

Universidad Autónoma de Querétaro
Facultad de Ingeniería
Licenciatura en Ingeniería Civil

Calibración del modelo de precipitación CRHUDA, para su
acoplamiento al sistema de alerta REDCIAQ.

Tesis

Que como parte de los requisitos para obtener el Grado de
Licenciado en Ingeniería Civil

Presenta
Isaac Carpintero Aguilar

Dirigido por:
Dr. M. Alfonso Gutiérrez López

Co-dirigido por:
Dr. Martín Muñoz Mandujano

Dr. M. Alfonso Gutiérrez López
Presidente

Dr. Martín Muñoz Mandujano
Secretario

M.C. Verónica Leyva Picazo
Vocal

M.S.I. José Alejandro Vargas Díaz
Suplente

M.C. Iván González García
Suplente

Centro Universitario, Querétaro. Qro.
Octubre de 2024
México

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.

AGRADECIMIENTOS

Cada decisión tomada en el pasado ha forjado el camino hasta este momento y las decisiones de hoy determinarán el sendero que se recorrerá el día de mañana, de cada una de ellas emana una responsabilidad la cual se tendrá que afrontar en algún momento de nuestras vidas, algunas son instantáneas, mientras que otras tardan meses o años en hacerse presentes, normalmente decidimos esperando que nuestra elección sea la mejor opción y que consigo se llegue a un objetivo, pero no siempre resulta de ese modo, es común que en ocasiones nuestras decisiones no sean las correctas, lo que nos lleva a lugares que no esperamos, a situaciones fuera de nuestro entendimiento, pero es gracias a esos momentos de apremio que podemos llegar a mostrar nuestra mejor faceta, de lo que somos capaces de hacer, solo ante la adversidad logra emerge el genio que habita en cada uno de nosotros. Hay ocasiones en donde deseamos claudicar, pues la marea causada por nuestras decisiones es tan fuerte que nos arrastra al fondo del océano, sin embargo, siempre hay alguien que nos brinda una mano para vencer la adversidad, que nos ayuda a seguir nadando hacia la orilla, y es gracias a ellos que podemos continuar. Resulta más sencillo afrontar los obstáculos de la vida y llegar a los objetivos que se plantean a diario cuando se cuenta con las personas adecuadas, y estoy profundamente agradecido por saber que la vida puso en mi camino a las personas correctas, las palabras siempre se quedarán cortas para poder expresar la gratitud que siento hacia cada una de ellas, a mis padres y hermanas, a los amigos que se convirtieron en familia, a los profesores que confiaron y apostaron por mí, al apoyo brindado por el CONAHCYT y la UNESCO en la realización de este trabajo, sé que un gracias no es suficiente, espero tener el tiempo necesario para demostrarles lo agradecido que estoy con cada uno de ustedes, las palabras se pierden fácil con el tiempo, pero aquellas que van acompañadas de acciones perduran por siempre, así que por ahora espero y se puedan conformar con este GRACIAS POR TODO.

SIMPLEMENTE GRACIAS.

ÍNDICE

RESUMEN.....	7
ABSTRACT.....	8
1. INTRODUCCIÓN	9
2. ANTECEDENTES Y JUSTIFICACIÓN	10
2.1. Estado del Arte.....	11
3. HIPÓTESIS.....	14
4. OBJETIVO GENERAL.....	14
4.1. Objetivos particulares.....	14
5. FUNDAMENTACIÓN TEÓRICA.....	14
5.1. Definiciones	14
5.2. Descripción del sistema de monitoreo	15
5.3. Herramientas de Modelación Hidrológicas.....	15
6. METODOLOGÍA	17
6.1. La humedad de la atmósfera	17
6.2. Modelo CRHUDA	19
6.3. Seleccionar una estación de la RedCIAQ y aplicar el modelo CRHUDA.....	20
6.4. Proposición del factor de ajuste o escalamiento del modelo.....	21
6.5. Análisis Multivariado.....	23
7. RESULTADOS.....	28
7.1. Resultados del modelo CRHUDA	28
7.2. Resultados del análisis multivariado.....	49
8. CONCLUSIONES	51
8.1 Comentarios finales.....	54
9. REFERENCIAS.....	55
10. APÉNDICES.....	58
Apéndice A.....	58
Apéndice B.....	59
Apéndice C.....	76

ÍNDICE DE FIGURAS

Figura 1. Arquitectura básica de RedCIAQ	15
Figura 2. Esquema conceptual del modelo CRHUDA.....	20
Figura 3. Gráfica de las series y precipitación para la tormenta 1	32
Figura 4. Gráfica de las series y precipitación para la tormenta 2	33
Figura 5. Gráfica de las series y precipitación para la tormenta 3	33
Figura 6. Gráfica de las series y precipitación para la tormenta 4	34
Figura 7. Gráfica de las series y precipitación para la tormenta 5	34
Figura 8. Gráfica de las series y precipitación para la tormenta 6	35
Figura 9. Gráfica de las series y precipitación para la tormenta 7	35
Figura 10. Gráfica de las series y precipitación para la tormenta 8	36
Figura 11. Gráfica de las series y precipitación para la tormenta 9	36
Figura 12. Gráfica de las series y precipitación para la tormenta 10	37
Figura 13. Cruce de las series exactamente al inicio de la precipitación para la tormenta 1	38
Figura 14. Cruce de las series exactamente al inicio de la precipitación para la tormenta 2...	38
Figura 15. Cruce de las series exactamente al inicio de la precipitación para la tormenta 3...	39
Figura 16. Cruce de las series exactamente al inicio de la precipitación para la tormenta 4...	39
Figura 17. Cruce de las series exactamente al inicio de la precipitación para la tormenta 5...	40
Figura 18. Cruce de las series exactamente al inicio de la precipitación para la tormenta 6...	40
Figura 19. Cruce de las series exactamente al inicio de la precipitación para la tormenta 7...	41
Figura 20. Cruce de las series exactamente al inicio de la precipitación para la tormenta 8...	41
Figura 21. Cruce de las series exactamente al inicio de la precipitación para la tormenta 9...	42
Figura 22. Cruce de las series exactamente al inicio de la precipitación para la tormenta 10	42
Figura 23. Cruces de las series en la tormenta 1 con un factor $\beta = 1.1$	43

Figura 24. Cruces de las series en la tormenta 2 con un factor $\beta = 1.1$	44
Figura 25. Cruces de las series en la tormenta 3 con un factor $\beta = 1.1$	44
Figura 26. Cruces de las series en la tormenta 4 con un factor $\beta = 1.1$	45
Figura 27. Cruces de las series en la tormenta 5 con un factor $\beta = 1.1$	45
Figura 28. Cruces de las series en la tormenta 6 con un factor $\beta = 1.1$	46
Figura 29. Cruces de las series en la tormenta 7 con un factor $\beta = 1.1$	46
Figura 30. Cruces de las series en la tormenta 8 con un factor $\beta = 1.1$	47
Figura 31. Cruces de las series en la tormenta 9 con un factor $\beta = 1.1$	47
Figura 32. Cruces de las series en la tormenta 10 con un factor $\beta = 1.1$	48
Figura 33. Círculo de correlación ACP para las variables del modelo CRHUDA	50
(Representación de 73.3% en los ejes 1-2)	50
Figura 34. Círculo de correlación ACP para las variables del modelo CRHUDA	51
(Representación de 41% en los ejes 2-3)	51
Figura 35. Modelo CRHUDA para la tormenta 24-25 de junio de 2013 estación Milenio ($\beta = 1$)	52
Figura 36. Modelo CRHUDA para la tormenta 24-25 de junio de 2013 estación Milenio ($\beta = 0.5$)	53

ÍNDICE DE TABLAS

Tabla 1. Fecha de ocurrencia de tormentas	20
Tabla 2. Tabla de verdad de la lógica propositiva del modelo CRHUDA.....	21
Tabla 3. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 1.....	28
Tabla 4. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 2.....	28
Tabla 5. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 3.....	29
Tabla 6. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 4.....	29
Tabla 7. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 5.....	29
Tabla 8. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 6.....	30
Tabla 9. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 7.....	30
Tabla 10. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 8.....	30
Tabla 11. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 9.....	31
Tabla 12. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 10.....	31
Tabla 13. Valores de los factores de escala β	37
Tabla 14. Resultados del análisis de sensibilidad y valores del factor de escala modelo CRHUDA tormentas extremas ocurridas en septiembre en la estación Milenio	49

RESUMEN

La anticipación de lluvias intensas es una de las primordiales preocupaciones en hidrología para América Latina y el Caribe (LAC). Cada año los daños provocados por las inundaciones aumentan, principalmente debido a las precipitaciones convectivas y huracanes. En la mayoría de naciones de esta zona no se dispone de un monitoreo hidrometeorológico. El establecimiento de un modelo efectivo de pronóstico de precipitaciones es uno de los desafíos fundamentales en la región LAC, el cual podría utilizarse en un Sistema de Alerta Temprana (SAT). El objetivo de este estudio es dar una predicción efectiva de las lluvias a corto plazo utilizando un grupo de factores climáticos fundamentados en la ecuación de Clausius-Clapeyron. Considerando que el vapor de agua atmosférico es una de las variables que más afectan a los fenómenos meteorológicos, en particular a las precipitaciones, se ha propuesto un modelo sencillo de previsión de las precipitaciones. El modelo se basa en datos monitorizados cada minuto, como la humedad, la temperatura superficial, la presión atmosférica y el punto de rocío. El modelo propuesto se ha desarrollado a partir de una base de datos histórica de 1237 tormentas, lo que permite seleccionar la combinación adecuada de estas variables. Los resultados demuestran que la metodología propuesta predijo con éxito la aparición de precipitaciones en función de la presión atmosférica, la humedad y el punto de rocío.

Palabras clave: Precipitación, presión atmosférica, humedad y punto de rocío.

ABSTRACT

The anticipation of heavy rainfall is a major concern in hydrology for Latin America and the Caribbean (LAC). Each year flood damage increases, mainly due to convective rainfall and hurricanes. Hydrometeorological monitoring is lacking in most nations in this area. The establishment of an effective rainfall forecast model is one of the fundamental challenges in the LAC region, which could be used in an Early Warning System (EWS). The objective of this study is to provide an effective short-term rainfall prediction using a set of climatic factors based on the Clausius-Clapeyron equation. Considering that atmospheric water vapor is one of the variables that most affect meteorological phenomena, particularly precipitation, a simple model for precipitation forecasting has been proposed. The model is based on data monitored every minute, such as humidity, surface temperature, atmospheric pressure and dew point. The proposed model has been developed from a historical database of 1237 storms, which allows selecting the appropriate combination of these variables. The results show that the proposed methodology successfully predicted the occurrence of precipitation as a function of atmospheric pressure, humidity and dew point.

Keywords: Rainfall, atmospheric pressure, humidity and dew point.

1. INTRODUCCIÓN

La RedCIAQ de Monitoreo de Precipitaciones Extremas en el estado de Querétaro, del Centro de Investigaciones del Agua (CIAQ) de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro (UAQ), es un conjunto de estaciones y herramientas hidro-informáticas que se encuentran en un portal Web para consulta de la población (<http://www.redciaq.uaq.mx/index.html>).

La Red de Monitoreo del CIAQ está compuesta por más de 40 estaciones meteorológicas que miden variables hidrológicas en tiempo real (cada minuto) en todo el territorio del estado de Querétaro, con presencia de al menos una estación en cada uno de sus municipios. Las variables monitoreadas son: temperatura, presión atmosférica, punto de rocío, velocidad y dirección del viento, precipitación, radiación solar y humedad relativa. El conjunto de investigadores, profesores y alumnos que forman parte de la RedCIAQ está trabajando en la creación de herramientas hidro-informáticas relacionadas con este sistema de monitoreo que posibilitan el empleo de la información medida y enviada en tiempo real. Una de estas herramientas hidro-informáticas es el modelo CRHUDA por sus siglas en inglés (*Crossing HUmidity, Dew point, and Atmospheric pressure*). Aplicando este modelo se puede predecir el inicio de la precipitación hasta con ocho horas de anticipación.

El problema es que este modelo CRHUDA se quiere acoplar a un Sistema de Alerta Temprana, pero se requiere de un Factor de Ajuste previo para lograr una precisión al momento de dar la alerta. A la fecha no se logrado ninguna recomendación al respecto. El propósito principal de esta investigación es proponer un factor de escala para el óptimo funcionamiento del modelo CRHUDA.

2. ANTECEDENTES Y JUSTIFICACIÓN

Las inundaciones son fenómenos recurrentes en México, las cuales provocan año con año grandes pérdidas económicas a la infraestructura, daños a la agricultura y al bienestar público. La principal causa de estas inundaciones, se debe a las fuertes precipitaciones que ocurren en las zonas urbanas de nuestro país. La red denominada RedCIAQ cuenta con una adquisición de datos cada minuto y se almacena en una base de datos relacionada de donde se extraen los datos para las distintas herramientas hidro-informáticas. La importancia de la prevención de desastres se ha destacado en el programa nacional de defensa civil, reconociendo la necesidad de desarrollar estrategias y planes a largo plazo centrados en la prevención y reducción de los impactos de diversos fenómenos que pueden desencadenar desastres en nuestra nación. Uno de los pasos fundamentales de una estrategia preventiva es reconocer los riesgos y amenazas para saber dónde, cuándo y cómo nos afectan (CENAPRED, 2016).

Dentro de las actividades de difusión de la ciencia que realiza el Centro de Investigaciones del Agua (CIAQ) de la Facultad de Ingeniería de la Universidad Autónoma de Querétaro, se encuentra realizar análisis técnicos-científicos de los fenómenos hidrometeorológicos que ocurren en nuestro estado. A partir del monitoreo de la RedCIAQ y sus herramientas hidro-informáticas, el CIAQ ha instalado y puesto en marcha, en la zona metropolitana de la ciudad de Querétaro, una red de monitoreo de variables hidrometeorológicas como: temperatura, precipitación, presión atmosférica, velocidad y dirección del viento.

Dentro de los aportes científicos de la RedCIAQ, podemos mencionar el sistema de alerta temprana. Este sistema denominado CRHUDA por sus siglas en inglés (*Crossing HUmidity, Dew point, and Atmospheric pressure*) utiliza series de tiempo de humedad, presión atmosférica y temperatura del punto de rocío, para el pronóstico de inicio de la precipitación. Es un modelo utilizado por las Autoridades de Protección Civil y requiere de una calibración permanente para su óptimo funcionamiento.

2.1. Estado del Arte

En México, como en otros países de Latinoamérica y el Caribe (LAC), escasean los datos históricos de precipitaciones medidas en intervalos inferiores a 24 horas. Las mediciones en tiempo real suelen ser necesarias para implementar sistemas de alerta temprana. En México, los desastres se miden por el impacto económico de los daños y pérdidas, así como por los problemas causados en el entorno social, como lesiones, víctimas mortales y daños a edificios, escuelas y hospitales, entre otros. Entre 2000 y 2014, se registraron pérdidas por un total de 2147 millones de dólares y 186 muertes anuales (CENAPRED, 2016). En 2013, se produjeron precipitaciones especialmente intensas, sobre todo en septiembre, y la profundidad histórica de las precipitaciones aumentó un 60% en comparación con la media histórica. La media mensual fue de 227.3 mm, superando el récord de 1955 de 212.1 mm (Gutierrez-Lopez et al., 2019). En las predicciones meteorológicas intervienen múltiples variables, como la temperatura, la humedad, el viento y el punto de rocío, entre otras, en un intento de ofrecer un pronóstico preciso. Sin embargo, la predicción puede ser un reto debido a las pequeñas escalas implicadas, la gama de mecanismos físicos implicados y la dificultad de predecir eventos a corto plazo. Las pruebas iniciales muestran una relación exponencial entre el logaritmo natural de las precipitaciones y la temperatura de la superficie (Lepore et al., 2016). Es importante señalar que la precipitación es episódica y carece de valores continuos como la temperatura y otras variables climáticas, lo que dificulta anticipar su ocurrencia. Lorenz y Saltzman (Saltzman, 1959, 2022; Lorenz, 1963) fueron de los primeros en reconocer que el clima es un sistema complejo y no lineal que comprende componentes tanto deterministas como estocásticos. Sin embargo, el concepto fundamental de que la precipitación convectiva se origina en función de la temperatura de la superficie fue demostrado por Berg y Haerter, 2013; el autor utilizó datos de temperatura y de estaciones pluviométricas con intervalos de acumulación de 5 minutos. La relación entre la temperatura y la magnitud de la energía potencial convectiva disponible (CAPE) es fuerte. Por lo tanto, la temperatura y la humedad se consideran las principales variables para predecir la precipitación (Holley et al., 2014). Sin embargo, el aire, la temperatura del punto de rocío (o humedad relativa), la velocidad del viento y la nubosidad también están fuertemente correlacionados con las precipitaciones (Lekouch et al., 2012). Los estudios científicos han

demostrado que el gradiente de temperatura provoca un aumento de la intensidad de las precipitaciones. Concretamente, la precipitación subdiaria u horaria tiene una mayor correlación con las restricciones termodinámicas, lo que se conoce como relación Clausius-Clapeyron (C-C) (Park y Min, 2017).

Se ha verificado que este evento ocurre con diversas formas de precipitación, incluidas las precipitaciones orográficas y convectivas (Dyson et al., 2014). En las regiones tropicales, Omotosho, 1989, demostró hace 30 años que la temperatura de la superficie era una variable meteorológica importante para comprender los sistemas meteorológicos tropicales. Este fue uno de los primeros estudios en utilizar los gradientes de temperatura para la predicción de la neblina de polvo. Desde 1990, los estudios estadísticos multivariantes de 28 variables climáticas en Australia han demostrado que los principales factores para crear un modelo climático son la humedad, la temperatura y las precipitaciones (Puvanewaran, 1990).

Predecir con exactitud la intensidad de las precipitaciones es crucial para predecir los caudales extremos (Damrath et al., 2000). Las investigaciones previas han puesto su atención mayormente en la información hidrometeorológica como el viento, la temperatura, la humedad y la presión atmosférica. Esta información se ha utilizado para crear previsiones diarias de caudales con plazos de 5-7 días (Rasouli et al., 2012). Sin embargo, el objetivo de un sistema de alerta temprana (EWS), un sistema de alerta temprana de inundaciones (FEWS) o un sistema de predicción por conjuntos (EPS) es avisar con antelación de los fenómenos extremos, en particular de las precipitaciones intensas a corto plazo. Los recientes avances en las técnicas de aprendizaje automático han puesto de relieve la importancia de utilizar datos hidrometeorológicos para un sistema de alerta temprana eficaz en caso de fenómenos a corto plazo (aviso de lluvia intensa en las próximas 3-9 horas) (Moon et al., 2019). Sin embargo, es importante reconocer la importancia de la predicción cuantitativa de precipitaciones a corto plazo (SQPF) para proporcionar avisos de inundaciones repentinas, garantizar la seguridad de la navegación y apoyar otras aplicaciones diversas. Recientemente, Zahraei et al. (2013) introdujeron el método PERsiann-ForeCAST, que utiliza las imágenes de tormentas más recientes para extraer las características de las tormentas y predecir la localización y el índice de precipitaciones durante un máximo de cuatro horas. Pruebas

recientes indican que un modelo de previsión con un componente de nowcasting basado en radar puede predecir patrones de distribución de las precipitaciones para tormentas de intensidad moderada a fuerte (30-50 mm/h) durante 1-2 horas (Li y Lai, 2004). Sin embargo, la aplicación del SQPF puede resultar complicada, sobre todo cuando se utilizan modelos para simular procesos hidrológicos en un intervalo de tiempo diario u horario. Esto se debe a la importante variación espacial de las precipitaciones (Carrera-Hernández y Gaskin, 2007). La evolución de las herramientas hidro-informáticas en la última década no ha tenido precedentes. Muchos analistas sostienen que la adición de más datos horarios de superficie, como el viento, la humedad específica (punto de rocío), la temperatura del aire, la vorticidad relativa y el flujo de divergencia de la humedad, ha dado buenos resultados cuando se combina con un marco bayesiano (Carter et al., 2000) o una red neuronal utilizada para generar previsiones de precipitaciones para el siguiente paso temporal (Valverde et al., 2005). Es importante comprender las variables que generan la lluvia y encontrar la combinación adecuada de estas variables para pronosticar con precisión el momento de inicio de una tormenta. Por lo tanto, una de las tareas más cruciales de la hidrología moderna es desarrollar modelos sencillos y eficaces para predecir fenómenos extremos.

3. HIPÓTESIS

El cruce de dos series de tiempo: (1) Humedad y (2) Presión atmosférica/punto de rocío, representadas gráficamente; identifica el punto de inicio de la precipitación.

4. OBJETIVO GENERAL

- Proponer un factor de escala que permita optimizar el cálculo con el modelo CRHUDA para el pronóstico del inicio de la precipitación.

4.1. Objetivos particulares

1. Aplicar el modelo CRHUDA a una de las estaciones de la RedCIAQ.
2. Comprobar que el modelo permite conocer el inicio de la precipitación.
3. Dar recomendaciones para su aplicación a un sistema de alerta.

5. FUNDAMENTACIÓN TEÓRICA

Para lograr una correcta calibración del modelo CRHUDA, es necesario primero algunos conceptos básicos.

5.1. Definiciones

Precipitación acumulada. Altura de la lluvia medida en milímetros (mm) que se registra en un pluviómetro y que está asociada a la duración total de una tormenta. Es importante también considerar la lluvia acumulada en 24 horas.

Intensidad de precipitación. Magnitud de la lluvia asociada con su energía (erosión del suelo y afectaciones en infraestructura urbana). Se mide en milímetros por hora y puede ser asociada a un semáforo de alerta.

que a la fecha se ha generado con este monitoreo, ha sido la base del desarrollo de una decena de tesis de licenciatura, maestría y doctorado. Por lo que la RedCIAQ es además una base sólida para la formación de recursos humanos altamente especializados. Asimismo, estos desarrollos tecnológicos han permitido dar un soporte científico e innovador a esta importante labor de monitorear variables hidroclimatológicas como un eficiente método de prevención ante eventuales desastres de origen meteorológico. Es importante considerar que la mayoría de las herramientas de hidro-informática se han generado por la solicitud específica de usuarios de la RedCIAQ. Por ejemplo, las autoridades de Protección Civil Estatal y Municipales, solicitaron visualizar de manera rápida y eficiente la evolución de las intensidades de precipitación durante una tormenta; es así que se desarrolla un semáforo de alertas con colores. Esta herramienta computacional denominada semáforo de alerta está actualmente siendo visualizado a tiempo real por las autoridades municipales del CECOM lo cual representa una gran labor de prevención. Otra de las herramientas que ha sido desarrollada para la prevención es la modelación a tiempo real del proceso lluvia escurrimiento. Esto consiste en utilizar a tiempo real la medición de la precipitación para modelar de forma matemática la evolución en el caudal máximo que presentan los principales drenes y canales que se localizan en la zona urbana de la ciudad de Querétaro. Esta herramienta también es utilizada por las autoridades y por la ciudadanía en general para alertar y prevenir posibles desbordamientos y fallas en la infraestructura. Cabe mencionar que este sistema se complementará, este otoño de 2024, con cámaras de monitoreo a tiempo real que permitan verificar la evolución de los niveles del agua. De esta forma es como la RedCIAQ ha desarrollado herramientas computacionales que permiten un pleno conocimiento de los fenómenos hidrometeorológicos que afectan nuestro estado. Debe destacarse también que dentro de los productos que ofrece esta RedCIAQ de monitoreo está la creación de reportes una vez que ha ocurrido una tormenta; esto con el objeto de informar a la población y a las autoridades de los resultados de un análisis forense científico del fenómeno ocurrido.

6. METODOLOGÍA

La metodología se base en los siguientes pasos:

- i. Verificar la relación entre humedad, punto de rocío y presión atmosférica.
- ii. Aplicar el modelo CRHUDA
- iii. Seleccionar una estación de la RedCIAQ y aplicar el modelo CRHUDA
- iv. Proponer el factor de ajuste o escalamiento del modelo

6.1. La humedad de la atmósfera

Las moléculas de agua ejercen una presión parcial que puede aumentar hasta alcanzar un umbral. En este punto, el número de moléculas de agua que se evaporan del líquido es igual al número que vuelven de la atmósfera, lo que crea un equilibrio dinámico entre evaporación y condensación, conocido como saturación. La temperatura T determina el umbral de saturación, que es independiente de la presión del aire seco. Si la presión cambia (ΔP), se debe al trabajo realizado (W), que es igual al calor latente (C) multiplicado por el cambio de temperatura (ΔT).

$$\Delta W = C \frac{\Delta T}{T} \quad (1)$$

Para provocar un cambio de estado, hay que modificar el volumen específico. Esto significa obtener un diferencial de los volúmenes gas-líquido, como se observa en la ecuación 2.

$$W = \Delta P (V_g - V_l) \quad (2)$$

Al igualar ambas ecuaciones se obtiene la relación Clausius-Clapeyron (C-C) que se muestra en la Ecuación 3.

$$\frac{\Delta P}{\Delta T} = \frac{\partial P}{\partial T} = \frac{C}{T \Delta V} \quad (3)$$

Clapeyron dedujo esta formulación de la teoría de Carnot y Clausius la puso a prueba. La relación C-C describe el comportamiento de un sistema cerrado durante un cambio de fase cuando la temperatura y la presión son constantes. El supuesto básico de la relación C-C es

que, a medida que aumenta la temperatura, la humedad relativa permanece constante, y la humedad específica aumenta debido a una mayor disponibilidad de humedad en la atmósfera (Park & Min, 2017). En las regiones tropicales, las precipitaciones pueden aumentar más de lo previsto por la relación Clausius-Clapeyron. Como resultado, puede ser necesaria una respuesta compensatoria diferente (Chang et al., 2016). Es importante utilizar la relación C-C de forma adecuada y detallada a la hora de predecir la precipitación. Según Lenderink et al. (2017), las actuales relaciones de escala entre precipitación y temperatura sugieren que las precipitaciones extremas por hora podrían responder al calentamiento más que la relación Clausius-Clapeyron. La temperatura del punto de rocío (T_d) es la temperatura a la que el aire se satura si se enfría a presión constante (Seidel et al., 2007). Esto ocurre cuando la presión de vapor es igual a la presión de saturación del aire (relación de mezcla del vapor de agua). Del mismo modo, el volumen de vapor en la atmósfera puede expresarse a través de la presión que genera (Chang et al., 2016; Millán et al., 2010). Sin embargo, la presión total en la atmósfera es la suma de la presión causada por el aire seco y el vapor de agua (Harder y Pomeroy, 2013; Holley et al., 2014). La cantidad de vapor de agua presente depende de la temperatura de la superficie (Dahm et al., 2019). A medida que aumenta la temperatura, el aire puede contener más vapor de agua (Mohr & Kunz, 2013; Myoung & Nielsen-Gammon, 2010). Esta relación se expresa mediante la ecuación de Clausius-Clapeyron (Gao et al., 2007; Wang et al., 2018). Por lo tanto, cuando el aire contiene una gran cantidad de vapor de agua, la presión del vapor de agua depende únicamente de la temperatura (Sim et al., 2019). Por el contrario, la temperatura de las corrientes ascendentes húmedas en la superficie y la profundidad de las nubes están directamente relacionadas con el punto de rocío superficial (Lenderink et al., 2017). Por lo tanto, debe proponerse un modelo directo que exprese la relación (ratio) entre la presión y el punto de rocío ($\partial P / \partial T_d$). Este modelo debería confirmar el papel fundamental de la humedad superficial en la actividad convectiva. Si los parámetros meteorológicos como la presión, la temperatura y la humedad relativa cambian a diferentes altitudes (Liu et al., 2015), se puede implementar un modelo de evolución sinóptica que cruce una serie de humedad, punto de rocío y presión atmosférica.

6.2. Modelo CRHUDA

A partir de lo propuesto por Muñoz-Mandujano et al., (2024), se propone un modelo estadístico de tipo ARMA(p,q) el cual se encuentra compuesto por un modelo autorregresivo AR de orden (p) en el cual se agrega el componente MA (q), conocido como promedio móvil. Para la construcción del presente modelo al que se le denominó CRHUDA, se tienen dos series independientes ($S1 \subseteq S2$) de variables climáticas S1 y S2.

$$\begin{aligned} S1 &= H_t = \phi_1 H_{t-1} + \varepsilon_t \\ S2 &= C_t = \varphi_1 C_{t-1} + \varepsilon_t \end{aligned} \tag{4}$$

Donde $\phi_1 = r_1$ y $\varphi_1 = r_1$ son los coeficientes de correlación serial $k=1$ para cada una de las series. Esto significa que existe un coeficiente de proporcionalidad en ambas series que permite escalar la serie para cruzarla en el tiempo t_1 . Sin embargo, hay que recordar que el coeficiente de auto-correlación de retraso k es igual a 1.

La C en la ecuación (3) se sustituye por el valor de la presión atmosférica (P), y en el denominador, (T) se sustituye por la temperatura del punto de rocío (Td), similar a (Shaw et al., 2011). De esta manera, se grafican dos series temporales diferentes: la primera es el dato de humedad (S1) y la segunda es la serie (S2), definida por $\left(\frac{\partial P}{\partial T_d}\right)$, similar a la relación Clausius-Clapeyron. El cruce de estas dos series mostrará al principio de la alerta ($t_1: S1 \subseteq S2$), y algunas horas después, la serie T_t se cruza una vez más ($t_2: S1 \cap S2$) y en ese momento la precipitación se inicia (ocurre) $T_t + \Delta t$. La figura 2 muestra el esquema conceptual del modelo CRHUDA. Si el modelo predice el comienzo exacto de la precipitación, entonces $\Delta t \rightarrow 0$.

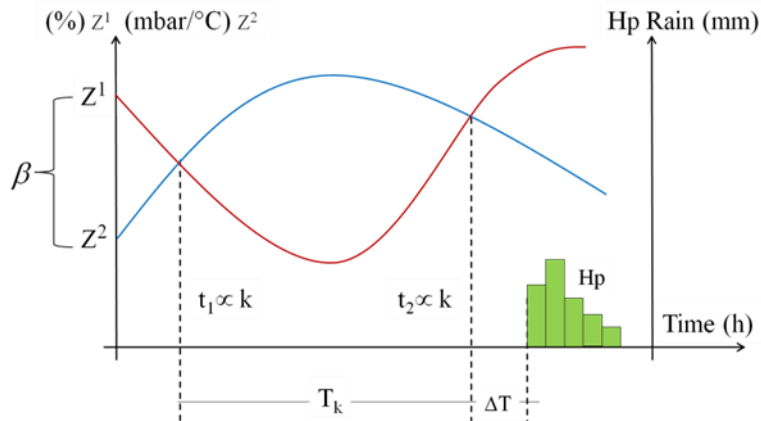


Figura 2. Esquema conceptual del modelo CRHUDA.
(CRossingHumedad, Dewpoint, and Atmospheric Presión)
 Gutierrez et al., (2019) y Muñoz-Mandujano et al., (2024)

Esto quiere decir que para que la precipitación empiece es necesario que ocurra en t_1 $H_{t_1} = C_{t_1}$; $(S_1 \cap S_2)$, y considerando $T_t + \Delta t$, $H_{t_2} = C_{t_2}$ en t_2 . Si $\Delta t = 0$, entonces el pronóstico del principio de la precipitación E es preciso. Si $\Delta t \neq 0$, existe un tiempo de retraso en el inicio de la precipitación del evento E .

6.3. Seleccionar una estación de la RedCIAQ y aplicar el modelo CRHUDA

Se utilizaron los datos de diez tormentas seleccionadas (Tabla 1) de la red de monitoreo de precipitaciones extremas RedCIAQ que incluye el sistema de alerta para la ciudad de Querétaro en el centro de México. Formado por más de 40 Estaciones Meteorológicas Automáticas (EMA) distribuidas en la zona metropolitana de la ciudad de Querétaro (Apéndice A).

Tabla 1. Fecha de ocurrencia de tormentas.

Tormenta	Fecha		
	Día	Mes	Año
1	8	Septiembre	2013
2	16	Septiembre	2013
3	21	Septiembre	2013
4	17	Septiembre	2015

5	25	Septiembre	2016
6	26	Septiembre	2017
7	9	Septiembre	2018
8	19	Septiembre	2019
9	29	Septiembre	2019
10	7	Septiembre	2021

6.4. Proposición del factor de ajuste o escalamiento del modelo

Para proponer un factor que ajuste ambas series y se pueda realizar un pronóstico preciso del inicio de la precipitación, se propone utilizar una tabla lógica. Esto significa que en términos de lógica propositiva, la construcción de la tabla de verdad se muestra a continuación (Tabla 2). Comienza con las dos premisas principales: Si hay un cruce de las dos series propuestas en el tiempo ($t1: S1 \subseteq S2$) entonces, algunas horas más tarde, la serie T_t se cruzará de nuevo ($t2: S1 \cap S2$) y, en ese momento, $T_t + \Delta t$, comenzará la precipitación. Si no se cruza, entonces no habrá lluvia y entonces se puede proponer un factor de ajuste.

Tabla 2. Tabla de verdad de la lógica propositiva del modelo CRHUDA.

$S1 \subseteq S2$	$S1 \cap S2$	$(S1 \subseteq S2) \rightarrow (S1 \cap S2)$	$\neg (S1 \subseteq S2) \rightarrow \neg (S1 \cap S2)$	$(S1 \subseteq S2) \rightarrow (S1 \cap S2) \wedge \dots$ $\dots \neg (S1 \subseteq S2) \rightarrow \neg (S1 \cap S2)$
Verdadero	Verdadero	Verdadero	Verdadero	Verdadero
Verdadero	Falso	Falso	Verdadero	Falso
Falso	Verdadero	Verdadero	Falso	Falso
Falso	Falso	Verdadero	Verdadero	Verdadero

Se concluye que es, de hecho, un modelo válido del tipo contingencia; una proposición compuesta que a veces es verdadera y a veces falsa. Es decir, se entiende por verdad contingente, o verdad, de hecho, aquella proposición que puede ser verdadera o falsa, según los valores de sus proposiciones constituyentes. Se introduce un factor de escala β que será proporcional a la serie de valores de autocorrelación serial.

$$(Z_{t-k}^1 \subseteq Z_{t-k}^2) \propto \beta (Z_{t-k}^1 \cap Z_{t-k}^2) \quad (5)$$

Se puede determinar la función de autocorrelación $r_k = f(Z_{t-k}^1 \subseteq Z_{t-k}^2)$ para cualquier proceso, proporcional a $f = [\beta(Z_{t-k}^1 \cap Z_{t-k}^2)]$. De esta forma se propone un punto de análisis de sensibilidad del modelo CRHUDA. Los residuales de las dos series $\varepsilon \rightarrow (Z_{t-k}^1 \subseteq Z_{t-k}^2)$ deben tener media cero y no deben estar correlacionados, lo cual garantiza su independencia del tiempo k . Esto es: $\varepsilon = [\varepsilon_t, t \in N]$; $E[\varepsilon_t | \varepsilon_{t-1}] = 0$ y $Var[\varepsilon_t] = \sigma_\varepsilon^2$. De las propiedades de la función de autocorrelación se tiene que $C_0 = E[(X_t - \bar{X})^2] = Var[X_t] = \sigma_x^2$ si $k = 0$ entonces C_0 es la varianza estacionaria en t_0 . Por lo tanto si las series Z_{t-k}^1 y Z_{t-k}^2 son independientes, entonces $r_k = \frac{C_k}{C_0} \rightarrow 0$ tiende a cero. Sin embargo, al ser un modelo estocástico multivariado las series deben cumplir la condición de independencia y estacionariedad conjunta. Esto puede verificarse de manera sistemática con la ayuda de los límites del correlograma-multivariado; de esta forma se propone que:

Lemma 1. *Un coeficiente de autocorrelación r_k calculado a partir de una serie estocástica multivariada $f(Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n)$ fuera de los límites de confianza del correlograma; representa un punto de quiebre en las series Z_{t-k}^n . Este punto de quiebre ubica a su vez los tiempos t_1 y t_2 de cruce entre las series que forman el modelo CRHUDA.*

Lemma 2. *El tiempo k de cruce entre las series del modelo CRHUDA; puede ser modificado en un tiempo T_k empleando un factor de escala β tal que $(Z_{t-k}^1 \subseteq Z_{t-k}^2) \propto \beta(Z_{t-k}^1 \cap Z_{t-k}^2)$.*

Ajustando la función de autocorrelación se tiene:

$$C_k = E[(X_t - \bar{X})(X_{t+k} - \bar{X})] = E[(X_{t-k} - \bar{X})(X_\beta - \bar{X})] \text{ con } \beta = t + k \quad (6)$$

Para asociar el tiempo Lag que ocurre en r_k es necesario hacer:

$$(Lag)_k = Lag(Lag + 1)(Lag + k - 1) = \frac{\Gamma(Lag + k)}{\Gamma(Lag)} \approx \frac{(Lag + k - 1)!}{(Lag - 1)!} \quad (7)$$

Si $\beta > 0$; $(\beta)_0 = 1$ y $(1)_k = k!$ entonces k es el tiempo *Lag* que ocurre en r_k (Lemma 1) para $r_k = \beta - 1 > 0$

$$\begin{aligned}
 (\beta)_k &= \beta(\beta + 1)(\beta + 2) \cdots (\beta + k - 1) \\
 (\beta)_k &= (r + 1)(r + 2) \cdots (r + k) \\
 (\beta)_k &= \frac{1}{r} r(r + 1)(r + 2) \cdots (r + k) = \frac{1}{r} (r)_{k+1}
 \end{aligned} \tag{8}$$

Entonces una relación de recurrencia puede escribirse como:

$$\begin{aligned}
 (\beta)_k &= \frac{(\beta - 1)_{k+1}}{\beta - 1} \\
 (\beta)_{k+1} &= \beta(\beta + 1)_k
 \end{aligned} \tag{9}$$

6.5. Análisis Multivariado

El Análisis de Componentes Principales (ACP) es una técnica estadística multivariada, particularmente descriptiva. Es un procedimiento ya tradicional que tiene su origen en los años treinta, sin embargo su utilización en temas de política pública se considera reciente. H. Hotelling (1933), propuso las bases del análisis por componentes principales basado en los resultados de los trabajos de Karl Pearson (1901), quien ajustó una línea o un plano, a un grupo de puntos en un espacio multidimensional. Fue en los años sesenta con el incremento de la computación cuando esta técnica fue mayormente empleada y su apogeo fue en los años ochenta con el enfoque francés de este análisis, desarrollado por Benzecri (1980), lo que permite con la formulación de Hotelling el tratamiento de grandes bases de datos.

El ACP es una técnica que permite reducir la dimensión de conjunto de datos que se encuentran correlacionados en un espacio multivariado de p variables; a un conjunto transformado de q variables no correlacionadas ($q \leq p$) llamadas componentes principales. Las p variables son medidas sobre cada uno de los n elementos, obteniéndose una matriz de datos de orden np ($p < n$). Las q componentes principales (nuevas variables) son una combinaciones lineales de las variables originales. Los componentes se ordenan en función

del porcentaje de varianza explicada; es decir, el primer componente será el más importante por ser el que explica con un mayor porcentaje la varianza de la muestra de datos. Entre los usos más frecuentes del ACP podemos mencionar:

- Como método de exploración de datos que ayuda a encontrar conexiones entre los datos y en función de los resultados, sugerir los análisis estadísticos más adecuados.
- Disminuir el tamaño de la matriz de información para prevenir repeticiones y resaltar conexiones. La mayoría de las veces, al considerar únicamente los primeros elementos, se puede explicar la mayoría de la variabilidad total presente en los datos originales.
- Crear factores no observables (elementos) utilizando variables que se pueden observar.

El planteamiento general de la transformación de componentes principales, es transformar el espacio de representación P en un nuevo espacio P^* , en donde los datos (mediciones) no presenten correlación alguna (la matriz de covarianza en ese espacio será diagonal). Es decir, se trata de encontrar un nuevo conjunto de ejes ortogonales en el que la varianza de los datos sea máxima. Considerando un conjunto de puntos en dos dimensiones que presentan un cierto grado de correlación, se concluye que su dispersión es mayor en los ejes X_2 y Y_2 una vez que los puntos son proyectados sobre el eje X_2 . Este nuevo eje se calcula como una rotación del eje original X_1 y lo mismo para el segundo eje (puesto que se consideran ortogonales), esto puede expresarse con una transformación lineal del tipo.

$$\begin{aligned} X_2 &= W_{11}X_1 + W_{12}Y_1 \\ Y_2 &= W_{21}X_1 + W_{22}Y_1 \end{aligned} \quad (10)$$

Con esta transformación, la longitud del eje mayor X_2 indicará el rango de los datos a lo largo de este nuevo eje, que será necesariamente mayor que sobre cualquiera de los ejes originales (X_1, Y_1) . En consecuencia, dependiendo de la relación entre los ejes originales, la mayor parte de la información contenida en el espacio P puede retenerse únicamente en el

$$F = W^T [\text{Cov}_{(X_1, Y_1)}] W - \lambda (W^T W - I) \quad (14)$$

y derivando (14) respecto a W ,

$$([\text{Cov}_{(X_1, Y_1)}] - \lambda I) W = 0 \quad (15)$$

Adicionalmente, W debe verificar que $([\text{Cov}_{(X_1, Y_1)}] - \lambda I) W = 0$ con objeto de que $W^T [\text{Cov}_{(X_1, Y_1)}] W = [\text{Cov}_{(X_2, Y_2)}]$ sea máxima, sujeta a la restricción de que $W^T W = I$.

Para que la ecuación (15) sea cierta sólo pueden ocurrir dos casos:

1. Que $W=0$ y en este caso la solución trivial
2. Que $[\text{Cov}_{(X_1, Y_1)}] - \lambda I$ sea singular (no invertible), esto es que:

$$|[\text{Cov}_{(X_1, Y_1)}] - \lambda I| = 0 \quad (16)$$

La ecuación (16) es la *ecuación característica* de la matriz y su expresión es una ecuación polinómica de λ . Las soluciones a esta ecuación (los valores de λ) se conocen como los *autovalores o valores propios (eigenvalue)* de $[\text{Cov}_{(X_1, Y_1)}]$. Cuando se sustituyen en (15), se calculan los vectores asociados a cada valor de λ , que se conocen como los *autovectores o vectores propios (eigenvectors)* de $[\text{Cov}_{(X_1, Y_1)}]$. Con otras palabras, cada autovalor λ_i , es solución a una ecuación del sistema $([\text{Cov}_{(X_1, Y_1)}] - \lambda I) W = 0$. Así, para cada ecuación, los parámetros de W asociados a la solución con λ_i es un autovector ϕ_i . Entonces podemos denotar la matriz W como un vector de transformación con d columnas (en donde W será entonces el vector de autovectores):

$$W = [\phi_1, \phi_2, \dots, \phi_d] \quad (17)$$

Como $[\text{Cov}_{(X_1, Y_1)}]$ es de orden $d \times d$, tendrá d autovalores asociados, $\lambda_1, \lambda_2, \dots, \lambda_d$ y como $[\text{Cov}_{(X_1, Y_1)}]$ es simétrica, todos los autovalores serán reales.

Como $[\text{Cov}_{(X_1, Y_1)}]$ es simétrica, todos sus autovalores serán reales. Por otra parte, dado que $[\text{Cov}_{(X_1, Y_1)}]$ es definida positiva, sus autovalores están ordenados:

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_d \quad (18)$$

La matriz de covarianza $[\text{Cov}_{(X_2, Y_2)}] = W^T [\text{Cov}_{(X_1, Y_1)}] W$ será una matriz *diagonal* formada por los autovalores de $[\text{Cov}_{(X_1, Y_1)}]$:

$$[\text{Cov}_{(X_2, Y_2)}] = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_d \end{bmatrix} \quad (19)$$

y los valores de la diagonal (autovalores *de* $[\text{Cov}_{(X_1, Y_1)}]$) son las varianzas de los patrones en las respectivas coordenadas transformadas. La matriz que contiene los coeficientes de la transformación, W , es la matriz de autovectores *de* $[\text{Cov}_{(X_1, Y_1)}]$, asumiendo que W es ortogonal.

Cada autovalor λ_i viene con su propio autovector ϕ_i y cada autovector establece la dirección de un eje en el espacio transformado P^* . Los autovalores están ordenados según el valor de varianza en cada eje de P^* y cada autovalor tiene un autovector asociado. Por lo tanto, podemos organizar las variables transformadas en un orden en el cual el primer componente principal nos mostrará la dirección de máxima varianza de los patrones en P , que está determinada por este eje.

7. RESULTADOS

7.1. Resultados del modelo CRHUDA

Se analizaron los datos de lámina de precipitación, humedad, punto de rocío y presión atmosférica a 10 tormentas correspondientes al mes de septiembre pertenecientes a la estación 7 ubicada en Milenio entre los años 2013 y 2021 ver (Tablas 3 a 12). Los datos completos de las tormentas se muestran en el Apéndice B. Se utilizaron datos tomados cada minuto para formar las series Z_{t-k}^1 y Z_{t-k}^2 donde:

$$CRHUDA (Z_{t-k}^1 \subseteq Z_{t-k}^2) \rightarrow (Z_{t-k}^1 \cap Z_{t-k}^2) \begin{cases} Z_{t-k}^1 = \text{humedad} \\ Z_{t-k}^2 = \frac{\text{presión atmosférica}}{\text{punto de rocío}} \end{cases}$$

Tabla 3. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 1.

Tormenta 1					
Tiempo	Presión	Lluvia	Humedad	Punto de rocío	Presión/Punto de rocío
16:53:00	1005.4	0.3	79	15.6	64.45
16:54:00	1005.5	0.5	81	16.1	62.45
...
17:09:00	1005.6	0.299999	87	15.6	64.46
17:10:00	1005.6	0.200001	87	15	67.04

Tabla 4. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 2.

Tormenta 2					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
15:21:00	79	0.5	1004.9	16.7	60.17
15:22:00	80	0.5	1005	16.1	62.42
...
15:31:00	86	0.799999	1004.9	15.6	64.42

15:32:00	86	0.3	1004.8	15.6	64.41
----------	----	-----	--------	------	-------

Tabla 5. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 3.

Tormenta 3					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:42:00	77	1	1001.7	16.7	59.98
19:43:00	78	0.8	1001.6	16.7	59.98
...
20:17:00	88	0.200001	1002.3	15	66.82
20:18:00	89	0.299999	1002.2	15	66.81

Tabla 6. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 4.

Tormenta 4					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:54:00	45	0.7	1006.5	16.1	62.52
19:55:00	45	0.5	1006.5	16.7	60.27
...
20:03:00	46	0.3	1006.6	16.1	62.52
20:04:00	46	0	1006.6	16.7	60.28

Tabla 7. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 5.

Tormenta 5					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
15:41:00	80	0.3	1006.3	14.4	69.88
15:43:00	80	0.8	1006.3	13.9	72.40
...

15:52:00	84	0.5	1005.9	13.9	72.37
15:53:00	82	0.3	1006	13.9	72.37

Tabla 8. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 6.

Tormenta 6					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:22:00	87	0.300003	1004.4	15.6	64.38
22:23:00	88	0.199997	1004.3	15.6	64.38
...
23:58:00	92	0.5	1005.9	13.9	72.37
23:59:00	92	0.299995	1005.9	13.9	72.37

Tabla 9. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 7.

Tormenta 7					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:07:00	81	0.3	1006.9	14.4	69.92
22:06:00	81	0.5	1006.9	14.4	69.92
...
21:58:00	79	0.3	1006.9	15	67.13
21:57:00	80	0.5	1006.9	15.6	64.54

Tabla 10. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 8.

Tormenta 8					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
21:46:00	91	0.254	1008.6	13.9	72.56
21:45:00	91	0	1008.5	13.9	72.55

...
20:55:00	80	0.508	1007.5	14.4	69.97
20:54:00	80	0.254	1007.3	14.4	69.95

Tabla 11. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 9.

Tormenta 9					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:21:00	88	0.254	1004.2	14.4	69.74
19:20:00	88	0	1004.3	14.4	69.74
...
19:00:00	83	1.524	1004.3	15	66.95
18:59:00	85	0.508	1004.3	15.6	64.38

Tabla 12. Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 10.

Tormenta 10					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:42:00	93	0.253998	1011.1	13.9	72.74
22:40:00	93	0	1011.1	13.3	76.02
...
18:06:00	59	0.254	1006.8	13.9	72.43
18:04:00	56	0.254	1006.7	13.3	75.69

Cabe resaltar que se capturaron los datos de 12 horas previas al comienzo de la precipitación de la tormenta para obtener los valores necesarios para sustentar el modelo CRHUDA. Se aplicó la ecuación 4 a los datos de las tormentas que ocurrieron entre 2013 y 2021 registrados en la estación Milenio. Para cada tormenta se graficaron ambas series, la primera corresponde a los valores de humedad registrados por la estación (Z_{t-k}^1), mientras que la segunda es el

cociente de la presión entre el punto de rocío (Z_{t-k}^2), además se agregó la precipitación a la gráfica en cuestión.




Figura 3. Gráfica de las series y precipitación para la tormenta 1.




Figura 4. Gráfica de las series y precipitación para la tormenta 2.




Figura 5. Gráfica de las series y precipitación para la tormenta 3.




Figura 6. Gráfica de las series y precipitación para la tormenta 4.

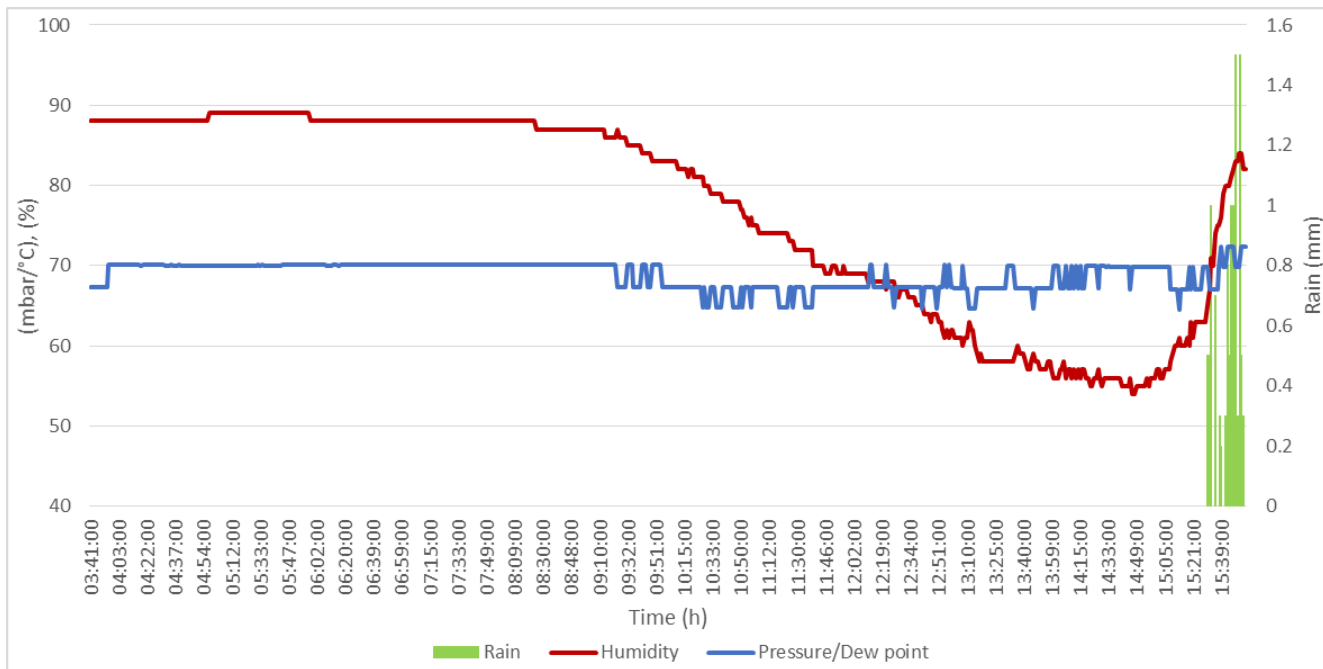


Figura 7. Gráfica de las series y precipitación para la tormenta 5.




Figura 8. Gráfica de las series y precipitación para la tormenta 6.




Figura 9. Gráfica de las series y precipitación para la tormenta 7.




Figura 10. Gráfica de las series y precipitación para la tormenta 8.




Figura 11. Gráfica de las series y precipitación para la tormenta 9.




Figura 12. Gráfica de las series y precipitación para la tormenta 10.

Se propusieron distintos valores del factor de escala β para las diez tormentas hasta que la serie Z_{t-k}^1 y la serie Z_{t-k}^2 se cruzan en el instante preciso para el inicio de la tormenta (Figuras 13 a 22). A continuación, se muestran los valores del factor de escala β para las diez tormentas analizadas.

Tabla 13. Valores de los factores de escala β .

Tormenta	Factor β
1	1.225
2	1.31
3	1.28
4	0.72
5	1.24
6	0.93
7	1.235
8	1.14
9	1.22




Figura 13. Cruce de las series exactamente al inicio de la precipitación para la tormenta 1.




Figura 14. Cruce de las series exactamente al inicio de la precipitación para la tormenta 2.




Figura 15. Cruce de las series exactamente al inicio de la precipitación para la tormenta 3.



Figura 16. Cruce de las series exactamente al inicio de la precipitación para la tormenta 4.




Figura 17. Cruce de las series exactamente al inicio de la precipitación para la tormenta 5.

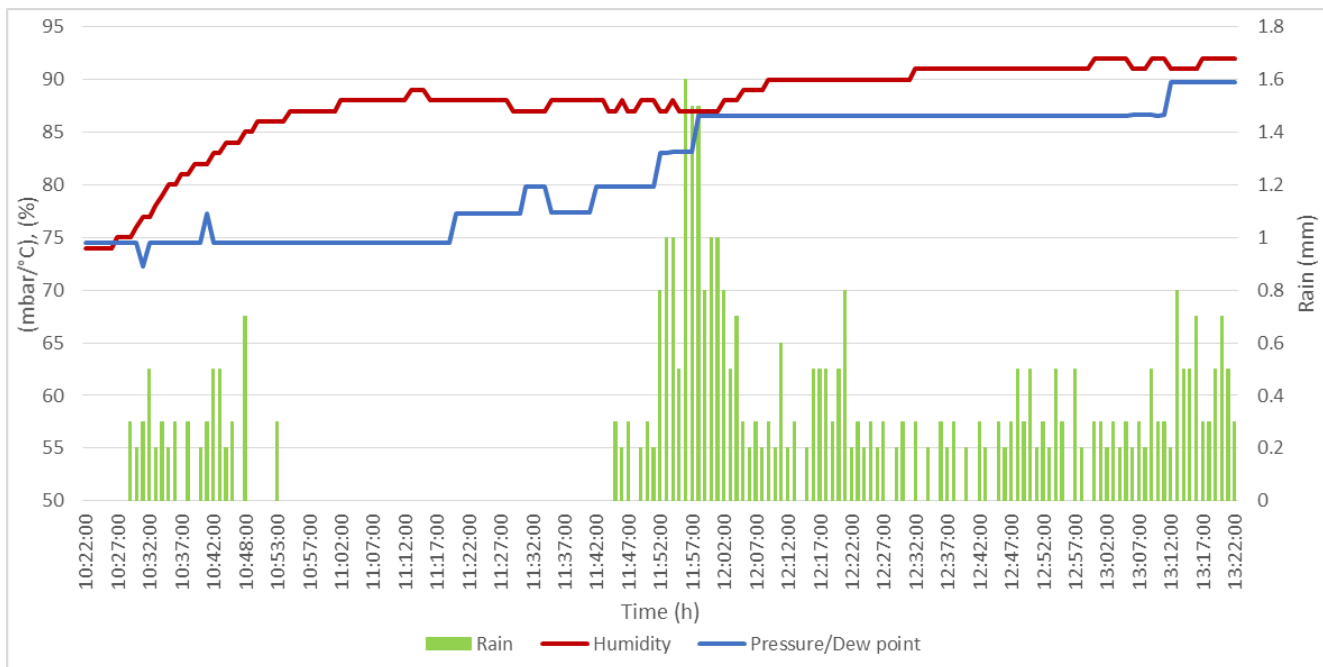


Figura 18. Cruce de las series exactamente al inicio de la precipitación para la tormenta 6.




Figura 19. Cruce de las series exactamente al inicio de la precipitación para la tormenta 7.




Figura 20. Cruce de las series exactamente al inicio de la precipitación para la tormenta 8.

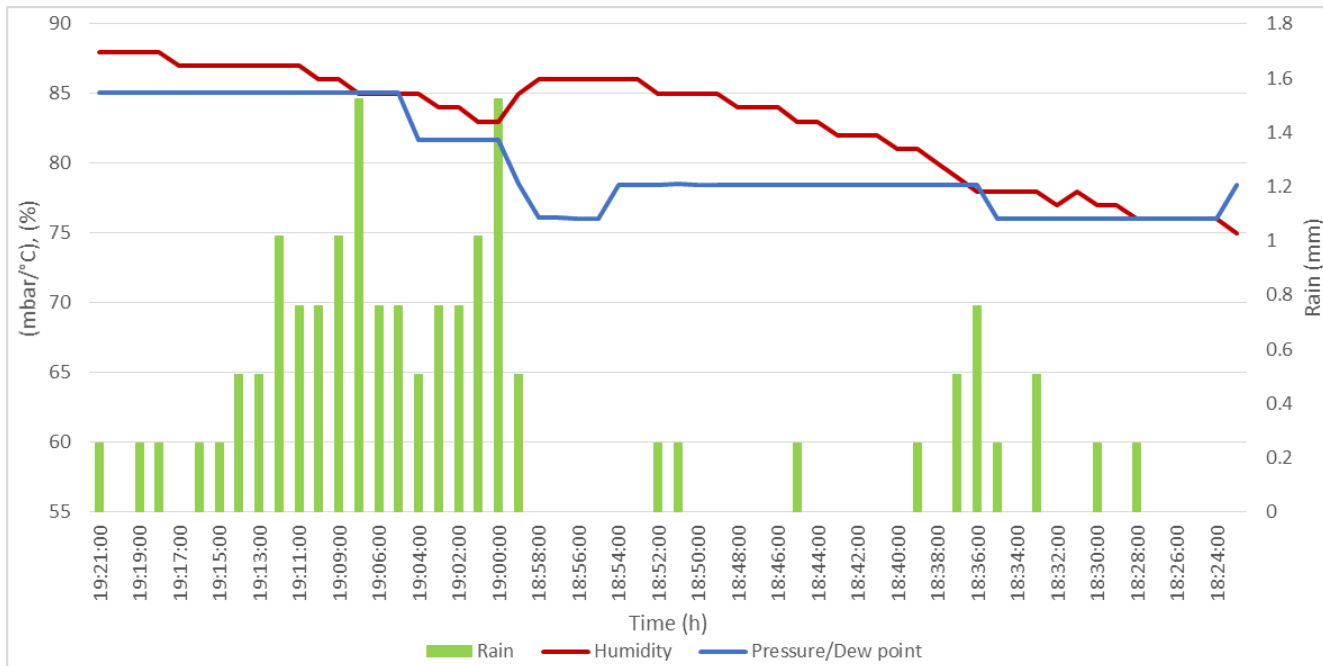


Figura 21. Cruce de las series exactamente al inicio de la precipitación para la tormenta 9.




Figura 22. Cruce de las series exactamente al inicio de la precipitación para la tormenta 10.

Dado que en las 10 tormentas la precipitación se presentaba inmediatamente ocurría el cruce de las series, se optó por calcular un factor de escala β promedio para las 10 tormentas y con este valor realizar nuevamente las gráficas y observar su comportamiento, dicho valor promedio obtenido resultó ser $\beta = 1.1$, por lo que las nuevas gráficas presentaron el siguiente comportamiento.




Figura 23. Cruces de las series en la tormenta 1 con un factor $\beta = 1.1$.

A las 16:37 se percibe el primer cruce, el valor de la humedad comienza a descender, tres minutos después se produce el segundo cruce, pero ahora en sentido contrario y a los 13 minutos comienza la precipitación.




Figura 24. Cruces de las series en la tormenta 2 con un factor $\beta = 1.1$.




Figura 25. Cruces de las series en la tormenta 3 con un factor $\beta = 1.1$.




Figura 26. Cruces de las series en la tormenta 4 con un factor $\beta = 1.1$.




Figura 27. Cruces de las series en la tormenta 5 con un factor $\beta = 1.1$.




Figura 28. Cruces de las series en la tormenta 6 con un factor $\beta = 1.1$.




Figura 29. Cruces de las series en la tormenta 7 con un factor $\beta = 1.1$.




Figura 30. Cruces de las series en la tormenta 8 con un factor $\beta = 1.1$.




Figura 31. Cruces de las series en la tormenta 9 con un factor $\beta = 1.1$.




Figura 32. Cruces de las series en la tormenta 10 con un factor $\beta = 1.1$.

Se puede observar un desfase entre el cruce y el comienzo de la precipitación, así como una serie de cruces previos al comienzo de la lluvia, con las gráficas obtenidas resulta posible obtener los valores necesarios para validar el modelo CHRUDA. Observando las figuras del 23 al 32, se puede notar que la representación gráfica obtenida se corresponde con el modelo CHRUDA planteado en la figura 4. La tabla 14 muestra los valores obtenidos de las gráficas resultantes del análisis de sensibilidad y del factor de escala para el modelo CRHUDA aplicado a las 10 tormentas extremas seleccionadas en el mes de septiembre en la estación Milenio.


Tabla 14. Resultados del análisis de sensibilidad y valores del factor de escala modelo CRHUDA tormentas extremas ocurridas en septiembre en la estación Milenio.

Tormenta	β	β prom.	t_2	Inicio lluvia	ΔT	t_1	T_k
1	1.225	1.11	16:40:00	16:53:00	0:13:00	16:37:00	0:03:00
2	1.31	1.11	15:15:00	15:21:00	0:06:00	14:51:00	0:24:00
3	1.28	1.11	13:54:46	14:39:00	0:44:14	13:54:16	0:00:30
4	0.72	1.11	0:00:00	0:00:00	0:00:00	0:00:00	0:00:00
5	1.24	1.11	15:37:00	15:32:00	0:05:00	15:36:00	0:01:00
6	0.93	1.11	19:26:00	21:06:00	1:40:00	19:12:00	0:14:00
7	1.235	1.11	21:18:00	21:57:00	0:39:00	21:16:00	0:02:00
8	1.14	1.11	20:52:00	20:54:00	0:02:00	11:41:00	9:11:00
9	1.22	1.11	18:10:00	18:28:00	0:18:00	18:08:00	0:02:00
10	0.77	1.11	18:17:00	18:04:00	0:13:00	10:27:00	7:50:00

7.2. Resultados del análisis multivariado

Respecto al análisis multivariado, éste no se ha efectuado en ningún otro trabajo de forma científica. Considerando que un ACP muestra las variables más representativas y nos indica además la jerarquía y su correlación. Las figuras 33 y 34 muestran la correlación que existe entre las variables del modelo CRHUDA. Es interesante observar cómo se comprueba la hipótesis planteada en este trabajo:

El cruce de dos series de tiempo, humedad y presión atmosférica/punto de rocío, representadas gráficamente; identifica el punto de inicio de la precipitación.



En el círculo de correlación de la figura 33 se observa una significancia del 73.3% entre las variables climáticas: Humedad, T2 (que indica el segundo cruce) y la hora de inicio de la precipitación. Por otro lado, la Presión Atmosférica esta correlacionada con Tk que es el tiempo entre los dos cruces que se producen. Por otro lado, se observa una correlación entre t1 que corresponde al momento de primer cruce y el Dt que identifica el tiempo entre el segundo cruce y el inicio de la precipitación. Finalmente, en este círculo de correlación se puede observar una relación muy importante entre el Punto de Rocío, la lámina de precipitación y el factor de escala β . Lo cual le da sentido al ajuste que se ha propuesto en este trabajo. Un análisis similar para los ejes 2-3 con significancia del 41% demuestra relaciones interesantes entre la Presión Atmosférica y el Punto de Rocío. Una vez más se comprueba la relación entre la lámina de precipitación y el factor de escala β y las variables correlacionadas que merecerían un análisis posterior, el tiempo de inicio de la precipitación con los tiempos t1 y t2, y con la humedad.




Figura 33. Círculo de correlación ACP para las variables del modelo CRHUDA (Representación de 73.3% en los ejes 1-2).




Figura 34. Círculo de correlación ACP para las variables del modelo CRHUDA (Representación de 41% en los ejes 2-3).

8. CONCLUSIONES

Una vez aceptada la parte sinóptica de la validación, aceptar el modelo de pronóstico estocástico es fundamental. Comprobado que existe un factor de escala, puede presentarse un análisis de sensibilidad como el que se muestra en las figuras 35 y 36. La figura 35 muestra cuatro zonas de cruce para dos tormentas registradas en la estación Milenio, el 24 y 25 de junio 2013. Considerando un factor de escala igual a uno, el pronóstico y la alerta se realizan normalmente. Sin embargo, cuando se modifica el factor de escala (solamente para fines de discusión); los cruces no suceden y por lo tanto no puede detonarse la alerta (figura 36). Es evidente que el factor de escala es de gran importancia cuando el modelo CRHUDA está vinculado a un sistema de alerta a tiempo real. Es necesario entonces, el cálculo y la calibración previa del factor de escala en función de los coeficientes de autocorrelación según la ecuación (8). Esto ya fue presentado por Muñoz-Mandujano et al., (2024) en forma analítica y ahora en este trabajo se prueba manualmente a partir de la base el análisis multivarado.




Figura 35. Modelo CRHUDA para la tormenta 24-25 de junio de 2013 estación Milenio ($\beta = 1$).




Figura 36. Modelo CRHUDA para la tormenta 24-25 de junio de 2013 estación Milenio ($\beta = 0.5$).

Es posible, según los resultados de esta investigación, combinar las variables climáticas: la presión atmosférica, el punto de rocío y la humedad; para el pronóstico del inicio de la precipitación. Estas variables se representan en dos series de tiempo que pueden ser trazadas para determinar, sinópticamente, el tiempo (instante) de cruce entre ambas series. Este instante de cruce marca el inicio de la alerta para en el siguiente cruce, considerar que se inicia la precipitación. De los resultados obtenidos se concluye que el tiempo de alerta desde el primer cruce hasta el inicio de la precipitación en el segundo cruce, en promedio, es de nueve a diez horas. Se comprobó que los instantes de cruce de ambas series son función de los coeficientes de autocorrelación del modelo completo. Se comprobó también que existe un factor de escala que permite ganar en la precisión del pronóstico en los tiempos de cruce. Dicho factor de escala se calcula empleando los coeficientes de autocorrelación. La aplicación sistemática del modelo CRHUDA con su respectivo factor de escala ajustado a los datos históricos de cada estación, es una herramienta adecuada para ser vinculada a un sistema de alerta de precipitaciones a tiempo real. Tiene que seguir el estudio del modelo CRHUDA como un algoritmo muy útil para los sistemas de alerta.

8.1 Comentarios finales

La RedCIAQ fue originalmente diseñada como un recurso para la investigación científica, ya que en la actualidad se están llevando a cabo diversas tesis de licenciatura, maestría y doctorado en la Facultad de Ingeniería que abordan temas relacionados con la hidrología e hidrometeorología. No obstante, al publicar la información en tiempo real en un sitio web, junto con las herramientas hidro-informáticas creadas por el Centro de Desarrollo de la Facultad de Informática; la RedCIAQ ha sido consultada y bien recibida tanto por los habitantes de Querétaro como por la comunidad científica. La UAQ está consciente de la importancia y necesidad evidente del monitoreo hidrometeorológico, por lo tanto, quiere fomentar la cultura de la medición, monitoreo y predicción de las variables hidrometeorológicas en el ámbito metropolitano y estatal, como un factor determinante de la calidad de vida y el bienestar social. Por consiguiente, se hace un llamado a organismos, gobiernos locales, organizaciones no gubernamentales y a toda la comunidad en general para unirse a este proyecto. El uso del modelo CRHUDA beneficiará a las autoridades y a la población en general durante la temporada de lluvias, especialmente.

9. REFERENCIAS

- Berg, P.; Haerter, J. Unexpected increase in precipitation intensity with temperature—A result of mixing of precipitation types? *Atmos. Res.* 2013, 119, 56–61. doi:10.1016/j.atmosres.2011.05.012.
- Carrera-Hernández, J., Gaskin, S. Spatio temporal analysis of daily precipitation and temperature in the Basin of Mexico. *J. Hydrol. (Amst.)* 2007, 336, 231–249. doi:10.1016/j.jhydrol.2006.12.021.
- Carter, M.; Elsner, J.; Bennett, S. A quantitative precipitation forecast experiment for Puerto Rico. *J. Hydrol. (Amst.)* 2000, 239, 162–178. doi:10.1016/s0022-1694(00)00349-8.
- CENAPRED. Disasters in Mexico: Social and Economic Impacts (1980–2014); Centro Nacional de Prevencion de Desastres: Mexico, 2016.
- Chang, W., Stein, M. L., Wang, J., Kotamarthi, V. R., & Moyer, E. J. (2016). Changes in spatiotemporal precipitation patterns in changing climate conditions. *Journal of Climate*, 29(23), 8355–8376.
- Dahm, R., Bhardwaj, A., Sperna Weiland, F., Corzo, G., & Bouwer, L. M. (2019). A temperature-scaling approach for projecting changes in short duration rainfall extremes from GCM data. *Water*, 11(2), 313.
- Damrath, U.; Doms, G.; Frühwald, D.; Heise, E.; Richter, B.; Steppeler, J. Operational quantitative precipitation forecasting at the German Weather Service. *J. Hydrol. (Amst.)* 2000, 239, 260–285. doi:10.1016/s0022-1694(00)00353-x.
- Dyson, L.; van Heerden, J.; Sumner, P. A baseline climatology of sounding-derived parameters associated with heavy rainfall over Gauteng, South Africa. *Int. J. Climatol.* 2014, 35, 114–127. doi:10.1002/joc.3967.
- Gao, X., Li, J., & Sorooshian, S. (2007). Modeling intraseasonal features of 2004 North American monsoon precipitation. *Journal of Climate*, 20(9), 1882–1896.
- Gutierrez-Lopez, A., Cruz-Paz, I., & Muñoz Mandujano, M. (2019). Algorithm to Predict the Rainfall Starting Point as a Function of Atmospheric Pressure, Humidity, and Dewpoint. *Climate*, 7(11), 131. <https://doi.org/10.3390/cli7110131>
- Gutierrez-Lopez, A.; Fortanell Trejo, M.; Albuquerque Gonzalez, N.; Bravo Prado, F. (2019) Análisis de la variabilidad espacial en la precipitación en la zona metropolitana de Querétaro empleando ecuaciones de anisotropía. *Investigaciones Geográficas*; doi:10.14350/ig.59757.
- Harder, P., & Pomeroy, J. (2013). Estimating precipitation phase using a psychrometric energy balance method. *Hydrological Processes*, 27(13), 1901–1914.
- Holley, D. M., Dorling, S. R., Steele, C. J., & Earl, N. (2014). A climatology of convective available potential energy in Great Britain. *International Journal of Climatology*, 34(14), 3811–3824.

- Holley, D.; Dorling, S.; Steele, C.; Earl, N. A climatology of convective available potential energy in Great Britain. *Int. J. Climatol.* 2014, 34, 3811–3824. doi:10.1002/joc.3976.
- Lekouch, I.; Lekouch, K.; Muselli, M.; Mongruel, A.; Kabbachi, B.; Beysens, D. Rooftop dew, fog and rain collection in southwest Morocco and predictive dew modeling using neural networks. *J. Hydrol. (Amst.)* 2012, 448, 60–72. doi:10.1016/j.jhydrol.2012.04.004.
- Lenderink, G., Barbero, R., Loriaux, J. M., & Fowler, H. J. (2017). Super-Clausius--Clapeyron scaling of extreme hourly convective precipitation and its relation to large-scale atmospheric conditions. *Journal of Climate*, 30(15), 6037–6052.
- Lepore, C.; Allen, J.; Tippett, M. Relationships between Hourly Rainfall Intensity and Atmospheric Variables over the Contiguous United States. *J. Clim.* 2016, 29, 3181–3197. doi:10.1175/jcli-d-15-0331.1.
- Li, P.; Lai, E. Short-range quantitative precipitation forecasting in Hong Kong. *J. Hydrol. (Amst.)* 2004, 288, 189–209. doi:10.1016/j.jhydrol.2003.11.034.
- Liu, Z., Chen, B., Chan, S. T., Cao, Y., Gao, Y., Zhang, K., & Nichol, J. (2015). Analysis and modelling of water vapour and temperature changes in Hong Kong using a 40-year radiosonde record: 1973--2012. *International Journal of Climatology*, 35(3), 462–474.
- Lorenz, E. Deterministic Nonperiodic Flow. *J. Atmos. Sci.* 1963, 20, 130–141. doi:10.1175/1520-0469(1963)020<0130:dnf>2.0.co;2.
- Millán, H., Ghanbarian-Alavijeh, B., & Garcia-Fornaris, I. (2010). Nonlinear dynamics of mean daily temperature and dewpoint time series at Babolsar, Iran, 1961--2005. *Atmospheric Research*, 98(1), 89–101.
- Mohr, S., & Kunz, M. (2013). Recent trends and variabilities of convective parameters relevant for hail events in Germany and Europe. *Atmospheric Research*, 123, 211–228.
- Moon, S.; Kim, Y.; Lee, Y.; Moon, B. Application of machine learning to an early warning system for very short-term heavy rainfall. *J. Hydrol. (Amst.)* 2019, 568, 1042–1054. doi:10.1016/j.jhydrol.2018.11.060.
- Muñoz-Mandujano, M., Gutierrez-Lopez, A., Acuña-García, J.A., Ibarra-Corona, M.A., Aguilar, I.C., Vargas-Diaz, J.A. (2024). Sensitivity Analysis of Start Point of Extreme Daily Rainfall Using CRHUDA and Stochastic Models. *Stats* (7), 160-171. <https://doi.org/10.3390/stats7010010>
- Myoung, B., & Nielsen-Gammon, J. W. (2010). Sensitivity of monthly convective precipitation to environmental conditions. *Journal of Climate*, 23(1), 166–188.
- Omotosho, J. Equivalent potential temperature and dust haze forecasting at Kano, Nigeria. *Atmos. Res.* 1989, 23, 163–178. doi:10.1016/0169-8095(89)90005-7.

- Park, I.; Min, S. Role of Convective Precipitation in the Relationship between Subdaily Extreme Precipitation and Temperature. *J. Clim.* 2017, 30, 9527–9537. doi:10.1175/jcli-d-17-0075.1.
- Park, I.-H., & Min, S.-K. (2017). Role of convective precipitation in the relationship between subdaily extreme precipitation and temperature. *Journal of Climate*, 30(23), 9527–9537.
- Puvaneswaran, M. Climatic classification for queensland using multivariate statistical techniques. *Int. J. Climatol.* 1990, 10, 591–608. doi:10.1002/joc.3370100604.
- Rasouli, K.; Hsieh, W.; Cannon, A. Daily streamflow forecasting by machine learning methods with weather and climate inputs. *J. Hydrol. (Amst.)* 2012, 414, 284–293. doi:10.1016/j.jhydrol.2011.10.039.
- Saltzman, B. *Dynamical Paleoclimatology*, 1st ed.; Academic Press: New York, NY, USA, 2002.
- Saltzman, B. On the Maintenance of the Large-Scale Quasi-Permanent Disturbances in the Atmosphere. *Tellus* 1959, 11, 425–431. doi:10.1111/j.2153-3490.1959.tb00052.x.
- Seidel, T. M., Grant, A. N., Pszenny, A. A. P., & Allman, D. J. (2007). Dewpoint and humidity measurements and trends at the summit of Mount Washington, New Hampshire, 1935--2004. *Journal of Climate*, 20(22), 5629–5641.
- Shaw, S. B., Royem, A. A., & Riha, S. J. (2011). The relationship between extreme hourly precipitation and surface temperature in different hydroclimatic regions of the United States. *Journal of Hydrometeorology*, 12(2), 319–325.
- Sim, I., Lee, O., & Kim, S. (2019). Sensitivity analysis of extreme daily rainfall depth in summer season on surface air temperature and dew-point temperature. *Water*, 11(4), 771.
- Valverde Ramírez, M.; de Campos Velho, H.; Ferreira, N. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *J. Hydrol. (Amst.)* 2005, 301, 146–162. doi:10.1016/j.jhydrol.2004.06.028.
- Wang, Y., Tang, L., Zhang, J., Gao, T., Wang, Q., Song, Y., & Hua, D. (2018). Investigation of precipitable water vapor obtained by Raman lidar and comprehensive analyses with meteorological parameters in Xi'an. *Remote Sensing*, 10(6), 967.
- Zahraei, A.; Hsu, K.; Sorooshian, S.; Gourley, J.; Hong, Y.; Behrangi, A. Short-term quantitative precipitation forecasting using an object-based approach. *J. Hydrol. (Amst.)* 2013, 483, 1–15. doi:10.1016/j.jhydrol.2012.09.052.

10. APÉNDICES

Apéndice A

RedCIAQ Estaciones climatológicas.

Id	Nombre	Long	Lat	Id	Nombre	Long	Lat
1	Chulavista	-100.47	20.63	18	Ezequiel Montes	-99.90	20.67
2	Belén	-100.41	20.65	19	Huimilpan	-100.27	20.37
3	Real del Parque	-100.40	20.61	20	Landa de Matamoros	-99.32	21.18
4	Candiles	-100.40	20.55	21	Pedro Escobedo	-100.14	20.50
5	Cimatario	-100.38	20.56	22	San Joaquín	-100.01	20.38
6	Centro histórico	-100.39	20.59	23	San Juan del Río	-99.97	20.39
7	Milenio III	-100.35	20.59	24	Tequisquiapan	-99.91	20.61
8	San gil	-100.44	20.70	25	Tolimán	-99.93	20.90
9	El refugio	-100.35	20.65	26	Viñedos	-100.49	20.61
10	COTAS Amazcala	-100.34	20.71	27	El esparrago	-100.01	20.38
11	Cerro de las Campanas	-100.41	20.59	28	Santa Rosa Jáuregui	-100.45	20.74
12	Amealco de Bonfil	-100.14	20.19	29	Unión de Ejidos	-100.23	20.65
13	Pinal de Amoles	-99.63	21.14	30	Joaquín Herrera	-99.57	20.92
14	Arroyo seco	-99.69	21.55	31	Juriquilla	-100.45	20.72
15	Cadereyta de Montes	-99.81	20.70	32	UAQ Aeropuerto	-100.37	20.62
16	Colón	-100.05	20.78	33	Pasteur y 57	-100.38	20.58
17	Corregidora	-100.43	20.55	34	CICATA QRO IPN	-100.37	20.57

Apéndice B

Datos completos de tormentas analizadas

Tabla B.1 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 1.

Tormenta 1					
Tiempo	Presión	Lluvia	Humedad	Punto de rocío	Presión/Punto de rocío
16:53:00	1005.4	0.3	79	15.6	64.45
16:54:00	1005.5	0.5	81	16.1	62.45
16:55:00	1005.5	0.7	81	15.6	64.46
16:56:00	1005.5	1	81	15.6	64.46
16:57:00	1005.5	0.6	81	15.6	64.46
16:59:00	1005.5	1.2	83	15.6	64.46
17:00:00	1005.4	0.3	83	15.6	64.45
17:01:00	1005.4	0.5	84	15.6	64.45
17:02:00	1005.4	0.2	84	15.6	64.45
17:03:00	1005.4	0.3	84	15.6	64.45
17:04:00	1005.5	0.5	84	15	67.03
17:05:00	1005.5	0.5	85	15.6	64.46
17:06:00	1005.5	0.3	86	15.6	64.46
17:07:00	1005.5	0.5	86	15.6	64.46
17:08:00	1005.5	0.2	86	15	67.03
17:09:00	1005.6	0.299999	87	15.6	64.46
17:10:00	1005.6	0.200001	87	15	67.04

Tabla B.2 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 2.

Tormenta 2					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
15:21:00	79	0.5	1004.9	16.7	60.17
15:22:00	80	0.5	1005	16.1	62.42

15:23:00	80	0.8	1005.1	16.1	62.43
15:24:00	80	1.3	1005.1	15.6	64.43
15:25:00	82	1	1005	15.6	64.42
15:26:00	83	1.5	1005.1	15.6	64.43
15:27:00	84	1	1005	15.6	64.42
15:28:00	83	0.5	1005	15	67.00
15:29:00	85	0.299999	1005	15.6	64.42
15:30:00	85	0.200001	1005	15.6	64.42
15:31:00	86	0.799999	1004.9	15.6	64.42
15:32:00	86	0.3	1004.8	15.6	64.41

Tabla B.3 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 3.

Tormenta 3					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:42:00	77	1	1001.7	16.7	59.98
19:43:00	78	0.8	1001.6	16.7	59.98
19:44:00	75	0.7	1001.7	16.1	62.22
19:45:00	76	0.8	1001.8	15.6	64.22
19:46:00	79	0.5	1001.9	16.1	62.23
19:47:00	80	0.8	1001.9	16.1	62.23
19:48:00	81	0.5	1001.9	16.1	62.23
19:49:00	82	0.5	1001.9	16.1	62.23
19:50:00	82	0.5	1002	15.6	64.23
19:51:00	83	1.5	1001.9	15.6	64.22
19:52:00	85	1.3	1002	16.1	62.24
19:53:00	85	1.8	1002	16.1	62.24
19:54:00	86	1.5	1002.1	16.1	62.24
19:55:00	86	1	1002	16.1	62.24
19:56:00	87	1.5	1002.1	16.1	62.24
19:57:00	87	1	1002.2	16.1	62.25
19:58:00	88	0.799999	1002.2	16.1	62.25
19:59:00	88	1.3	1002.4	16.1	62.26
20:00:00	88	1.8	1002.5	16.1	62.27

20:01:00	89	2.2	1002.4	16.1	62.26
20:02:00	89	2.3	1002.6	16.1	62.27
20:03:00	88	2.3	1002.6	16.1	62.27
20:04:00	88	1.8	1002.7	16.1	62.28
20:05:00	88	1.8	1002.8	15.6	64.28
20:06:00	88	2.8	1002.8	15.6	64.28
20:07:00	88	2	1002.8	15.6	64.28
20:08:00	88	2.8	1002.8	15.6	64.28
20:09:00	88	1.5	1002.8	15.6	64.28
20:10:00	87	2.8	1002.6	15	66.84
20:11:00	87	2	1002.4	15	66.83
20:12:00	87	1.3	1002.2	15	66.81
20:13:00	87	1.8	1002.3	15	66.82
20:14:00	87	0.700001	1002.3	15	66.82
20:15:00	88	0.799999	1002.4	15	66.83
20:16:00	87	1.3	1002.3	15	66.82
20:17:00	88	0.200001	1002.3	15	66.82
20:18:00	89	0.299999	1002.2	15	66.81

Tabla B.4 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 4.

Tormenta 4					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:54:00	45	0.7	1006.5	16.1	62.52
19:55:00	45	0.5	1006.5	16.7	60.27
19:56:00	45	0.8	1006.5	16.1	62.52
19:57:00	45	0.5	1006.5	16.1	62.52
19:58:00	45	0.5	1006.6	16.1	62.52
19:59:00	46	0.5	1006.6	16.1	62.52
20:00:00	46	0.3	1006.6	16.1	62.52
20:01:00	46	0.5	1006.6	16.1	62.52
20:02:00	46	0.7	1006.7	16.1	62.53
20:03:00	46	0.3	1006.6	16.1	62.52
20:04:00	46	0	1006.6	16.7	60.28

Tabla B.5 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 5.

Tormenta 5					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
15:41:00	80	0.3	1006.3	14.4	69.88
15:43:00	80	0.8	1006.3	13.9	72.40
15:44:00	80	0.5	1006.3	13.9	72.40
15:45:00	81	1	1006.3	13.9	72.40
15:46:00	82	1	1006.2	13.9	72.39
15:48:00	83	1.5	1006.1	14.4	69.87
15:49:00	83	0.299999	1006.1	14.4	69.87
15:51:00	84	1.5	1006	14.4	69.86
15:52:00	84	0.5	1005.9	13.9	72.37
15:53:00	82	0.3	1006	13.9	72.37

Tabla B.6 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 6.

Tormenta 6					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:22:00	87	0.300003	1004.4	15.6	64.38
22:23:00	88	0.199997	1004.3	15.6	64.38
22:24:00	87	0.300003	1004.3	15.6	64.38
22:25:00	87	0	1004.4	15.6	64.38
22:26:00	88	0.199997	1004.4	15.6	64.38
22:27:00	88	0.300003	1004.5	15.6	64.39
22:28:00	88	0.199997	1004.6	15.6	64.40
22:29:00	87	0.800003	1004.7	15	66.98
22:30:00	87	1	1004.9	15	66.99
22:31:00	88	1	1005	15	67.00
22:32:00	87	0.5	1005	15	67.00
22:33:00	87	1.6	1005	15	67.00
22:34:00	87	1.5	1005	15	67.00

22:35:00	87	1.5	1005.1	14.4	69.80
22:36:00	87	0.800003	1005.1	14.4	69.80
22:37:00	87	1	1005	14.4	69.79
22:38:00	87	1	1004.9	14.4	69.78
22:39:00	88	0.799995	1004.9	14.4	69.78
22:40:00	88	0.5	1005	14.4	69.79
22:41:00	88	0.700005	1005	14.4	69.79
22:42:00	89	0.299995	1005	14.4	69.79
22:43:00	89	0.200005	1004.9	14.4	69.78
22:44:00	89	0.299995	1004.9	14.4	69.78
22:45:00	89	0.200005	1004.8	14.4	69.78
22:46:00	90	0.299995	1004.8	14.4	69.78
22:47:00	90	0.200005	1004.8	14.4	69.78
22:48:00	90	0.599998	1004.9	14.4	69.78
22:49:00	90	0.199997	1004.9	14.4	69.78
22:50:00	90	0.300003	1005	14.4	69.79
22:51:00	90	0	1005.1	14.4	69.80
22:52:00	90	0.199997	1005.1	14.4	69.80
22:53:00	90	0.5	1005.1	14.4	69.80
22:54:00	90	0.5	1005.1	14.4	69.80
22:55:00	90	0.5	1005.1	14.4	69.80
22:56:00	90	0.300003	1005.1	14.4	69.80
22:57:00	90	0.5	1005.1	14.4	69.80
22:58:00	90	0.799995	1005.2	14.4	69.81
22:59:00	90	0.200005	1005.2	14.4	69.81
23:00:00	90	0.299995	1005.1	14.4	69.80
23:01:00	90	0.200005	1005.2	14.4	69.81
23:02:00	90	0.299995	1005.1	14.4	69.80
23:03:00	90	0.200005	1005.2	14.4	69.81
23:04:00	90	0.299995	1005.1	14.4	69.80
23:05:00	90	0	1005.1	14.4	69.80
23:06:00	90	0.200005	1005.1	14.4	69.80
23:07:00	90	0.299995	1005.1	14.4	69.80
23:08:00	90	0	1005.1	14.4	69.80
23:09:00	91	0.300003	1005	14.4	69.79

23:10:00	91	0	1005	14.4	69.79
23:11:00	91	0.199997	1005	14.4	69.79
23:12:00	91	0	1005	14.4	69.79
23:13:00	91	0.300003	1005.1	14.4	69.80
23:14:00	91	0.199997	1005.2	14.4	69.81
23:15:00	91	0.300003	1005.2	14.4	69.81
23:16:00	91	0	1005.3	14.4	69.81
23:17:00	91	0.199997	1005.4	14.4	69.82
23:18:00	91	0	1005.5	14.4	69.83
23:19:00	91	0.300003	1005.4	14.4	69.82
23:20:00	91	0.199997	1005.5	14.4	69.83
23:21:00	91	0	1005.5	14.4	69.83
23:22:00	91	0.300003	1005.4	14.4	69.82
23:23:00	91	0.199997	1005.4	14.4	69.82
23:24:00	91	0.300003	1005.5	14.4	69.83
23:25:00	91	0.5	1005.5	14.4	69.83
23:26:00	91	0.300003	1005.5	14.4	69.83
23:27:00	91	0.5	1005.5	14.4	69.83
23:28:00	91	0.199997	1005.6	14.4	69.83
23:29:00	91	0.300003	1005.6	14.4	69.83
23:30:00	91	0.199997	1005.6	14.4	69.83
23:31:00	91	0.5	1005.6	14.4	69.83
23:32:00	91	0.300003	1005.6	14.4	69.83
23:32:00	91	0	1005.6	14.4	69.83
23:34:00	91	0.5	1005.5	14.4	69.83
23:35:00	91	0.199997	1005.4	14.4	69.82
23:36:00	91	0	1005.4	14.4	69.82
23:37:00	92	0.300003	1005.4	14.4	69.82
23:38:00	92	0.299995	1005.4	14.4	69.82
23:39:00	92	0.200005	1005.4	14.4	69.82
23:40:00	92	0.299995	1005.5	14.4	69.83
23:41:00	92	0.200005	1005.6	14.4	69.83
23:42:00	92	0.299995	1005.6	14.4	69.83
23:43:00	91	0.200005	1005.7	14.4	69.84
23:44:00	91	0.299995	1005.7	14.4	69.84

23:45:00	91	0.200005	1005.7	14.4	69.84
23:46:00	92	0.5	1005.7	14.4	69.84
23:47:00	92	0.299995	1005.6	14.4	69.83
23:48:00	92	0.300003	1005.7	14.4	69.84
23:49:00	91	0.199997	1005.7	13.9	72.35
23:50:00	91	0.800003	1005.7	13.9	72.35
23:51:00	91	0.5	1005.7	13.9	72.35
23:52:00	91	0.5	1005.6	13.9	72.35
23:53:00	91	0.699997	1005.6	13.9	72.35
23:54:00	92	0.300003	1005.6	13.9	72.35
23:55:00	92	0.299995	1005.7	13.9	72.35
23:56:00	92	0.5	1005.8	13.9	72.36
23:57:00	92	0.700005	1005.9	13.9	72.37
23:58:00	92	0.5	1005.9	13.9	72.37
23:59:00	92	0.299995	1005.9	13.9	72.37

Tabla B.7 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 7.

Tormenta 7					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:07:00	81	0.3	1006.9	14.4	69.92
22:06:00	81	0.5	1006.9	14.4	69.92
22:05:00	81	0.5	1006.9	14.4	69.92
22:04:00	81	0.5	1006.9	15	67.13
22:03:00	81	0.3	1006.9	15	67.13
22:02:00	79	0.2	1006.9	14.4	69.92
22:01:00	79	0.5	1006.9	14.4	69.92
22:00:00	79	0.5	1006.9	15	67.13
21:59:00	79	0.3	1006.9	15	67.13
21:58:00	79	0.3	1006.9	15	67.13
21:57:00	80	0.5	1006.9	15.6	64.54

Tabla B.8 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 8.

Tormenta 8					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
21:46:00	91	0.254	1008.6	13.9	72.56
21:45:00	91	0	1008.5	13.9	72.55
21:44:00	91	0	1008.5	13.9	72.55
21:43:00	91	0.254	1008.4	13.9	72.55
21:42:00	90	0.254	1008.4	13.9	72.55
21:41:00	90	0	1008.3	13.9	72.54
21:40:00	90	0.254	1008.3	13.9	72.54
21:39:00	90	0.254001	1008.3	13.9	72.54
21:38:00	90	0.254	1008.2	13.9	72.53
21:37:00	90	0.254001	1008.2	13.9	72.53
21:36:00	90	0.254001	1008.2	13.9	72.53
21:35:00	90	0.253999	1008.2	13.9	72.53
21:34:00	90	0	1008.2	13.9	72.53
21:33:00	90	0.254	1008.2	13.9	72.53
21:32:00	90	0	1008.2	13.9	72.53
21:31:00	90	0.254	1008.2	13.9	72.53
21:30:00	90	0	1008.1	13.9	72.53
21:29:00	90	0	1008.1	13.9	72.53
21:28:00	90	0.254	1008.2	13.9	72.53
21:27:00	90	0.254001	1008.1	13.9	72.53
21:26:00	90	9.54E-07	1008.2	13.3	75.80
21:25:00	90	0.254001	1008.2	13.3	75.80
21:24:00	90	0	1008.2	13.3	75.80
21:23:00	90	0.253999	1008.2	13.3	75.80
21:22:00	89	0	1008.1	13.3	75.80
21:21:00	89	0.253999	1008.1	13.3	75.80
21:20:00	89	0.254	1008.1	13.3	75.80
21:19:00	89	0	1008	13.3	75.79
21:18:00	89	0.254	1008	13.3	75.79
21:17:00	89	0.254	1007.9	13.3	75.78
21:16:00	89	0.254	1007.9	13.3	75.78
21:15:00	88	0.254	1007.8	13.3	75.77

21:14:00	88	0.254	1007.7	13.3	75.77
21:13:00	88	0.254	1007.6	13.3	75.76
21:12:00	88	0.762	1007.5	13.3	75.75
21:11:00	87	0.761999	1007.6	13.3	75.76
21:10:00	87	0.254	1007.5	13.3	75.75
21:09:00	86	0.762	1007.5	13.3	75.75
21:08:00	86	0.507999	1007.4	13.3	75.74
21:07:00	85	0.508	1007.2	13.3	75.73
21:06:00	85	1.016	1007.3	13.3	75.74
21:04:00	84	0.762	1007.6	13.9	72.49
21:02:00	83	1.016	1007.7	13.9	72.50
21:01:00	83	0.762	1007.7	14.4	69.98
20:59:00	83	1.016	1007.7	14.4	69.98
20:58:00	82	1.016	1007.6	14.4	69.97
20:57:00	82	0.254	1007.6	14.4	69.97
20:56:00	81	0.254	1007.5	14.4	69.97
20:55:00	80	0.508	1007.5	14.4	69.97
20:54:00	80	0.254	1007.3	14.4	69.95

Tabla B.9 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 9.

Tormenta 9					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
19:21:00	88	0.254	1004.2	14.4	69.74
19:20:00	88	0	1004.3	14.4	69.74
19:19:00	88	0.254	1004.3	14.4	69.74
19:18:00	88	0.254	1004.3	14.4	69.74
19:17:00	87	0	1004.4	14.4	69.75
19:16:00	87	0.254	1004.4	14.4	69.75
19:15:00	87	0.254	1004.4	14.4	69.75
19:14:00	87	0.507999	1004.4	14.4	69.75
19:13:00	87	0.507999	1004.4	14.4	69.75
19:12:00	87	1.016	1004.5	14.4	69.76
19:11:00	87	0.761999	1004.4	14.4	69.75

19:10:00	86	0.762	1004.4	14.4	69.75
19:09:00	86	1.016	1004.3	14.4	69.74
19:07:00	85	1.524	1004.5	14.4	69.76
19:06:00	85	0.762	1004.4	14.4	69.75
19:05:00	85	0.762	1004.5	14.4	69.76
19:04:00	85	0.507999	1004.4	15	66.96
19:03:00	84	0.761999	1004.3	15	66.95
19:02:00	84	0.762	1004.4	15	66.96
19:01:00	83	1.016	1004.3	15	66.95
19:00:00	83	1.524	1004.3	15	66.95
18:59:00	85	0.508	1004.3	15.6	64.38

Tabla B.10 Valores necesarios de acuerdo al modelo CRHUDA correspondientes a la tormenta 10.

Tormenta 10					
Tiempo	Humedad	Lluvia	Presión	Punto de rocío	Presión/Punto de rocío
22:42:00	93	0.253998	1011.1	13.9	72.74
22:40:00	93	0	1011.1	13.3	76.02
22:39:00	93	0	1011.1	13.3	76.02
22:38:00	93	0	1011.1	13.3	76.02
22:37:00	93	0	1011.1	13.3	76.02
22:36:00	92	0	1011.1	13.3	76.02
22:35:00	92	0	1011.2	13.3	76.03
22:34:00	92	0.254002	1011.1	13.3	76.02
22:33:00	92	0	1011.1	13.3	76.02
22:32:00	92	0	1011.1	13.3	76.02
22:31:00	92	0	1011.1	13.3	76.02
22:30:00	92	0	1011.1	13.3	76.02
22:29:00	92	0	1011	13.3	76.02
22:28:00	92	0	1011	13.3	76.02
22:27:00	92	0	1011	13.3	76.02
22:26:00	92	0	1011	13.3	76.02
22:25:00	92	0.253998	1011	13.3	76.02
22:24:00	92	0	1011	13.3	76.02

22:23:00	92	0	1011	13.3	76.02
22:22:00	92	0	1010.9	13.3	76.01
22:21:00	92	0	1011	13.3	76.02
22:20:00	92	0	1011.1	13.3	76.02
22:19:00	92	0	1011.1	13.3	76.02
22:18:00	93	0.254002	1011	13.3	76.02
22:17:00	92	0	1011	13.3	76.02
22:16:00	92	0	1011	13.3	76.02
22:15:00	92	0	1011	13.3	76.02
22:14:00	92	0.253998	1011.1	13.3	76.02
22:13:00	93	0	1011.1	13.3	76.02
22:12:00	93	0	1011.1	13.9	72.74
22:11:00	93	0	1011.1	13.3	76.02
22:10:00	93	0.254002	1011	13.9	72.73
22:09:00	93	0	1011	13.9	72.73
22:08:00	93	0	1011.1	13.9	72.74
22:07:00	93	0	1011	13.9	72.73
22:06:00	93	0.253998	1011	13.9	72.73
22:05:00	93	0	1011	13.9	72.73
22:04:00	93	0	1011	13.9	72.73
22:03:00	93	0	1011.1	13.9	72.74
22:02:00	93	0	1011.1	13.9	72.74
22:01:00	93	0	1011.1	13.9	72.74
22:00:00	93	0.254002	1011.1	13.9	72.74
21:59:00	93	0	1011	13.9	72.73
21:58:00	93	0	1011	13.9	72.73
21:57:00	93	0	1011.1	13.9	72.74
21:56:00	93	0.254002	1011.1	13.9	72.74
21:55:00	93	0	1011.1	13.9	72.74
21:54:00	93	0	1011	13.9	72.73
21:53:00	92	0	1011	13.3	76.02
21:52:00	92	0.253998	1011	13.3	76.02
21:51:00	92	0	1011	13.3	76.02
21:50:00	92	0	1011.1	13.3	76.02
21:49:00	93	0.254002	1011	13.9	72.73

21:48:00	93	0	1010.9	13.9	72.73
21:47:00	93	0	1010.9	13.9	72.73
21:46:00	93	0.253998	1010.9	13.9	72.73
21:45:00	93	0	1011	13.9	72.73
21:44:00	93	0.253998	1011	13.9	72.73
21:43:00	93	0	1011	13.9	72.73
21:42:00	93	0	1011	13.9	72.73
21:41:00	93	0.254002	1010.9	13.9	72.73
21:40:00	93	0	1010.9	13.9	72.73
21:39:00	93	0.253998	1011	13.9	72.73
21:38:00	93	0	1010.9	13.9	72.73
21:37:00	93	0.254002	1010.9	13.9	72.73
21:36:00	93	0	1010.9	13.9	72.73
21:35:00	93	0.253998	1010.9	13.9	72.73
21:34:00	93	0	1010.9	13.9	72.73
21:33:00	93	0.254002	1010.9	13.9	72.73
21:32:00	93	0	1010.9	13.9	72.73
21:31:00	93	0.253998	1010.9	13.9	72.73
21:30:00	93	0	1010.9	13.9	72.73
21:29:00	93	0	1010.9	13.9	72.73
21:28:00	93	0.254002	1010.8	13.9	72.72
21:27:00	93	0	1010.7	13.9	72.71
21:26:00	93	0.254002	1010.8	13.9	72.72
21:25:00	93	0	1010.8	13.9	72.72
21:24:00	93	0.253998	1010.8	13.9	72.72
21:23:00	93	0	1010.7	13.9	72.71
21:22:00	93	0	1010.7	13.9	72.71
21:21:00	93	0.254002	1010.7	13.9	72.71
21:20:00	93	0	1010.7	13.9	72.71
21:19:00	93	0	1010.6	13.9	72.71
21:18:00	93	0	1010.6	13.9	72.71
21:17:00	93	0.253998	1010.6	13.9	72.71
21:16:00	92	0	1010.5	13.9	72.70
21:15:00	92	0.254002	1010.6	13.9	72.71
21:14:00	92	0	1010.5	13.9	72.70

21:13:00	93	0	1010.5	13.9	72.70
21:12:00	93	0.253998	1010.5	13.9	72.70
21:11:00	93	0	1010.5	13.9	72.70
21:10:00	93	0.254002	1010.5	13.9	72.70
21:09:00	93	0	1010.5	13.9	72.70
21:08:00	93	0	1010.4	13.9	72.69
21:07:00	93	0.254	1010.4	13.9	72.69
21:06:00	93	0	1010.4	13.9	72.69
21:05:00	93	0.254	1010.4	13.9	72.69
21:04:00	93	0	1010.4	13.9	72.69
21:03:00	93	0	1010.3	13.9	72.68
21:02:00	93	0.254	1010.3	13.9	72.68
21:01:00	93	0	1010.3	13.9	72.68
21:00:00	93	0.254002	1010.3	13.9	72.68
20:59:00	93	1.91E-06	1010.3	14.4	70.16
20:58:00	93	0.254002	1010.3	14.4	70.16
20:57:00	93	1.91E-06	1010.3	14.4	70.16
20:56:00	92	0.254002	1010.3	13.9	72.68
20:55:00	92	0.254002	1010.3	13.9	72.68
20:53:00	92	0	1010.3	13.9	72.68
20:52:00	93	0.253998	1010.3	14.4	70.16
20:51:00	93	0	1010.3	14.4	70.16
20:50:00	93	0.253998	1010.3	14.4	70.16
20:49:00	93	0	1010.2	14.4	70.15
20:48:00	93	0.254	1010.3	14.4	70.16
20:47:00	93	0.254	1010.2	14.4	70.15
20:46:00	93	0	1010.2	14.4	70.15
20:45:00	93	0.254	1010.2	14.4	70.15
20:44:00	93	0.254	1010.3	14.4	70.16
20:43:00	93	0	1010.2	14.4	70.15
20:42:00	93	0.254	1010.2	14.4	70.15
20:40:00	93	0.254	1010.2	14.4	70.15
20:39:00	93	0.254	1010.1	14.4	70.15
20:38:00	93	0.254002	1010.1	14.4	70.15
20:37:00	93	0.254002	1010.1	14.4	70.15

20:36:00	93	0.254002	1010.1	14.4	70.15
20:34:00	93	0.253998	1010.1	14.4	70.15
20:33:00	93	0	1010.1	14.4	70.15
20:32:00	93	0.253998	1010	14.4	70.14
20:31:00	93	0.253998	1010	14.4	70.14
20:30:00	92	0	1010	14.4	70.14
20:29:00	92	0.253998	1010	14.4	70.14
20:28:00	92	0	1010	14.4	70.14
20:27:00	92	0.254	1010	14.4	70.14
20:26:00	92	0	1010	14.4	70.14
20:25:00	92	0.254	1010	14.4	70.14
20:24:00	92	0	1010	14.4	70.14
20:23:00	92	0.254	1009.9	14.4	70.13
20:22:00	92	0.254	1009.9	14.4	70.13
20:21:00	92	0	1009.9	14.4	70.13
20:20:00	92	0.254	1009.9	14.4	70.13
20:18:00	92	0	1009.8	14.4	70.13
20:17:00	92	0.254	1009.8	14.4	70.13
20:16:00	92	0	1009.8	14.4	70.13
20:15:00	92	0.254	1009.7	14.4	70.12
20:14:00	92	0	1009.7	14.4	70.12
20:12:00	92	0.254	1009.7	14.4	70.12
20:11:00	92	0.254	1009.7	14.4	70.12
20:10:00	92	0	1009.7	14.4	70.12
20:08:00	92	0.254	1009.6	14.4	70.11
20:07:00	92	0	1009.6	14.4	70.11
20:06:00	92	0.254	1009.6	14.4	70.11
20:05:00	92	0	1009.5	14.4	70.10
20:04:00	92	0.254	1009.5	14.4	70.10
20:03:00	92	0.253998	1009.5	14.4	70.10
20:01:00	92	0	1009.4	14.4	70.10
20:00:00	92	0	1009.4	14.4	70.10
19:59:00	92	0.254	1009.4	14.4	70.10
19:58:00	92	0	1009.3	14.4	70.09
19:57:00	92	0.254	1009.4	14.4	70.10

19:56:00	92	0	1009.4	14.4	70.10
19:55:00	92	0.254	1009.3	14.4	70.09
19:54:00	92	0	1009.3	14.4	70.09
19:53:00	92	0.254	1009.3	14.4	70.09
19:52:00	92	0	1009.3	14.4	70.09
19:51:00	92	0.254	1009.3	14.4	70.09
19:48:00	92	0.253998	1009.3	14.4	70.09
19:47:00	91	0	1009.3	14.4	70.09
19:46:00	91	0	1009.3	14.4	70.09
19:45:00	91	0.254	1009.2	14.4	70.08
19:44:00	91	0	1009.3	14.4	70.09
19:43:00	91	0.254	1009.3	14.4	70.09
19:42:00	91	0	1009.2	14.4	70.08
19:41:00	91	0	1009.2	14.4	70.08
19:40:00	91	0.254	1009.2	14.4	70.08
19:39:00	91	0	1009.2	14.4	70.08
19:38:00	91	0	1009.2	14.4	70.08
19:37:00	91	0.254	1009.2	13.9	72.60
19:36:00	91	0	1009.1	13.9	72.60
19:35:00	91	0	1009.1	13.9	72.60
19:34:00	91	0.254	1009.1	13.9	72.60
19:33:00	91	0.253998	1009.1	13.9	72.60
19:30:00	90	0	1009.1	13.9	72.60
19:29:00	90	0	1009.1	13.9	72.60
19:28:00	90	0	1009.1	13.9	72.60
19:27:00	90	0.253998	1009.1	13.9	72.60
19:26:00	90	0	1009	13.9	72.59
19:25:00	90	0.254	1009.1	13.9	72.60
19:24:00	90	0	1009.1	13.9	72.60
19:23:00	90	0	1009	13.9	72.59
19:22:00	90	0.254	1009	13.9	72.59
19:21:00	89	0	1009.1	13.3	75.87
19:20:00	89	0.254	1009	13.3	75.86
19:19:00	89	0	1008.9	13.3	75.86
19:18:00	89	0.254	1009	13.3	75.86

19:17:00	89	0	1008.9	13.9	72.58
19:16:00	89	0.254	1008.9	13.9	72.58
19:15:00	89	0	1008.9	13.9	72.58
19:14:00	89	0	1009	13.9	72.59
19:13:00	89	0.254	1009	13.9	72.59
19:11:00	89	0	1008.9	13.9	72.58
19:10:00	89	0	1008.8	13.9	72.58
19:09:00	89	0	1008.9	13.9	72.58
19:08:00	89	0	1008.8	13.9	72.58
19:07:00	89	0.254	1008.8	13.9	72.58
19:05:00	89	0	1008.8	13.9	72.58
19:04:00	88	0	1008.7	13.9	72.57
19:03:00	88	0.254	1008.7	13.9	72.57
19:02:00	88	0	1008.6	13.9	72.56
19:01:00	88	0.254	1008.5	13.9	72.55
18:59:00	88	0	1008.5	13.9	72.55
18:58:00	87	0	1008.4	13.9	72.55
18:57:00	88	0	1008.4	13.9	72.55
18:56:00	87	0	1008.4	13.9	72.55
18:55:00	87	0.254	1008.4	13.9	72.55
18:54:00	88	0	1008.3	14.4	70.02
18:53:00	88	0.254	1008.3	14.4	70.02
18:52:00	87	0	1008.3	13.9	72.54
18:51:00	87	0.254	1008.3	13.9	72.54
18:50:00	87	0.254	1008.2	13.9	72.53
18:48:00	87	0.254001	1008.2	14.4	70.01
18:47:00	87	0.254	1008.2	14.4	70.01
18:46:00	87	0	1008.2	14.4	70.01
18:45:00	86	0.254001	1008.1	13.9	72.53
18:44:00	86	0.508	1008.1	14.4	70.01
18:42:00	86	0.254	1008.1	14.4	70.01
18:41:00	86	0.254	1008.1	14.4	70.01
18:40:00	85	0.254	1008	14.4	70.00
18:39:00	85	0.508	1008.1	14.4	70.01
18:38:00	85	0.761999	1008	14.4	70.00


18:37:00	85	0.254	1008	14.4	70.00
18:36:00	85	0.762	1008	14.4	70.00
18:35:00	85	0.508	1008	14.4	70.00
18:34:00	84	1.016	1007.9	14.4	69.99
18:33:00	84	0.762	1007.8	14.4	69.99
18:32:00	83	0.254	1007.8	14.4	69.99
18:31:00	83	0.254	1007.8	14.4	69.99
18:30:00	83	0.254	1007.7	14.4	69.98
18:29:00	82	0.507999	1007.7	14.4	69.98
18:28:00	82	0.508	1007.7	14.4	69.98
18:27:00	81	0.762001	1007.6	14.4	69.97
18:26:00	81	0.508	1007.6	14.4	69.97
18:25:00	80	0.508	1007.5	14.4	69.97
18:24:00	79	0	1007.5	14.4	69.97
18:23:00	79	0.254	1007.4	14.4	69.96
18:22:00	78	0.508	1007.3	14.4	69.95
18:21:00	78	0.254	1007.3	15	67.15
18:20:00	77	0.508	1007.3	15	67.15
18:19:00	76	0.762	1007.3	15	67.15
18:18:00	75	0.762	1007.2	15	67.15
18:17:00	74	0.254	1007.1	15	67.14
18:16:00	73	0.254	1007.1	15	67.14
18:15:00	72	0.254	1007	15	67.13
18:14:00	71	0	1007	15	67.13
18:13:00	69	0.254	1007	14.4	69.93
18:12:00	68	0	1007	15	67.13
18:11:00	68	0.254	1006.9	15	67.13
18:10:00	67	0.254	1006.8	15	67.12
18:09:00	66	0.254	1006.8	15.6	64.54
18:08:00	65	0.254	1006.8	15.6	64.54
18:07:00	61	0.254	1006.8	14.4	69.92
18:06:00	59	0.254	1006.8	13.9	72.43
18:04:00	56	0.254	1006.7	13.3	75.69

Apéndice C

Artículo Científico Publicado como co-autor

Article

Sensitivity Analysis of Start Point of Extreme Daily Rainfall Using CRHUDA and Stochastic Models

Martin Muñoz-Mandujano ¹, Alfonso Gutierrez-Lopez ^{2,*} , Jose Alfredo Acuña-Garcia ^{1,*},
Mauricio Arturo Ibarra-Corona ¹, Isaac Carpintero Aguilar ³ and José Alejandro Vargas-Diaz ¹

¹ Facultad de Informatica, Autonomous University of Queretaro Juriquilla, Queretaro 76230, Mexico; martin.munoz.mandujano@uaq.mx (M.M.-M.); mauricio.ibarra@uaq.mx (M.A.I.-C.); alejandro.vargas@uaq.mx (J.A.V.-D.)

² Water Research Center, International Flood Initiative, Latin-American and the Caribbean Region (IFI-LAC), Intergovernmental Hydrological Programme (IHP), Autonomous University of Queretaro, Queretaro 76010, Mexico

³ Facultad de Ingenieria, Ingenieria Civil, Autonomous University of Queretaro Centro Universitario, Queretaro 76010, Mexico

* Correspondence: alfonso.gutierrez@uaq.mx (A.G.-L.); jose.alfredo.acuna@uaq.mx (J.A.A.-G.)

Abstract: Forecasting extreme precipitation is one of the basic actions of warning systems in Latin America and the Caribbean (LAC). With thousands of economic losses and severe damage caused by floods in urban areas, hydrometeorological monitoring is a priority in most countries in the LAC region. The monitoring of convective precipitation, cold fronts, and hurricane tracks are the most demanded technological developments for early warning systems in the region. However, predicting and forecasting the onset time of extreme precipitation is a subject of life-saving scientific research. Developed in 2019, the CRHUDA (Crossing HUMidity, Dew point, and Atmospheric pressure) model provides insight into the onset of precipitation from the Clausius–Clapeyron relationship. With access to a historical database of more than 600 storms, the CRHUDA model provides a prediction with a precision of six to eight hours in advance of storm onset. However, the calibration is complex given the addition of ARMA(p,q)-type models for real-time forecasting. This paper presents the calibration of the joint CRHUDA+ARMA(p,q) model. It is concluded that CRHUDA is significantly more suitable and relevant for the forecast of precipitation and a possible future development for an early warning system (EWS).

Keywords: CRHUDA; hydrological regime; hydraulic works; storm-duration; rainfall intensity; extreme rainfall



Citation: Muñoz-Mandujano, M.; Gutierrez-Lopez, A.; Acuña-Garcia, J.A.; Ibarra-Corona, M.A.; Aguilar, I.C.; Vargas-Diaz, J.A. Sensitivity Analysis of Start Point of Extreme Daily Rainfall Using CRHUDA and Stochastic Models. *Stats* **2024**, *7*, 160–171. <https://doi.org/10.3390/stats7010010>

Academic Editor: Wei Zhu

Received: 17 December 2023

Revised: 25 January 2024

Accepted: 4 February 2024

Published: 8 February 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Extreme hydrometeorological events represent one of the most important hazards in the countries of Latin America and the Caribbean (LAC). At least three countries in this region have coasts on the Pacific and Atlantic oceans. Mexico, principally due to its orographic characteristics and its geographical position in the Intertropical-zone; make it annually vulnerable to the tracks of tropical cyclones and severe storms of convective origin. [1,2]. Heavy rainfall triggers severe floods, which in turned cause economic losses, damage to infrastructure, social impacts, and health hurt to the population [3]. The implementation of early warning systems, for both floods and extreme precipitation, is one of the ways to reduce the effect of flood damage in the LAC region. However, the technological development used in warning systems in developed countries is far from being applied in LAC lands. Although techniques like neural networks, fuzzy logic, and artificial intelligence have been applied to develop learning algorithms based on the monitoring of climatological variables, the prediction of extreme phenomena is complex [4,5].

Forecasting models allow warning, in the most favorable case, hours in advance. However, it is thoroughly distinguished that phenomena as dynamic as convective cells

of extraordinary intensity, such as vertically developed *cumulus nimbus*, are difficult to predict [6,7]. Recently, the need to incorporate combined models for the spatio-temporal analysis of extreme events associated with early warning systems has been highlighted. The cartography of extreme events is solved with the appropriate selection of anisotropy functions, for example the CH-Glo estimator proposed by Gutierrez-Lopez [8]. Coupling and calibrating warning systems with complex temporal mathematical frameworks is even more difficult.

In the temporal approach, the connection to the warning systems is even more difficult. One of the most often used tools for this goal represent positively the application of stochastic models of the ARMA(p,q) autoregressive type [9,10]. Used in the modeling of most of the processes of the hydrological cycle, these models are adapted to worries related to the representation of groundwater flow as well as to problems involved in the rainfall and runoff regime of a region [11]. The usefulness of these models makes it possible to analyze the incidence of extreme events, uncertainties, potential climatic changes, and strategies to determine even the policies for the operation of hydraulic infrastructure [12,13].

At present, the study of rainfall–runoff processes developed for several climate scenarios can be explored with autoregressive models [14]. Even anomalies due to climate change are studied with ARMA models [15]. A framework that integrates the climatological part with time series analysis is the CRHUDA model, which employs the combination of humidity, atmospheric pressure, and dew point series to predict the onset of precipitation.

Presented by Gutierrez-Lopez et al. in (2019) [16], this CRHUDA model is based on the graphical crossing of the time series of the mentioned variables. It has proved to represent an efficient and effective model for the calibration of the warning system (RedCIAQ) operated by the Civil Protection authorities of the city of Queretaro, Mexico [17]. However, it has been shown that the warning time can be reduced if a scaling factor is introduced to force the crossing of the model series to become increasingly evident. Therefore, the objective of this work is to provide a proportional scaling factor to allow the use of the time series used in the CRHUDA model, hence improving the forecast of the onset of precipitation.

2. Materials and Methods

2.1. CRHUDA Proposed Model

The dew point temperature is the temperature at which air is saturated if it is chilled at a constant pressure [18,19]; that is, the temperature at which the vapor pressure is equal to the saturation pressure of the air. In the same way, the vapor volume present in the atmosphere can be expressed through the pressure that this vapor generates [20,21]. However, the total pressure of the atmosphere is the sum of the pressure caused by dry-air plus the pressure produced by water vapor [22,23]. Thus, the maximum vapor pressure that may be present depends on the ambient temperature [24]. As the temperature increases, more vapor pressure can be contained in the air [25,26]. This can be expressed by the Clausius–Clapeyron relationship [27,28]. Therefore, when the air is saturated with water vapor, the pressure of the water vapor depends only on the temperature [10,29,30]. In this way, two time series are plotted; the first is the humidity data (Z^1) and the second is the series defined by dew point and atmospheric pressure (Z^2). The crossing of these two series will indicate the beginning of the alert; eight hours later, the series will cross again and, at that moment, the precipitation will start (Figure 1).

This means that, for the precipitation to begin, it must happen on $t_1 \rightarrow (Z^1_{t-k} \cap Z^2_{t-k})$, and considering $T_k + \Delta T$ at $t_2 \rightarrow (Z^1_{t-k} \cap Z^2_{t-k})$. If $\Delta T = 0$, the forecast of the start of precipitation event H_p is precise. If $\Delta T \neq 0$, there is a time delay in the start of the precipitation event H_p [16].




Figure 1. Conceptual scheme of the CRHUDA model (Crossing HUmidity, Dew point, and Atmospheric pressure). Adapted from [16].

2.2. Autoregressive Moving-Average Models ARMA(p,q)

These models are applied to annual series; they comprise a combination of the autoregressive AR(p) models and the moving average MA(q) models [31]; the value of p refers to the number of parameters associated with the autoregressive component, and q represents the number of parameters of the moving average component. The general representation of the ARMA(p,q) models is:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q}, \quad (1)$$

where ε_t is a random variable independent of time, ϕ_p are parameters of the autoregressive component, and θ_q are parameters of the moving average component. If a representative sample of the process is available, the parameters ϕ_p are determined so as to reproduce the correlations r_1, r_2, \dots, r_p calculated with the data. This method considers the data and residuals to be normal and independent. A property of ARMA(p,q) models is that the autocovariances from order 1 to order q depend on the autoregressive parameters ϕ_p and the moving averages θ_q , while for higher orders they depend only on the autoregressive parameters. For the case of a discrete series, the autocovariance is calculated as:

$$C_k = \frac{1}{n} \sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t-k} - \bar{X}); 0 < k < N. \quad (2)$$

2.3. Multivariate Stochastic Models

The practice of multivariate analysis combined with time series in hydrometeorological subjects has been developed to estimate hydrological variables at ungauged sites or without data. While spectral functions allowed the study of frequency relationships between two time series, the fundamental question in the time domain is how to improve the predictions of univariate models. Hydrologists use the time (frequency) domain in multivariate series to consider climatic phenomena simultaneously.

Predictions of Z_t can be made using the past history of the single variable Z_t , or by considering a richer set of information ($Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n; k = 0, 1, 2, \dots$), and by building a multivariate model $Z_t = f(Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n, \varepsilon_{t-k}^1, \varepsilon_{t-k}^2, \varepsilon_{t-k}^3, \dots, \varepsilon_{t-k}^n; k > 0)$. This multivariate modeling is of double interest: it provides an explanatory framework that is descriptive of the evolution of Z_t , and theoretically it should lead to better forecasts than those provided by the univariate model $\varnothing(B)Z_t \approx \theta(B)\varepsilon_t$. With this background, the use of stochastic models is proposed to describe the behavior of the CRHUDA model series $Z_t = f(Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n, \varepsilon_{t-k}^1, \varepsilon_{t-k}^2, \varepsilon_{t-k}^3, \dots, \varepsilon_{t-k}^n; k > 0)$ —multivariate models distributed in time, in which the inputs X_t are climatic variables.

2.4. Autocorrelation as Validation of CRHUDA Model

The autocovariance function C_k provides a covariance measure for a couple of values with an offset of time lag k . It provides information about the variability of the series and the temporal relations between the different components of the X_t series. If only the correlations between the different pairs X_t, X_{t+k} are of interest, it is necessary to define the autocorrelation function r_k of the process X_t , i.e.,

$$r_k = \frac{C_k}{C_0} = \frac{\sum_{t=1}^{N-k} (X_t - \bar{X})(X_{t+k} - \bar{X})}{n \sum_{t=1}^N (X_t - \bar{X})^2}, \tag{3}$$

where

$$C_0 = n \sum_{t=1}^N (X_t - \bar{X})^2 \tag{4}$$

$$\text{Cov} = [X_t X_{t-k}] = E[(X_t - \bar{X})(X_{t-k} - \bar{X})]. \tag{5}$$

r_k represents the correlation coefficient for a couple of values separated by a lag time k . As k increases, the correlation between $[X_t \text{ and } X_{t-k}]$ decreases. Then, for our case, $Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n; k = 0, 1, 2, \dots$ will be the three time series of the CRHUDA model. That is:

$$\text{CRHUDA} \left(Z_{t-k}^1 \subseteq Z_{t-k}^2 \right) \rightarrow \left(Z_{t-k}^1 \cap Z_{t-k}^2 \right) \left\{ \begin{array}{l} Z_{t-k}^1 = \text{humidity} \\ Z_{t-k}^2 = \frac{\text{atmospheric pressure}}{\text{dew point}} \end{array} \right. \tag{6}$$

2.5. Sensitivity Analysis

A scaling factor β is introduced, which will be proportional to the series of serial autocorrelation values.

$$\left(Z_{t-k}^1 \subseteq Z_{t-k}^2 \right) \propto \beta \left(Z_{t-k}^1 \cap Z_{t-k}^2 \right). \tag{7}$$

The autocorrelation function can be defined by $r_k = f \left(Z_{t-k}^1 \subseteq Z_{t-k}^2 \right)$ for any process, proportional to $f = \left[\beta \left(Z_{t-k}^1 \cap Z_{t-k}^2 \right) \right]$. Thus, a sensitivity analysis item of the CRHUDA model is proposed. Residuals from the two series $\varepsilon \rightarrow \left(Z_{t-k}^1 \subseteq Z_{t-k}^2 \right)$ must have zero mean and must be uncorrelated, which implies that it is independent of time k ; this is $\varepsilon = [\varepsilon_t, t \in N]; E[\varepsilon_t | \varepsilon_{t-1}] = 0$ and $\text{Var}[\varepsilon_t] = \sigma_\varepsilon^2$. From the properties of the autocorrelation function, it is known that $C_0 = E \left[(X_t - \bar{X})^2 \right] = \text{Var}[X_t] = \sigma_x^2$ if $k = 0$, then C_0 is the stationary variance in t_0 . Thus, if the series Z_{t-k}^1 & Z_{t-k}^2 are independent, then $r_k = \frac{C_k}{C_0} \rightarrow 0$ tends to zero. However, being a multivariate stochastic model, the series must fulfill the condition of independence and joint stationarity. This can be verified in a systematical manner with the help of the correlogram-multivariate limits; in this way, it is proposed that:

Lemma 1. *An autocorrelation coefficient r_k calculated from a multivariate stochastic series $f \left(Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n \right)$ outside the confidence limits of the correlogram; it represents a break point in the Z_{t-k}^n series. This break point in itself locates the times t_1 and t_2 of crossing between the series that compose the CRHUDA model.*

Lemma 2. *The crossing time k between the series of the CRHUDA model can be modified by a time T_k using a scaling factor β such that $\left(Z_{t-k}^1 \subseteq Z_{t-k}^2 \right) \propto \beta \left(Z_{t-k}^1 \cap Z_{t-k}^2 \right)$.*

Fitting the autocorrelation function, the result is as follows:

$$C_k = E[(X_t - \bar{X})(X_{t+k} - \bar{X})] = E[(X_{t-k} - \bar{X})(X_\beta - \bar{X})] \text{ with } \beta = t + k. \tag{8}$$

To associate the time lag that occurs in r_k , it is possible to do:

$$(\text{Lag})_k = \text{Lag}(\text{Lag} + 1)(\text{Lag} + k - 1) = \frac{\Gamma(\text{Lag} + k)}{\Gamma(\text{Lag})} \approx \frac{(\text{Lag} + k - 1)!}{(\text{Lag} - 1)!}. \quad (9)$$

If $\beta > 0$; $(\beta)_0 = 1$ & $(1)_k = k!$, then k is the time lag, where r_k (Lemma 1) for $r_k = \beta - 1 > 0$

$$\begin{aligned} (\beta)_k &= \beta(\beta + 1)(\beta + 2) \cdots (\beta + k - 1) \\ (\beta)_k &= (r + 1)(r + 2) \cdots (r + k) \\ (\beta)_k &= \frac{1}{r}r(r + 1)(r + 2) \cdots (r + k) = \frac{1}{r}(r)_{k+1}. \end{aligned} \quad (10)$$

Then, the scaling factor can be written as:

$$\begin{aligned} (\beta)_k &= \frac{(\beta - 1)_{k+1}}{\beta - 1} \\ (\beta)_{k+1} &= \beta(\beta + 1)_k. \end{aligned} \quad (11)$$

3. Results

Data from the extreme precipitation monitoring network RedCIAQ, which includes the alert system for the city of Queretaro in central Mexico [8], were used. This network includes more than 40 Automatic Weather Stations (AWS) located in the metropolitan area of the city of Queretaro. The data were collected in real-time, minute by minute. The database managed in this work consists of 2800 CSV files, totaling 12 GB of information. To calculate the scale factor, correlograms of each event studied must be calculated using the autocorrelation function values. To produce the autocorrelograms, we selected a sample of convective storms from several stations and dates, handling approximately 145,000 records and generating a total of 720 autocorrelograms. The method involved three phases. In the first phase, the data of the precipitation height, humidity, dew point, and atmospheric pressure were extracted for more than 500 storms between 2012 and 2021 collected every minute to generate the series Z_{t-k}^1 and Z_{t-k}^2 . The second phase of the process includes calculating the values of the autocorrelation coefficient and plotting the correlograms of all the series $r_k = f(Z_{t-k}^1 \subseteq Z_{t-k}^2)$ to evaluate the breakpoints. In the third phase, the scaling factor is calculated and verified as β .

3.1. Presentation of CRHUDA Model

The CRHUDA model, in its initial version, used two time series comprising three climatological variables: humidity, atmospheric pressure, and dew point. The series are presented in a scaled graph that highlights the moments of crossing between them. The calculation and application of the proposed scale factor optimize the crossing time between the two series for forecasting the onset of precipitation.

The CRHUDA model (Equation (6)) was applied to the data of the storms that occurred between 2012 and 2021 in the metropolitan area of the city of Queretaro. In a synoptic sense, it is possible to see, remarkably, that the crossing of these two time series $\text{CRHUDA}(Z_{t-k}^1 \subseteq Z_{t-k}^2) \rightarrow (Z_{t-k}^1 \cap Z_{t-k}^2)$, a point in time that provides a warning 9 to 10 h prior to the onset of the storm. For example, Figure 2 shows the results of the application of the CRHUDA model in the AWS-Candiles for the storm data of 24 and 25 June 2013. At around 10:20, the first crossing is observed; the humidity drops fast, which allows the alert to be initiated. After this point, the crossing occurs in the opposite direction and precipitation starts. Results revealed a mean time of 10 h $T_t + \Delta t = 619.58$ min between warning t_1 and the onset of precipitation t_2 , with a mean of 8.9 h (534 min). The same analysis can be performed for the next day's storm. With this example, it is evident that the scale of the ordinate axis is important and strongly influences the location of the points in time (t_1 & t_2) as precise instants of crossings. Lemmas 1 and 2 are important here. Finding the precise instants of t_1 and t_2 crossings is critical to generate warnings and communicate to the local civil protection authorities. Thus, the scaling factor between the

two series must be visualized and calculated $(Z^1_{t-k} \subseteq Z^2_{t-k}) \propto \beta (Z^1_{t-k} \cap Z^2_{t-k})$. The visual calibration results of the scaling factor were between 0.4 and 2.6 with a mean of 1.784.




Figure 2. Results of the application of the CRHUDA model at AWS-Candiles station on 24–25 June 2013.

Figures 3 and 4 show the results for other stations and with different storm data. Storms where the need to estimate the scaling factor is evident are especially highlighted. For example, in Figure 3, the crossing between the two time series is imperceptible at some times. A synoptic recognition is very compromised to associate the result with a warning system. Lemma 2 must then be mathematically tested through the components and parameters of the time series processed as a multivariate stochastic autoregressive model.




Figure 3. Results of the application of the CRHUDA model at the AWS-Cimatario station on 16 August 2014 (maximum rainfall 15.4 mm in 1-h; maximum intensity 41.2 mm/h; 32-year return period).



Figure 4. Results of the application of the CRHUDA model to the AWS-UAQ Cerro Campanas data of 16 August 2014 (maximum rainfall 55.2 mm in 1-h; maximum intensity 63.8 mm/h; 53-year return period).

Figure 4 shows a large sequence of storms for the AWS University Center station. The application of the CRHUDA model is remarkable due to the number of storms that occurred. In all cases, the crossings are perfectly identified, which allows a very trustworthy forecast of the onset of precipitation to be made. Next, it is important to mathematically validate the calculation of the scaling factor β using the autocorrelation function values.

3.2. Calculation of Correlograms

An autocorrelation coefficient r_k calculated from a multivariate stochastic series $f(Z_{t-k}^1, Z_{t-k}^2, Z_{t-k}^3, \dots, Z_{t-k}^n)$ outside the confidence limits of the correlogram; it represents a break point in the Z_{t-k}^n series. This break point itself locates the times t_1 and t_2 of crossing between the series that form the CRHUDA model. With this hypothesis, the values of the autocovariance and autocorrelation functions of each of the variables, series, and the complete CRHUDA model were calculated. The main question remains—what is the forecast time of rainfall events?—since the answer has important implications, as a successful rainfall forecasting model can be used in a flood early warning system. Thus, the correlograms obtained from Equations (2)–(4) allow the scaling factor to be calculated with precision. Figure 5 shows the correlograms for the atmospheric pressure time series for the AWS-Juriquilla station during the 17 September 2017 storm: (a) 1 h; (b) 6 h; (c) 12 h; and (d) 24 h. For the same storm, Figures 6 and 7 show the correlograms for the humidity and dew point series, respectively. To be specific, this storm caused severe damage in the Queretaro metropolitan area including a large sinkhole and losses of road infrastructure, to mention a few. It is critical to highlight that the management of extreme precipitation in this city has already been studied in terms of its spatial component associated with the city’s warning system [8].




Figure 5. Atmospheric pressure correlograms for AWS-Juriquilla Station on 17 September 2017 at different time intervals (a) 6 h, (b) 12 h, and (c) 24 h.




Figure 6. Humidity correlograms for AWS-Juriquilla Station on 17 September 2017 at different time intervals (a) 6 h (b) 12 h and (c) 24 h.

The results of the correlograms of the series analyzed individually show, in almost all cases, a break in one of the k times. With these results, two facts are verified: (i) the correlograms allow us to locate in time the changes in the behavior of the series, identified

from the correlogram as points outside the confidence limits; (ii) the estimated values of the autocorrelation coefficients allow us to calculate a scaling factor. In Figures 6–8, the blue line represents the correlogram, while the red line represents its limits.




Figure 7. Dew point correlograms for AWS-Juriquilla Station on 17 September 2017 at different time intervals (a) 6 h, (b) 12 h, and (c) 24 h.




Figure 8. Correlogram for the full CRHUDA model at AWS-Juriquilla Station on 17 September 2017 at different time intervals (a) 12 h, and (b) 24 h.

3.3. Calculation of Scaling Factor β

These results show that, as was expected when Equation (9) was derived, it is possible to represent the scaling factor employing the full model. At that point, the results of the correlograms of the full model provide the necessary values of the autocorrelation coefficients to build the scaling factor. The calculation of the scaling factor is performed on the basis of the premise proposed in this work, where the crossing time k between the series of the CRHUDA model is modified by a time T_k using a scaling factor β such that $(Z_{t-k}^1 \subseteq Z_{t-k}^2) \propto \beta(Z_{t-k}^1 \cap Z_{t-k}^2)$. From the values of the autocorrelation function, the correlograms of the complete model are calculated; for example, for one of the most destructive storms in recent years in the metropolitan area of the city of Queretaro, on 17 September 2017. Figure 8 shows the results of the correlograms of the complete CRHUDA model for this storm. At some points (k times), the correlogram goes out of its limits. These points represent the values of $(\beta)_{k+1} = \beta(\beta + 1)_k$ for computing the scaling factor. As a complement to the mentioned before, Table 1 shows the results of calculating the autocorrelation coefficients and all the parameters of the CRHUDA model for storms occurring in September, which is the rainiest month of the year in the city of Queretaro. The mean scaling factor for the month of September is 1.107, the mean value of $\Delta T = 0:24:01$, and the mean value of $T_k = 1:46:45$. From the above it can be deduced that, for the month of September, a warning can be given with a time of around two hours in advance ($1:46:45 + 0:24:01 = 2:10:46$) whenever the scaling factor is used with the calculated values. It is worth mentioning that only results for some storms and some AWS-stations are shown. Complete results for all storms and all source data are available upon request.

Table 1. Results of the sensitivity analysis and scaling factor for the CRHUDA model applied to data from various extreme storms recorded in the month of September. AWS-Milenio station.

Storm Date	β	t_2	ΔT	t_1	T_k
8 September 2013	1.23	16:40:00	0:13:00	16:37:00	0:03:00
16 September 2013	1.31	15:15:00	0:06:00	14:51:00	0:24:00
21 September 2013	1.28	13:54:46	0:44:14	13:54:16	0:00:30
25 September 2016	1.24	15:37:00	0:05:00	15:36:00	0:01:00
17 September 2017	0.72	0:00:00	0:00:00	0:00:00	0:00:00
26 September 2017	0.93	19:26:00	1:40:00	19:12:00	0:14:00
9 September 2018	1.24	21:18:00	0:39:00	21:16:00	0:02:00
19 September 2019	1.14	20:52:00	0:02:00	11:41:00	9:11:00
29 September 2019	1.22	18:10:00	0:18:00	18:08:00	0:02:00
7 September 2021	0.77	18:17:00	0:13:00	10:27:00	7:50:00

4. Discussion

4.1. Calculation of Scaling Factor β

At this point, it has been proven that the CRHUDA model that was designed to detect the effect of the Clausius–Clapeyron (C-C) ratio (combination of atmospheric pressure, dew point, and humidity) is able to predict the onset of precipitation with excellent accuracy. These variables have already been manipulated, but individually and in meteorological models [9,28,32]. However, the results are consistent with those of other studies that suggest there is a correlation between the dew point and the C-C ratio. This is for the coherent physical argument that C-C behavior arises from the physics of convective clouds [25,33]. Thus, CRHUDA as a fundamental synoptic model can forecast the onset of precipitation reliably, on mean nine to ten hours before the onset of precipitation; this forecast seems acceptable. This is also in agreement with our previous observations that showed that it is possible to use the real-time hydrometeorological data set on a minute-by-minute basis [34,35]. Therefore, it can be suggested that a daily precipitation database allows the correct spatiotemporal disaggregation of spatially distributed hourly precipitation [36,37]. This finding has important implications for the development of a precipitation forecasting model to provide forecasts in advance, since it is only necessary to find the right combination of climatic variables [38,39]. Once the synoptic part of the validation is accepted, the stochastic forecast model is critical. A scaling factor having been verified, a sensitivity analysis can be presented as shown in Figures 9 and 10. Figure 9 shows four crossover zones for two storms recorded at the AWS-Milenio station on 24 and 25 June 2013. Considering a scaling factor equal to one, the forecast and warning are performed normally. However, when the scaling factor is modified (for discussion purposes only); the crossing does not occur and therefore the alert cannot be triggered (Figure 10). It is evident that the scaling factor is of considerable importance when the CRHUDA model is linked to a real-time warning system. It is necessary, then, that the calculation and the previous calibration of the scaling factor is the function of the autocorrelation coefficients according to Equation (10).




Figure 9. CRHUDA model for the 24–25 June 2013 AWS-Milenio station ($\beta = 1$). Humidity (red line), Atmospheric pressure/dewpoint (blue line).




Figure 10. CRHUDA model for the 24–25 June 2013 AWS-Milenio station ($\beta = 0.5$). Humidity (red line), Atmospheric pressure/dewpoint (blue line).

4.2. Model Calibration, Validation and Precision

The calibration and validation process of the CRHUDA model were conducted in 2019 [16]. However, it is believed that the model's precision, particularly when coupled with early warning systems, can be improved. Therefore, this paper presents the estimation of a scaling factor based on the autocorrelation coefficient of the time series that comprise the model.

The CRHUDA model is currently coupled to the RedCIAQ extreme precipitation monitoring network [8] and is in operation. The daily operation of the CRHUDA model is vital for the intervention protocols of the local Civil Protection authorities, especially during the months of July to September. Improving the accuracy of early warning models for extreme precipitation remains a priority, particularly in underdeveloped countries. Therefore, it is appropriate to conduct a sensitivity analysis of the scaling factor proposed in this work. Figure 9 illustrates the daily application of the CRHUDA model. For instance, in June, the warning time is appropriate for a scaling factor of one at the AWS-Milenio station. However, Figure 10 shows hypothetically how a change in the scaling factor's value can affect the crossing times' location and, consequently, the alert times issued by the authorities.

Although the focus of this work was on obtaining the scale factor, a comprehensive sensitivity analysis of all climatological stations in the RedCIAQ is required. Therefore, it is necessary to adjust the precision of the CRHUDA model using the proposed scale factor for each AWS station and for each month. It is recommended that this analysis be conducted at least once a year before the rainy season.

5. Conclusions

The results of this study show that it is possible to combine the climatic variables— atmospheric pressure, dew point, and humidity—to forecast the onset of precipitation. These variables are represented in two time series that can be plotted to determine, synoptically, the time (instant) of crossing between both series. This instant of crossing triggers the warning to be considered as the onset of precipitation at the subsequent crossing. From the results obtained, it is concluded that the warning time from the first crossing to the onset of precipitation at the second crossing, on mean, represent nine to ten hours. It was exposed that the crossing times of both series are a function of the autocorrelation coefficients of the complete model. It has been found that a scaling factor can improve forecast precision at crossing times. This scaling factor is calculated using the autocorrelation coefficients. The systematic application of the CRHUDA model with its respective scaling factor adjusted to the historical data of each AWS represents a suitable tool to be linked to a real-time precipitation warning system. The study of the CRHUDA model as an extremely practical algorithm for warning systems should be extended.

Author Contributions: Conceptualization, M.M.-M. and A.G.-L.; methodology, A.G.-L.; software, M.M.-M.; validation, M.A.I.-C., I.C.A. and J.A.V.-D.; formal analysis, A.G.-L.; investigation, M.M.-M. and A.G.-L.; resources, J.A.A.-G.; data curation, M.M.-M.; writing-original draft preparation, A.G.-L.; writing-review and editing, A.G.-L. All authors have read and agreed to the published version of the manuscript.

Funding: This work was financially supported by the National Council of Science and Technology, Mexico. Call for proposals 2021–2022, national research and incidence projects on extensive knowledge and watershed management of the socio-natural water cycle for the collective good and environmental justice (CONACYT/PRONAI-318956).

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Data are available from the corresponding author, upon reasonable request.

Acknowledgments: The author is grateful to the Risk Management Unit of the UNESCO Regional Office of Science for Latin America and the Caribbean.

Conflicts of Interest: The authors declare no conflicts of interest.

References

1. Lepore, C.; Allen, J.T.; Tippet, M.K. Relationships between Hourly Rainfall Intensity and Atmospheric Variables over the Contiguous United States. *J. Clim.* **2016**, *29*, 3181–3197. [[CrossRef](#)]
2. Vincent, L.A.; van Wijngaarden, W.A.; Hopkinson, R. Surface Temperature and Humidity Trends in Canada for 1953–2005. *J. Clim.* **2007**, *20*, 5100–5113. [[CrossRef](#)]
3. CENAPRED. *Disasters in Mexico: Social and Economic Impacts (1980–2014)*; Centro Nacional de Prevención de Desastres: Ciudad de México, Mexico, 2016.
4. Valverde Ramírez, M.C.; de Campos Velho, H.F.; Ferreira, N.J. Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *J. Hydrol.* **2005**, *301*, 146–162. [[CrossRef](#)]
5. Zahraei, A.; Hsu, K.-L.; Sorooshian, S.; Gourley, J.J.; Hong, Y.; Behrangi, A. Short-term quantitative precipitation forecasting using an object-based approach. *J. Hydrol.* **2013**, *483*, 1–15. [[CrossRef](#)]
6. Egerer, M.H.; Lin, B.B.; Kendal, D. Temperature Variability Differs in Urban Agroecosystems across Two Metropolitan Regions. *Climate* **2019**, *7*, 50. [[CrossRef](#)]
7. Emmanuel, L.A.; Hounou, N.R.; Biao, C.A.; Badou, D.F. Statistical Analysis of Recent and Future Rainfall and Temperature Variability in the Mono River Watershed (Benin, Togo). *Climate* **2019**, *7*, 8. [[CrossRef](#)]
8. Gutierrez-Lopez, A. A Robust Gaussian variogram estimator for cartography of hydrological extreme events. *Nat. Hazards* **2021**, *107*, 1469–1488. [[CrossRef](#)]
9. Rogers, J.C.; Wang, S.-H.; Coleman, J.S.M. Evaluation of a Long-Term (1882–2005) Equivalent Temperature Time Series. *J. Clim.* **2007**, *20*, 4476–4485. [[CrossRef](#)]
10. Millán, H.; Ghanbarian-Alavijeh, B.; García-Fornaris, I. Nonlinear dynamics of mean daily temperature and dewpoint time series at Babolsar, Iran, 1961–2005. *Atmos. Res.* **2010**, *98*, 89–101. [[CrossRef](#)]
11. Mohr, S.; Kunz, M. Recent trends and variabilities of convective parameters relevant for hail events in Germany and Europe. *Atmos. Res.* **2013**, *123*, 211–228. [[CrossRef](#)]
12. Dahm, R.; Bhardwaj, A.; Weiland, F.S.; Corzo, G.; Bouwer, L.M. A Temperature-Scaling Approach for Projecting Changes in Short Duration Rainfall Extremes from GCM Data. *Water* **2019**, *11*, 313. [[CrossRef](#)]
13. Damrath, U.; Doms, G.; Frühwald, D.; Heise, E.; Richter, B.; Steppeler, J. Operational quantitative precipitation forecasting at the German Weather Service. *J. Hydrol.* **2000**, *239*, 260–285. [[CrossRef](#)]
14. Polotzek, K.; Kantz, H. An ARFIMA-based model for daily precipitation amounts with direct access to fluctuations. *Stoch. Environ. Res. Risk Assess.* **2020**, *34*, 1487–1505. [[CrossRef](#)]
15. Gil-Alana, L.A.; Martín-Valmayor, M.A.; Hube-Antoine, C. An analysis of temperature anomalies in Chile using fractional integration. *Stoch. Environ. Res. Risk Assess.* **2023**, *37*, 2713–2724. [[CrossRef](#)]
16. Gutierrez-Lopez, A.; Cruz-Paz, I.; Mandujano, M.M. Algorithm to Predict the Rainfall Starting Point as a Function of Atmospheric Pressure, Humidity, and Dewpoint. *Climate* **2019**, *7*, 131. [[CrossRef](#)]
17. Gutierrez-Lopez, A.; Trejo, M.F.; Gonzalez, N.I.A.; Prado, F.B. Análisis de la variabilidad espacial en la precipitación en la zona metropolitana de Querétaro empleando ecuaciones de anisotropía. *Investig. Geográficas* **2019**, *99*, 1–16. [[CrossRef](#)]
18. Shaw, S.B.; Royem, A.A.; Riha, S.J. The Relationship between Extreme Hourly Precipitation and Surface Temperature in Different Hydroclimatic Regions of the United States. *J. Hydrometeorol.* **2011**, *12*, 319–325. [[CrossRef](#)]
19. Agard, V.; Emanuel, K. Clausius-Clapeyron Scaling of Peak CAPE in Continental Convective Storm Environments. *J. Atmos. Sci.* **2017**, *74*, 3043–3054. [[CrossRef](#)]

20. Lorenz, D.J.; DeWeaver, E.T. The Response of the Extratropical Hydrological Cycle to Global Warming. *J. Clim.* **2007**, *20*, 3470–3484. [[CrossRef](#)]
21. Camuffo, D. Theoretical Grounds for Humidity. In *Microclimate for Cultural Heritage*; Elsevier: Amsterdam, The Netherlands, 2014; Chapter 2A; pp. 49–76. ISBN 9780444632982. [[CrossRef](#)]
22. Romps, D.M. An Analytical Model for Tropical Relative Humidity. *J. Clim.* **2014**, *27*, 7432–7449. [[CrossRef](#)]
23. Holley, D.M.; Dorling, S.R.; Steele, C.J.; Earl, N. A climatology of convective available potential energy in Great Britain. *Int. J. Clim.* **2014**, *34*, 3811–3824. [[CrossRef](#)]
24. Chang, W.; Stein, M.L.; Wang, J.; Kotamarthi, V.R.; Moyer, E.J. Changes in Spatiotemporal Precipitation Patterns in Changing Climate Conditions. *J. Clim.* **2016**, *29*, 8355–8376. [[CrossRef](#)]
25. Lenderink, G.; Barbero, R.; Loriaux, J.M.; Fowler, H.J. Super-Clausius–Clapeyron Scaling of Extreme Hourly Convective Precipitation and Its Relation to Large-Scale Atmospheric Conditions. *J. Clim.* **2017**, *30*, 6037–6052. [[CrossRef](#)]
26. Bürger, G.; Heistermann, M.; Bronstert, A. Towards Subdaily Rainfall Disaggregation via Clausius–Clapeyron. *J. Hydrometeorol.* **2014**, *15*, 1303–1311. [[CrossRef](#)]
27. Peleg, N.; Marra, F.; Fatichi, S.; Molnar, P.; Morin, E.; Sharma, A.; Burlando, P. Intensification of Convective Rain Cells at Warmer Temperatures Observed from High-Resolution Weather Radar Data. *J. Hydrometeorol.* **2018**, *19*, 715–726. [[CrossRef](#)]
28. Velasco, S.; Fernández-Pineda, C. Sobre la obtención de la ecuación de Clapeyron-Clausius. *Rev. Española Física* **2008**, *22*, 7–14.
29. Seidel, T.M.; Grant, A.N.; Pszenny, A.A.P.; Allman, D.J. Dewpoint and Humidity Measurements and Trends at the Summit of Mount Washington, New Hampshire, 1935–2004. *J. Clim.* **2007**, *20*, 5629–5641. [[CrossRef](#)]
30. Harder, P.; Pomeroy, J. Estimating precipitation phase using a psychrometric energy balance method. *Hydrol. Process.* **2013**, *27*, 1901–1914. [[CrossRef](#)]
31. Box GE, P.; Jenkins, G.M. *Time Series Analysis: Forecasting and Control*; Holden-Day: San Francisco, CA, USA, 1976; ISBN 9780816211043.
32. Sim, I.; Lee, O.; Kim, S. Sensitivity Analysis of Extreme Daily Rainfall Depth in Summer Season on Surface Air Temperature and Dew-Point Temperature. *Water* **2019**, *11*, 771. [[CrossRef](#)]
33. Danladi, A.; Stephen, M.; Aliyu, B.; Gaya, G.; Silikwa, N.; Machael, Y. Assessing the influence of weather parameters on rainfall to forecast river discharge based on short-term. *Alex. Eng. J.* **2018**, *57*, 1157–1162. [[CrossRef](#)]
34. Li, P.; Lai, E.S. Short-range quantitative precipitation forecasting in Hong Kong. *J. Hydrol.* **2004**, *288*, 189–209. [[CrossRef](#)]
35. Moon, S.-H.; Kim, Y.-H.; Lee, Y.H.; Moon, B.-R. Application of machine learning to an early warning system for very short-term heavy rainfall. *J. Hydrol.* **2019**, *568*, 1042–1054. [[CrossRef](#)]
36. Segond, M.-L.; Onof, C.; Wheeler, H. Spatial-temporal disaggregation of daily rainfall from a generalized linear model. *J. Hydrol.* **2006**, *331*, 674–689. [[CrossRef](#)]
37. Dyson, L.L.; van Heerden, J.; Sumner, P.D. A baseline climatology of sounding-derived parameters associated with heavy rainfall over Gauteng, South Africa. *Int. J. Clim.* **2014**, *35*, 114–127. [[CrossRef](#)]
38. Berg, P.; Haerter, J. Unexpected increase in precipitation intensity with temperature—A result of mixing of precipitation types? *Atmos. Res.* **2013**, *119*, 56–61. [[CrossRef](#)]
39. Park, I.-H.; Min, S.-K. Role of Convective Precipitation in the Relationship between Subdaily Extreme Precipitation and Temperature. *J. Clim.* **2017**, *30*, 9527–9537. [[CrossRef](#)]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.