10.3390/atmos13081220>
- Wilks, D. S. (1998). Multisite generalization of a daily stochastic precipitation generation model. *Journal of Hydrology*, 210(1–4), 178–191.
[https://doi.org/10.1016/S0022-1694\(98\)00186-3](https://doi.org/10.1016/S0022-1694(98)00186-3)
- Zhiña, D., Pacheco, J., & Avilés, A. (2017). Modelos estocásticos para el pronóstico de sequías en la microcuenca del río Chulco en Ecuador
Stochastic models for droughts forecasting in the Chulco river micro-basin in Ecuador. *Revista de La Facultad de Ciencias Químicas*, 16, 44–61.



13. ANEXOS



ANEXO A: Eventos coincidentes para la estación MORE-UNAM y 76665-CONAGUA, duraciones de 2 a 5 horas.

- Eventos de 2 horas














Figura 52. Gráficas para eventos coincidentes de la estación MORE y 76665 a una duración de 2 horas.


- **Eventos de 3 horas**




EVENTOS COINCIDENTES DE LLUVIA A 3 HORAS





EVENTOS COINCIDENTES DE LLUVIA A 3 HORAS






- Eventos de 4 horas



- Eventos de 5 horas



ANEXO B.

Se presentan las parametrizaciones de las medias y desviación estándar para las series analizadas, se pudo observar que la parametrización mediante series de Fourier se ajusto de manera adecuada, permitiendo reducir los parámetros de las series originales.

- Series de Fourier para eventos de lluvia con duración de 3 horas

