



UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO

Maestría en Ciencias en Ingeniería Ambiental

Facultad de Ingeniería Química

Facultad de Ingeniería Civil

Facultad de Biología

TESIS

“SISTEMA DE ALERTA TEMPRANA PARA EL PRONÓSTICO A CORTO PLAZO DE LLUVIAS INTENSAS EN LA CIUDAD DE MORELIA, MICHOACÁN, MÉXICO”.

Como requisito para obtener el grado de:

Maestro en Ciencias en Ingeniería Ambiental

Presenta:

Ing. Juan Ángel Saucedo García

Asesora:

Dra. Sonia Tatiana Sánchez Quispe

Co-Asesor:

Dr. Francisco Javier Domínguez Mota

Febrero de 2023

Morelia, Michoacán, México.

Dedicatoria

A Dios por permitirme llegar hasta este punto de mi vida, por ser tan generoso y otorgarme la dicha de poder disfrutar todos los momentos buenos y malos que se me han presentado.

A mis padres María y Epigmenio que siguen siendo un pilar fundamental en mi vida académica y personal. Por seguir dándome su apoyo cuando se los he pedido. Por ser tan amorosos y sobre todo por seguir enseñándome muchísimo de la vida a pesar de creer que ya lo sé todo.

A mi abuelito Epigmenio que es un ejemplo grandísimo de disciplina y espiritualidad, en el que me veo reflejado para poder conseguir mis metas. También a mis abuelitas María y Mago que ya no se encuentran en este mundo pero que sin duda me hubiera encantado compartir con ellas este logro.

A mi novia Alejandra a la que amo mucho, que ha sido un apoyo emocional incondicional a lo largo de esta travesía y que me ha brindado muchas alegrías.

Agradecimientos

Quiero agradecer especialmente a la Dra. Sonia que ha sido parte fundamental de este trabajo, por su conocimiento otorgado y consejos tanto académicos como profesionales. Por su tiempo y esfuerzo puesto en esta dirección de tesis.

Al Dr. Francisco Javier también por su esfuerzo y tiempo otorgado hacia este trabajo. Al Dr. Jaime que invirtió tanto tiempo en la revisión de este documento, por sus correcciones oportunas y apoyo en otros ámbitos académicos y de investigación.

A mi mesa sinodal, al Dr. Julio César Orantes, Dr. Juan Manuel Ortega, Dr. Ricardo Miguel Pérez y el Dr. José Apolinar. Por sus enriquecedores y oportunos aportes a este trabajo.

A mis compañeros de maestría Julio Cardiel y Daniel Mejía que me hicieron más amena mi estancia en este posgrado, por los momentos de diversión y amistad.

Índice de contenido

Resumen	1
1. Introducción.....	2
2. Justificación	4
3. Hipótesis	5
4. Objetivos.....	5
4.1. Objetivo General.....	5
4.2. Objetivos específicos	5
5. Marco teórico.....	6
5.1. Gestión del Riesgo de Desastre	6
5.2. Componentes básicas del Riesgo.....	6
5.2.1. Desastres	6
5.2.2. Riesgo	7
5.2.3. Vulnerabilidad	9
5.2.4. Amenaza	11
5.3. Sistemas de Alerta Temprana	12
5.3.1. Definiciones.....	12
5.3.2. Elementos de un SAT	12
5.4. Pronóstico de lluvias.....	13
5.4.1. Métodos para el pronóstico de lluvias	14
5.4.2. Redes Neuronales Artificiales	15
5.4.2.1. Neurona biológica y neurona artificial.....	15
5.4.2.2. Perceptrón.....	17
5.4.2.3. Algoritmo Backpropagation.....	19
5.4.3. Lluvias intensas	22
6. Metodología.....	25
6.1. Recopilación de datos	25
6.2. Red de monitoreo de variables climáticas	26
6.2.1. Análisis del riesgo (caracterización de la zona de estudio).....	26
6.2.1.1. Mapa de vulnerabilidad.....	26
6.2.1.2. Mapa de amenazas	31
6.2.1.3. Mapa de riesgo	33

6.2.2.	Diseño de la red de monitoreo de variables climáticas	33
6.3.	Sistema de pronóstico de lluvia a corto plazo.....	35
6.3.1.	Creación de modelo de pronóstico con Redes Neuronales Artificiales	35
6.3.2.	Desarrollo de plataforma digital.....	37
7.	Resultados.....	38
7.1.	Análisis del riesgo (caracterización de la zona de estudio)	38
7.1.1.	Mapa de vulnerabilidad	38
7.1.2.	Mapa de amenazas.....	39
7.1.3.	Mapa de riesgo	44
7.2.	Diseño de la red de monitoreo de variables climáticas.....	45
7.3.	Modelo de pronóstico con Redes Neuronales Artificiales.....	49
7.4.	Plataforma digital.....	58
8.	Conclusiones.....	59
9.	Bibliografía.....	60

Índice de tablas

Tabla 1. Clasificación de la intensidad de lluvia de acuerdo al Sistema Meteorológico Nacional de México.....	23
Tabla 2. Clasificación de la intensidad de lluvia acuerdo al Agencia Estatal de Meteorología de España.....	23
Tabla 3. Clasificación de la intensidad de lluvia acuerdo al Servicio Meteorológico Nacional de los Estados Unidos de América.	24
Tabla 4. Subcriterios utilizados en el Proceso Analítico Jerárquico Difuso.	27
Tabla 5. Criterios de comparación pareada (Saaty, 1980)	27
Tabla 6. Porcentajes máximos para el Ratio de Consistencia (Yepes Piqueras, 2022).	28
Tabla 7. Valores de los índices aleatorios (<i>IA</i>) para las matrices propuestas por Saaty (1980).	28
Tabla 8. Escala de Saaty (1980) y escala triangular difusa Büyüközkan et al. (2004).	29
Tabla 9. Estaciones meteorológicas usadas para la creación del mapa de precipitación media anual	32
Tabla 10. Pesos locales y globales para cada criterio y subcriterio utilizados en el PAJD	38
Tabla 11. Porcentaje de contribución al modelo de los factores predictivos	41
Tabla 12. Parámetros de ajuste para la estructura final utilizada.	53
Tabla 13. Hiperparámetros y características ajustadas para la red neuronal utilizada.	55
Tabla 14. Resultado del ajuste de parámetros de los mejores cinco entrenamientos.	56
Tabla 15. Delimitación de los puntajes para el índice NSE. (Moriasi et al., 2007)	57

Índice de figuras

Figura 1. Esquema de una neurona biológica	16
Figura 2. Mecanismo de transferencia de señales entre dos neuronas biológicas.	16
Figura 3. Interacción de señales de n neuronas y analogía con la suma de señales en una neurona artificial que comprende el perceptrón de una sola capa.	17
Figura 4. Separabilidad lineal vs no lineal	18
Figura 5. Perceptrón multicapa que contiene capas de entrada, oculta, de salida y nodos con enlaces de avance.	18
Figura 6. Indexación y notación generalmente usada en redes BP.	20
Figura 7. Ruta metodológica que se seguirá para crear el sistema de alerta temprana.	25
Figura 8. Ruta metodológica específica para el análisis del riesgo.	26
Figura 9. Matriz de comparación pareada entre los criterios generales que pertenecen a un mismo nivel jerárquico.	27
Figura 10. Matriz de comparación pareada entre los subcriterios que pertenecen al grupo de infraestructura.	27
Figura 11. Entorno de MaxEnt con los datos para analizar los puntos de presencia de inundaciones pluviales y fluviales.	33
Figura 12. Proceso sistemático usado para el diseño de la red de monitoreo de variables climáticas.	34
Figura 13. Procedimiento para la creación del modelo de pronóstico de lluvias con base en una red neuronal artificial.	35
Figura 14. Enlaces y funcionamiento de la plataforma digital.	37
Figura 15. Mapa de vulnerabilidad ante inundaciones de la ciudad de Morelia.	39
Figura 16. Factores predictivos de inundaciones. a) elevación del terreno, b) pendiente del terreno, c) distancia con ríos y canales, d) uso de suelo y e) lluvia media anual.	40
Figura 17. Sitios con registro de inundación en la ciudad de Morelia.	40
Figura 18. Mapa de probabilidad de inundación en la ciudad de Morelia (mapa de amenazas).	41

Figura 19. Curvas de respuesta resultado del modelo MaxEnt.	42
Figura 20. Resultados de validación del modelo MaxEnt mediante la curva AUC-ROC	43
Figura 21. Mapa interactivo de peligros de la ciudad de Morelia. Fuente: IMPLAN https://sigmorelia.gob.mx/	44
Figura 22. Mapa de riesgo ante inundaciones de la ciudad de Morelia.	45
Figura 23. Diagrama de conexiones del circuito impreso desarrollado para la nueva configuración de las EMA's de la red SAIH.	46
Figura 24. Ejemplo de construcción de la Estación Meteorológica Automática.	46
Figura 25. Placas de desarrollo principales usadas en las EMA's de la red SAIH.	47
Figura 26. Sensores usados en las EMA's de la red SAIH.	47
Figura 27. Carcasa de recubrimiento para el sensor DHT22.	48
Figura 28. Comparación de lecturas de temperaturas entre el sensor una estación comercial Davis Instruments y el sensor de una EMA.	48
Figura 29. Plataforma web SAIH para la visualización de datos en tiempo real.	49
Figura 30. Patrón de comportamiento de la variable de precipitación contra las variables de temperatura y humedad relativa.	50
Figura 31. Estructura de datos básica de los datos de entrada y salida usados en el entrenamiento de la red neuronal.	50
Figura 32. Datos de una tormenta de ejemplo con precipitaciones acumuladas en la última hora.	51
Figura 33. Segmentación de la tormenta en muestras individuales para ser ingresadas a la red neuronal.	52
Figura 34. Metodo K-Fold para la evaluación del entrenamiento de una red neuronal.	53
Figura 35. Curva de aprendizaje de la red usando la función de costo del error cuadrático media (MSE) con un ejemplo de overfitting.	55
Figura 36. Curva de aprendizaje de la red usando la función de validación del error absoluto medio (MAE).	55

Figura 37.Comparación gráfica entre las precipitaciones observadas y pronosticadas por la red neuronal.	57
Figura 38.Diagrama de flujo de la plataforma digital para ejecutar los pronósticos y emisión de alerta.....	58

Resumen

En este trabajo se desarrolló un Sistema de Alerta Temprana (SAT) y se evaluó la fiabilidad de sus alertas y la precisión para pronosticar lluvias intensas a corto plazo en la ciudad de Morelia. Se propuso una metodología enfocada en cubrir 3 elementos básicos que componen a un SAT, los cuales son 1) Conocimiento del riesgo, 2) Servicio de vigilancia y alerta y 3) Difusión y Comunicación. Mediante un análisis del riesgo se identificaron las zonas con mayor riesgo de inundaciones, las cuales se relacionan con las lluvias intensas. Se desarrolló una red de monitoreo de variables climáticas en tiempo real, desplegando 12 estaciones meteorológicas automáticas. Además, se creó y evaluó un modelo de pronóstico basado en una red neuronal artificial del tipo MLP cuyas precisiones en los pronósticos se categorizaron como muy buenas de acuerdo a los índices de bondad de ajuste de Nash-Sutcliffe efficiency y Kling-Gupta efficiency obteniendo puntajes de 0.965 y 0.931, respectivamente. Por último, se creó una plataforma digital que procesa los datos capturados por las estaciones meteorológicas automáticas para posteriormente ejecutar el modelo de pronóstico y generar las predicciones de los siguientes 10 minutos de lluvia.

Palabras clave: inundaciones, análisis del riesgo, redes neuronales artificiales, estaciones meteorológicas de bajo costo, Arduino.

Abstract

In this work, an Early Warning System (EWS) was developed and the reliability of its alerts and the accuracy to forecast intense rains in the short term in the city of Morelia were evaluated. A methodology focused on covering 3 basic elements that make up a EWS was proposed, which are 1) Risk Knowledge, 2) Surveillance and Alert Service and 3) Dissemination and Communication. Through a risk analysis, the areas with the highest risk of flooding were identified, which are related to heavy rains. A network for monitoring climate variables in real time was developed, deploying 12 automatic weather stations. In addition, a forecasting model based on an artificial neural network of the MLP type was created and evaluated, whose forecast accuracies were categorized as very good according to the goodness-of-fit indices of Nash-Sutcliffe efficiency and Kling-Gupta efficiency, obtaining scores of 0.965 and 0.931, respectively. Finally, a digital platform was created that processes the data captured by the automatic weather stations to later run the forecast model and generate predictions of the next 10 minutes of rain.

1. Introducción

En la actualidad existen registros del aumento en la frecuencia de los fenómenos hidrometeorológicos extremos, como ondas de calor, sequías prolongadas y lluvias intensas que están ligados al cambio climático global (IPCC, 2013). Los desastres en México originados por eventos hidrometeorológicos, son los desastres que ocurren con mayor frecuencia, que originan mayor número de personas afectadas y son el segundo tipo de desastres que mayor cantidad de víctimas ocasionan (Alcántara-Ayala, 2019), solo después de los sismos.

Los desastres en zonas urbanas relacionados con eventos hidrometeorológicos han tenido diferentes consecuencias a través de los años, sin embargo, en las últimas décadas los impactos de las amenazas naturales han causado innumerables pérdidas humanas, materiales y económicas (Pelling, 2005). Las inundaciones repentinas suelen ser el principal desastre originado por los eventos hidrometeorológicos extremos de las lluvias intensas. Estas inundaciones ocurren minutos después de haberse iniciado una lluvia intensa, cuando el escurrimiento de agua generado no es capaz de ser desalojado por los ríos o sistemas de drenaje de la ciudad (Benzerra et al., 2012).

En las ciudades pequeñas y en desarrollo de Latinoamérica se presentan procesos de modificación del suelo y crecimiento desorganizado del territorio urbano como asentamientos irregulares en los límites de sus ríos, sobre antiguas ciénegas y depresiones topográficas, tal es el caso de la ciudad de Morelia donde han ocurrido inundaciones con daños materiales que han alcanzado los 4 millones de dólares además de afectaciones sociales a la población (Hernández y Vieyra, 2010).

Es evidente que las inundaciones repentinas desencadenadas por lluvias intensas son la principal causa de daños por desastres en la población de México. Es por esto que surge la necesidad de crear mecanismos que mitiguen/disminuyan los daños ocasionados. Es mediante la Gestión del Riesgo de Desastres (GRD) que se busca evitar, disminuir o transferir los efectos adversos de las amenazas mediante diversas actividades y medidas de prevención, mitigación y preparación (ISDR, 2009).

Narváez et al., (2009) definen 6 puntos para llevar a cabo una correcta GRD, siendo en el punto 4 (preparar la respuesta), donde se plantea desarrollar capacidades, instrumentos y mecanismos para pronosticar y responder ante condiciones de emergencia y desastre. Uno de los instrumentos más importantes para la GRD son los Sistemas de Alerta Temprana (SAT) que juegan un rol principal en el pronóstico de amenazas (Basher, 2006).

Según la Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres (UNDRR, 2020), un Sistema de Alerta Temprana es un Sistema integrado de monitoreo, previsión y predicción de amenazas, evaluación del riesgo de desastres, sistemas y procesos de actividades de comunicación y preparación que permite a las personas, comunidades, gobiernos, empresas y otros tomar medidas oportunas para reducir los riesgos de desastres antes de que ocurran eventos peligrosos.

Por otro lado, la Estrategia Internacional para la Reducción del Desastre (ISDR, 2006), establece cuatro elementos básicos para el buen funcionamiento de un SAT; 1) Conocimiento del riesgo, 2) Servicio de vigilancia y alerta, 3) Difusión y Comunicación, y 4) Preparación y Respuesta.

Dicho lo anterior, este trabajo se centra en proponer un SAT para la ciudad de Morelia que pronóstique eventos de lluvias intensas y emita una alerta cuando el pronóstico supere un determinado umbral. Con base en la estructura propuesta para el Sistema de Alerta Temprana ¿Cuál será la fiabilidad del sistema y la precisión de los pronósticos de lluvias intensas que logrará alcanzar el sistema? Con base a la revisión bibliográfica se puede asumir que, con la estructura propuesta para el Sistema de Alerta Temprana, la fiabilidad de las alertas y la precisión de los pronósticos de lluvias intensas cumplirán positivamente con los criterios establecidos para su evaluación.

Este trabajo está dividido en 9 capítulos. Los primeros cuatro capítulos hacen referencia a temas introductorios como lo son 1. Introducción, 2. Justificación, 3. Hipótesis y 4. Objetivos. En el capítulo 5. Marco teórico se abordan algunas definiciones y conceptos básicos como ¿qué es un sistema de alerta temprana? ¿cómo se define el riesgo? ¿qué es una red neuronal? entre otros. En seguida, en el capítulo 6. Metodología se explica al proceso metodológico que se siguió para llegar a desarrollar el SAT. Posteriormente en el capítulo 7. Resultados se describen los resultados más sustanciales del proceso metodológico como lo fueron el análisis del riesgo, la creación del modelo de pronóstico y el desarrollo de la red de monitoreo de variables climáticas. Finalmente, se tienen los capítulos 8. Conclusiones y 9. Bibliografía.

2. Justificación

Es una realidad la necesidad urgente de crear instrumentos para la gestión del riesgo ante eventos meteorológicos en México. Con un Sistema de Alerta Temprana (SAT) se pretende proteger principalmente al sector de la población que se encuentra en zonas de alta vulnerabilidad (Hernández-Guerrero et al., 2012), así como la infraestructura y bienes materiales de la población de la ciudad de Morelia. Además, el monitoreo que ofrecería un SAT puede ser útil en otras áreas como en la gestión del recurso hídrico, en el que se pueden realizar modelos lluvia-escurrimiento en zonas urbanas, revisar la calidad del agua de la precipitación, entre otros.

3. Hipótesis

Un Sistema de Alerta Temprana para el pronóstico de lluvias intensas tendrá la precisión suficiente al usar una red neuronal artificial como modelo de predicción y datos en tiempo real de una red de monitoreo de variables climáticas.

4. Objetivos

4.1. Objetivo General

Desarrollar un Sistema de Alerta Temprana y evaluar la fiabilidad de sus alertas y la precisión para pronosticar lluvias intensas a corto plazo en la ciudad de Morelia.

4.2. Objetivos específicos

1. Desarrollar e instalar un conjunto de estaciones meteorológicas de bajo costo para elaborar una red de monitoreo de variables climáticas en tiempo real.
2. Producir un mapa de riesgo de inundaciones con la finalidad de zonificar las emisiones de las alertas además de conocer la influencia de las estaciones meteorológicas sobre las zonas de mayor riesgo.
3. Implementar un modelo de predicción para el pronóstico de lluvias intensas a corto plazo.
4. Diseñar una plataforma digital que permita la difusión de alertas ante un evento de lluvias intensas.

5. Marco teórico

5.1. Gestión del Riesgo de Desastre

El concepto de riesgo en su sentido más amplio está ligado a la existencia humana en esta Tierra, es decir, no existiría la necesidad de analizar el riesgo sin un conjunto de individuos en los cuales pueda recaer. Cuando se hace referencia específicamente a desastres naturales, condiciones o circunstancias sociales en las que la sociedad se haya visto afectada significativamente por la influencia de eventos físicos de diversos orígenes, tales como terremotos, huracanes, inundaciones o explosiones, con consecuencias que perturban la vida cotidiana y su normal funcionamiento nos encontramos ante el concepto de “riesgo de desastre” (Narváez et al., 2009).

Ahora bien, a las acciones y decisiones para minimizar las pérdidas por desastres se les conoce como Gestión del Riesgo de Desastres (GRD). De acuerdo a The International Strategy for Disaster Reduction (ISDR, 2009), “la gestión del riesgo de desastres busca evitar, disminuir o transferir los efectos adversos de las amenazas mediante diversas actividades y medidas de prevención, mitigación y preparación”.

Las acciones de gestión del riesgo de desastres se dividen comúnmente en los diferentes pasos del ciclo de gestión de desastres, que incluyen: prevención, para minimizar pérdidas futuras; preparación y gestión de crisis, a menudo centrada en salvar vidas; y la gestión posterior a las crisis con el fin de restablecer los servicios de apoyo a las actividades humanas (Le Cozannet et al., 2020).

Cuando hablamos de las características del riesgo estamos hablando no solo de una incidencia de la naturaleza y la distribución social del daño, sino que incluye también el desafío social para dar una respuesta luego de un desastre y la implementación de las modalidades de reconstrucción. Una clave para la reducción del riesgo se encuentra en el entendimiento del riesgo, en la educación acerca de él, y en la participación decidida y comprometida de los actores sociales, privados y públicos para su resolución (Lavell, 1999).

Narváez et al., (2009) definen 6 puntos para llevar a cabo una correcta GRD, siendo en el punto 4 (preparar la respuesta), donde se plantea desarrollar capacidades, instrumentos y mecanismos para pronosticar y responder ante condiciones de emergencia y desastre. Uno de los componentes más importantes para la GRD son los Sistemas de Alerta Temprana (SAT) que juegan un rol principal en la previsión de amenazas (Basher, 2006).

5.2. Componentes básicas del Riesgo

5.2.1. Desastres

Comprender los mal llamados desastres naturales, cómo prevenirlos y recuperarse de ellos cuando ocurren requiere deshacerse de una serie de conceptos erróneos que nos confunden y nos impiden hacer lo correcto.

Todavía existe el "pensamiento mágico" sobre los eventos causados por fuerzas naturales, cuyo objetivo es elevar la causa de los desastres a un nivel por encima de las causas humanas (generalmente Dios), lo que hace imposible que se encuentren causas racionales para estos desastres. Este concepto en la actualidad ha comenzado a desaparecer, pero ha dado paso a otro tipo de conceptos erróneos que vinculan la causa de los desastres a algún mal comportamiento de la naturaleza, supliendo así el dicho "castigo de Dios" por "castigo de la naturaleza".

Otra parte de esta distorsión conceptual es la superposición de dos términos muy diferentes, "fenómeno natural" y "desastre natural", que a menudo se utilizan como sinónimos. Está claro que no son lo mismo. Incluso si es el primero, no implica el segundo.

Entonces, ¿qué es un fenómeno natural? Es pues, una manifestación de la naturaleza. Se refiere a cualquier expresión que adopta ésta como resultado de su funcionamiento interno, que tiene ciertos atributos de regularidad o que tiene una apariencia inusual y sorprendente. Entre los más comunes tenemos los eventos meteorológicos como las lluvias, granizadas y nevadas o hasta los menos comunes, pero más dañinos como los tsunamis, huracanes y sismos. Es importante señalar que un fenómeno natural no necesariamente tiene que representar un riesgo para el humano.

Por otro lado, un desastre natural es la correlación entre fenómenos naturales peligrosos (como un sismo, huracán o tsunami) y determinadas condiciones socioeconómicas y físicas vulnerables (como situación económica precaria, viviendas mal construidas, tipo de suelo inestable, mala ubicación de la vivienda, etc.). En otras palabras, puede decirse que hay un alto riesgo de desastre si uno o más fenómenos naturales peligrosos ocurrieran en situaciones vulnerables (Romero, Gilberto; Maskrey, 1993).

5.2.2. Riesgo

Encontrar el riesgo de desastre implica encontrar las amenazas relevantes y el grado de vulnerabilidad de las personas y la sociedad que se encuentran en peligro (ISDR, 2006).

Según Jeréz-Ramírez (2014), las definiciones de riesgo usualmente aceptadas son entendidas sobre la base de un esquema lógico que indica la relación entre un suceso dañino y unas víctimas afectadas, relación que proviene de una fórmula muy usada que señala al evento agresor como la amenaza (A), y la susceptibilidad o tendencia de la población a sufrir el impacto, es decir, la vulnerabilidad (V). De allí que se calcule el riesgo como: $\text{Riesgo} = \text{Amenaza} \times \text{Vulnerabilidad}$ o $\text{Riesgo} = \text{Amenaza} + \text{Vulnerabilidad}$.

Esta definición contempla únicamente elementos matemáticos, señalando a las amenazas y las vulnerabilidades como factores que solo se suman o se multiplican. Por otro lado, Caram y Pérez (2006), toman en cuenta cuatro elementos que explican la complejidad del riesgo, visibles analíticamente, pero vinculados entre sí, estos son:

1. La peligrosidad, que no es más que el potencial de amenaza de cualquier fenómeno natural adverso, por ello, mientras más información se tenga sobre este, mayores

posibilidades hay de predecir su ocurrencia en aquellos casos donde la predicción es posible.

2. La exposición, que hace mención a las construcciones materiales y a la distribución de la población, puesta de manifiesto en las precarias edificaciones, carencia de servicios, construcción en áreas inestables, que en conjunto constituyen la combinación de elementos materiales, infraestructura y población potencialmente afectadas ante un evento adverso.
3. La vulnerabilidad, definida como la situación en la que se encuentra la población, características o atributos existentes en la misma, que le permiten o le imposibilitan enfrentar un imprevisto fenómeno natural; y finalmente,
4. La incertidumbre ante esos eventos, que impone la necesidad de involucrar en la toma de decisiones a quienes están o estarán expuestos al peligro, haciéndose necesario el conocimiento de las percepciones del riesgo de los actores sociales.

La amenaza, la vulnerabilidad y el riesgo son factores socialmente construidos, ya que los eventos físicos extremos asociados con procesos naturales pueden transformarse en amenazas, solamente por intermediación humana; lo mismo ocurre con la vulnerabilidad, su aumento o disminución dependerá de las conductas individuales y colectivas (Lavell, 2002).

Por lo tanto, si se desea estimar el riesgo, es necesario realizar una evaluación de la amenaza natural ya sea predecible o no; y respecto a la vulnerabilidad, debe expresarse en términos técnicos, que son fácilmente cuantificables, en términos físicos y funcionales (infraestructura, líneas de vida, por ejemplo) y aquellos de carácter social, aún más importante, que deben valorarse en términos cualitativos, mucho más complejos en función del contexto social y cultural (Reyes Rivero et al., 2017).

En este trabajo el objeto principal de análisis son las lluvias intensas, por lo que el fenómeno natural de las lluvias sería la amenaza relacionada al riesgo, sin embargo, un evento de lluvia intensa no representa por sí solo una amenaza directa sobre la población, en este caso el riesgo se tendría que relacionar con los efectos ocasionados por las lluvias intensas, los cuales son las inundaciones repentinas.

El riesgo por inundación está directamente relacionado con la amenaza natural de las lluvias intensas que cada vez son más frecuentes debido al cambio climático. En general, estas son el resultado de una intensificación del ciclo hidrológico y un incremento de las actividades humanas que, a su vez, ocasionan cambios en el medio ambiente (Trenberth, 2011; Hirabayashi et al., 2013).

Los sistemas de drenaje deficientes, la baja capacidad de almacenamiento e infiltración durante las tormentas, la falta de mantenimiento y el crecimiento urbano heterogéneo son las principales razones de las inundaciones en las zonas urbanas (Darabi et al., 2019).

El mapeo del riesgo de inundación urbana desempeña un papel decisivo en la gestión y planificación urbanas, especialmente en la reducción de los daños causados por las inundaciones. El mapeo del riesgo y la predicción de la ubicación de las áreas propensas a

las inundaciones utilizando mapas de riesgo de inundación pueden mitigar los efectos de las inundaciones en las áreas urbanas y se pueden usar para la planificación urbana.

Trabajos como el de Eini et al. (2020), donde se elaboró un mapa de riesgo de inundación para la ciudad de Kermanshah (Irán) en función de la combinación de mapas de peligro de inundación y vulnerabilidad a las inundaciones, han sido útiles para zonificar el nivel de riesgo y conocer las vulnerabilidades de esa población a las inundaciones.

5.2.3. Vulnerabilidad

Existen numerosas definiciones de la vulnerabilidad como la de Lavell (1999) que define la vulnerabilidad como la tendencia de la sociedad a recibir daño y a la medida de dificultad de recuperación de las consecuencias, que están relacionadas estrechamente con las modalidades de desarrollo que tenga la sociedad. Briones-Gamboa (2007) la define como la imposibilidad de un grupo social para responder a cambios por efectos de un evento adverso, ya sea por su incapacidad, su estado de exposición o su susceptibilidad. Reyes Rivero et al. (2017) menciona que la vulnerabilidad comprende el factor interno que va a depender de las condiciones que cada región posea para enfrentar ese factor externo (amenaza), dichas condiciones serán mayor o menor en medida que existan debilidades de carácter social, económico y estructural, entre otros, capaces de ocasionar daños cuantiosos e irreparables en algunos casos.

A pesar de la mejora de los métodos utilizados en la cartografía de peligros de inundación, el conocimiento de la vulnerabilidad sigue siendo uno de los desafíos más importantes en la evaluación del riesgo de inundación (Nasiri et al., 2016).

La medición de la vulnerabilidad es un proceso complejo en el caso de la identificación de áreas vulnerables porque la vulnerabilidad se ve afectada por varios factores como las condiciones socioeconómicas de la comunidad, la política de autoridad urbana y las capacidades, la infraestructura, las condiciones de los asentamientos humanos, etc. Estos factores se abordan de diferentes maneras, dependiendo de la cultura de la sociedad frente a las amenazas, las actividades humanas y las condiciones ambientales, por lo que varían de un lugar a otro (Ahmad & Simonovic, 2013).

Karmakar et al. (2010) definieron cuatro criterios para abordar la vulnerabilidad a las inundaciones urbanas que incluyen infraestructura (carreteras, escuelas, hospitales, estaciones de bomberos), económica (estructura e historia de los edificios), social (edad, estructura familiar, acceso a los recursos, estatus socioeconómico de las comunidades) y física (enfermedades ambientales como los humedales).

Darabi et al. (2019); Koks et al. (2015); Sadeghi-Pouya et al. (2017) utilizaron solo dos criterios para el mapeo de la vulnerabilidad a las inundaciones, que son económicos y sociales, aunque los subcriterios son diferentes en cada estudio. Los subcriterios están limitados por la disponibilidad de datos y las especificidades urbanas, como las creencias y costumbres, la educación, la población inmigrante/minoritaria, la población arrendataria y

la densidad de población que pueden considerarse en el elemento social (Zachos et al., 2016).

Existe una variedad de métodos de evaluación de la vulnerabilidad, difieren en su definición de vulnerabilidad, marco teórico, variables y metodología. Los métodos de evaluación pueden clasificarse en 5 grupos (Nasiri et al., 2016):

1) Métodos de indicadores de vulnerabilidad

Se adoptó para usar datos disponibles para proporcionar una imagen lógica de la vulnerabilidad del lugar. Este método se usa en estudios de vulnerabilidad a las inundaciones y depende de índices complejos con y sin ponderaciones. Existen dos enfoques, basados en la teoría (deductivos) y basados en datos (inductivos) para la selección de indicadores en este método (Füssel, 2010). El enfoque deductivo se basa en un marco teórico para seleccionar indicadores apropiados y considerar su relación, en tanto que el enfoque inductivo selecciona indicadores relacionados con un vínculo estadístico.

2) Método de la curva de vulnerabilidad

En este método se emplean curvas empíricas de daño o fragilidad para relacionar el riesgo de inundación y sus elementos. Se basa esencialmente en datos de estudios de casos bien documentados de daños reales, por lo que se limita únicamente a viviendas en áreas específicas, requiere mucho tiempo y recursos, la confiabilidad de este método es menor que la de los otros métodos ya que no es aplicable en otras regiones.

3) Método de datos de pérdida por desastre

Estos métodos están basados en la recopilación de datos de peligros de inundaciones reales y su uso para futuros eventos. El método es un enfoque simple, pero es poco inexacto y debido a los datos registrados de manera desigual, el resultado de estos métodos debe ser tratado con cuidado.

4) Métodos de modelado

Estos modelos pueden evaluar la profundidad, elevación y velocidad de las inundaciones utilizando la frecuencia, magnitud y forma del hidrograma. Existen modelos de una o dos dimensiones basadas en soluciones de las formas completas o aproximadas de las ecuaciones del agua superficial. Estos métodos dependen de datos detallados sobre información topográfica, hidrográfica y económica de la región en estudio. Estas modelaciones pueden evaluar la vulnerabilidad a nivel local de manera más sensible porque considera factores locales específicos, sin embargo, no puede describir un vínculo muy claro entre el mapa pronosticado y el nivel real de daño por inundación. La desventaja de este método es que en condiciones de escasez de datos su validez es baja.

5) Métodos con criterio de ponderación

Basados en un proceso de selección de variables relacionadas con la vulnerabilidad de las zonas que han sido afectadas por las inundaciones y en posterior análisis de estas variables

con una metodología de soporte a la decisión como lo es el Proceso Analítico Jerárquico Difuso (PAJD) (Chang, 1996).

Eini et al. (2020) propuso determinar la vulnerabilidad en función de factores socio-económicos y de infraestructura que mediante un PAJD que suele ser efectivo en países en desarrollo. Mediante este PAJD obtuvo un vector de ponderación que representaba el grado de importancia que se le dio a cada uno de los factores analizados.

El PAJD considera un conjunto de objetos $X = \{x_1, x_2, x_3, \dots, x_n\}$ y otro conjunto $U = \{u_1, u_2, u_3, \dots, u_n\}$ que se desarrolla el análisis ampliado para cada uno de los valores de los objetos; de esta manera se obtienen para cada objetivo g_i y los valores del análisis extendido de m se pueden obtener con la siguiente notación:

$$M^1_{g_i}, M^2_{g_i}, \dots, M^m_{g_i} \quad (i = 1, 2, 3, \dots, n)$$

5.2.4. Amenaza

Otro componente de la evaluación del riesgo de inundación es la producción de mapas de inundaciones urbanas y la predicción de áreas propensas a inundaciones. Se han desarrollado modelos físicos para el mapeo de susceptibilidad a los peligros, por ejemplo, Technical Release 55 (TR-55) (Usda, 1986), Hydrologic Engineering Center-River Analysis System (HEC-RAS) y Urban Flood Cell Model (MODCEL), que se basan en datos hidrológicos e hidráulicos detallados. Es un desafío aplicar estos modelos donde la disponibilidad de datos sigue siendo un problema importante. La computación blanda, el aprendizaje automático, por ejemplo, la máquina de vectores de soporte (Yan et al., 2018), el bosque aleatorio (Feng et al., 2015), la red neuronal artificial (Berkhahn et al., 2019), la producción de conjuntos de reglas de algoritmos genéticos (GARP) (Darabi et al., 2019) y los métodos estadísticos, por ejemplo, los enfoques estadísticos bivariados y multivariantes (Youssef et al., 2016) son adecuados para aplicar en estas regiones, especialmente para los países en desarrollo.

Eini et al. (2020) utiliza dos técnicas de aprendizaje automático, el modelo de Máxima Entropía (MaxEnt) y Algoritmos Genéticos para la Producción de Reglas (GARP) para generar mapas de susceptibilidad de inundaciones, llegando a la conclusión de que MaxEnt es más idóneo para condiciones en países en desarrollo.

La base de MaxEnt es la teoría de la entropía, que significa desorden. De hecho, la entropía en procesos aleatorios es una medida de incertidumbre que refleja indirectamente las características temporales y espaciales del proceso. El Modelo de Máxima Entropía a menudo se aplica bien en contextos ecológicos, geografía urbana y redes arqueológicas y Modelado de Escorrentía-Lluvia, diseño de redes de monitoreo de la calidad del agua, localización de pluviómetros y redes de estaciones hidrométricas (Ridolfi et al., 2011).

MaxEnt es un modelo práctico porque la entropía máxima da la estimación menos sesgada posible sobre los datos dados en el caso de caracterizar eventos desconocidos con un modelo estadístico. La distribución de probabilidad con entropía máxima se aproxima para

estimar la idoneidad de cada cuadrícula, que está sujeta a restricciones derivadas del valor de los parámetros ambientales en las presencias observadas.

Los valores de los datos ambientales brutos se definen como limitaciones en términos de características. Cuando las entidades de entrada son variables continuas, MaxEnt utiliza transformaciones (es decir, vectores de entidades) de las variables. Para mejorar el ajuste del modelo a los datos, los vectores de características se consideran en el modelo MaxEnt. Los usuarios pueden elegir la opción de función automática para encontrar la combinación óptima de entidad y vector en función del tamaño de la muestra del conjunto de datos de entrada (Phillips et al., 2006; Phillips y Dudík, 2008).

5.3.Sistemas de Alerta Temprana

5.3.1. Definiciones

1) *Alerta*

De acuerdo con Lavell (2000), se define como el estado que se declara, con anterioridad a la manifestación de un fenómeno peligroso, con el fin de que los organismos operativos de emergencia activen procedimientos de acción preestablecidos y para que la población tome precauciones específicas debido a la inminente ocurrencia del evento previsible

2) *Sistema de Alerta Temprana*

Según la Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres (UNDRR, 2020), un SAT es un Sistema integrado de monitoreo, previsión y predicción de amenazas, evaluación del riesgo de desastres, sistemas y procesos de actividades de comunicación y preparación que permite a las personas, comunidades, gobiernos, empresas y otros, tomar medidas oportunas para reducir los riesgos antes de que ocurran eventos peligrosos.

Un SAT es un elemento clave para la Gestión del Riesgo de Desastres hidrometeorológicos extremos, deslizamientos de masas de tierra, sismos y hasta tsunamis. Tanto una alerta temprana y como una respuesta oportuna desempeñan un papel importante en la reducción de la vulnerabilidad y la mortalidad causadas por los desastres y en la mejora de la resiliencia de las comunidades (Seng, 2012).

5.3.2. Elementos de un SAT

Aunque no existe un consenso sobre los elementos de un SAT, la ISDR (2006) especifica cuatro elementos para un sistema completo y eficaz, los cuales se interactúan entre sí:

- 1) *Conocimiento del riesgo*: conocimiento de los peligros relevantes y de las vulnerabilidades de las personas y la sociedad a estos peligros.
- 2) *Servicio de vigilancia y alerta*: capacidad técnica para vigilar los precursores de peligro, pronosticar la evolución del peligro y emitir advertencias.

- 3) *Difusión y comunicación*: difusión de advertencias comprensibles e información previa sobre la preparación a las personas en situación de riesgo.
- 4) *Capacidad de respuesta*: conocimientos, planes y capacidades para la acción oportuna y apropiada de las autoridades y las personas en riesgo.

El segundo elemento, el servicio de vigilancia y alerta, es la parte más reconocida del sistema de alerta temprana, pero la experiencia ha demostrado que las predicciones técnicamente de alta calidad por sí solas son insuficientes para lograr la reducción deseada de las pérdidas y los impactos (Basher, 2006).

Existen numerosas aplicaciones de un SAT, por ejemplo, en México se desarrolló el SASMEX (Espinosa-Aranda et al., 2009), que desde 1991 se ha encargado de monitorear y emitir alertas ante eventos sísmicos. Ahmed et al. (2018) desarrollaron un SAT para deslizamientos de tierras basado en una Web-GIS para el Área Metropolitana de Chittagong, Bangladesh. Ramón-Valencia et al. (2019) diseñaron y aplicaron un Sistema de Alerta Temprana para eventos climáticos al norte de Santander en Colombia usando una red de monitoreo y pronósticos basados en métodos numéricos WRF y GFS.

Las aplicaciones anteriores se basan en enfoques simples o multi amenaza que se desarrollaron en diferentes niveles. The United Nations Office for Disaster Risk Reduction (UNDRR), ha propuesto una plataforma de cuatro elementos que incluye conocimientos de riesgos, monitoreo, difusión de advertencias y respuesta. También hay modelos de tres fases tradicionales como el propuesto por Villagrán de León et al. (2006), o modelos integrados como el de Basher (2006). Sin embargo, cada uno de estos modelos tiene fortalezas y debilidades y no hay consenso sobre los modelos y sus elementos esenciales.

Algunos modelos se centran en la identificación de riesgos y la toma de decisiones, y otros se centran en la advertencia y la respuesta, y rara vez hay un modelo que incluya todos los elementos necesarios (Waidyanatha, 2010).

Si bien este conjunto de elementos parece tener una secuencia lógica, de hecho, cada elemento tiene vínculos bidireccionales directos e interacciones con cada uno de los otros elementos.

5.4.Pronóstico de lluvias

Una tarea difícil para la gestión de las cuencas hidrográficas y la gestión de las inundaciones en particular es la elaboración de un pronóstico cuantitativo de las precipitaciones. Las previsiones precisas de la distribución espacial y temporal de las precipitaciones son útiles tanto para la gestión de la cantidad como de la calidad del agua. Por ejemplo, un sistema de advertencia de inundaciones para cuencas de respuesta rápida puede requerir un pronóstico cuantitativo de lluvia para aumentar el tiempo de advertencia. Del mismo modo, un pronóstico de lluvia proporciona información anticipada para muchos problemas de calidad del agua (Luk et al., 2001).

5.4.1. Métodos para el pronóstico de lluvias

Existen dos enfoques posibles para pronosticar las precipitaciones. El primer enfoque implica el estudio de los procesos de lluvia con el fin de modelar las leyes físicas subyacentes. Sin embargo, este enfoque de modelado de procesos basado en la física puede no ser factible porque:

- 1) La lluvia es un producto final de una serie de procesos atmosféricos complejos que varían tanto en el espacio como en el tiempo.
- 2) Incluso si los procesos de lluvia se pueden describir de manera concisa y completa, el volumen de cálculos involucrados puede ser prohibitivo.
- 3) Los datos disponibles para ayudar en la definición de variables de control para los modelos de proceso, como la intensidad de la lluvia, la velocidad del viento y la evaporación, etc., están limitados tanto en las dimensiones espaciales como temporales.

Un segundo enfoque para pronosticar la lluvia se basa en la metodología de reconocimiento de patrones, que intenta reconocer los patrones de lluvia, en función de sus características. La lógica detrás de este enfoque es descubrir características espaciales y temporales relevantes en los patrones históricos de lluvia y usarlas para predecir la evolución de otras tormentas. Resulta que este enfoque es ampliamente utilizado por su simplicidad en los requerimientos para alimentar el modelo (Luk et al., 2001).

Recientemente, se han utilizado técnicas de aprendizaje automático para pronosticar la lluvia en el campo del reconocimiento de patrones y la inteligencia artificial. Existen los clasificadores que se pueden utilizar en la clasificación de lluvia/no lluvia (Liu et al., 2001; Meyer et al., 2015) o la predicción de fuertes lluvias (Lee et al., 2012), y las funciones de regresión se pueden utilizar para predecir la cantidad de precipitación (Hong, 2008; Valverde Ramírez et al., 2005) y para detectar anomalías en los datos meteorológicos (Kashiwao et al., 2017).

Las Redes Neuronales Artificiales (RNAs) se ha utilizado con frecuencia en los países del hemisferio norte con fines de pronóstico, reconocimiento y clasificación de muchos fenómenos meteorológicos (Cavazos, 1997; Hsu et al., 1997; Marzbam & Stumpf, 1996). En cuanto a las aplicaciones prácticas, las RNA también se han utilizado en la predicción de precipitaciones a corto plazo. Hall (1999) utilizó una serie temporal de 2 años del modelo ETA de los Centros Nacionales de Predicción Ambiental (NCEP) y sondeos de aire superior como entrada de la RNA para pronosticar las precipitaciones en Dallas, Texas.

Otra aplicación es descrita por Kuligowski y Barros (1998), quienes utilizaron como predictores los campos de salida del Modelo de Cuadrícula Anidada (NGM) NCEP y como predicción de datos de lluvia del Archivo Nacional del Centro de Datos Climáticos, para producir pronósticos de lluvia de 6 horas en dos cuencas de drenaje en Pensilvania. El conjunto de datos tuvo una duración de 5 años, desde diciembre de 1987 hasta noviembre de 1992. También mostraron que el rendimiento de la RNA fue superior al de un modelo de regresión multilínea al menos para eventos de lluvias intensas. Koizumi (1999) empleó una RNA usando radar, datos satelitales y de estaciones meteorológicas junto con productos

numéricos generados por el Modelo Espectral Asiático de la Agencia Meteorológica de Japón (JMA) para datos de entrenamiento de 1 año, y encontraron que las habilidades de la RNA eran mejores que las de los modelos de pronóstico.

Applequist et al. (2002) compararon cinco técnicas diferentes (RNA, regresión lineal, análisis discriminante, regresión logística y un sistema de clasificación) para los pronósticos de lluvia. Utilizaron variables meteorológicas generadas por el NCEP NGM para el entrenamiento en áreas centrales y orientales de los Estados Unidos. El modelo de regresión logística en su estudio tuvo el mejor desempeño.

5.4.2. Redes Neuronales Artificiales

Las redes neuronales artificiales (RNAs) son técnicas de modelado computacional que aparecieron recientemente y han encontrado una amplia aplicación en muchas disciplinas para resolver problemas complejos del mundo real. Las RNAs pueden definirse como estructuras compuestas por elementos de procesamiento simples adaptativos densamente interconectados (llamados neuronas o nodos artificiales) que son capaces de realizar cálculos masivos en paralelo para el procesamiento de datos y la representación del conocimiento (Hecht-Nielsen, 1990; Schalkoff, 1997).

Los modelos artificiales que poseen tales características son deseables porque (i) la no linealidad permite un mejor ajuste a los datos, (ii) la insensibilidad al ruido proporciona una predicción precisa en presencia de datos inciertos y errores de medición, (iii) el alto paralelismo implica un procesamiento rápido y tolerancia a fallas de hardware, (iv) el aprendizaje y la adaptabilidad permiten que el sistema actualice (modifique) su estructura interna en respuesta al entorno cambiante, y v) la generalización permite la aplicación del modelo a datos no aprendidos. El objetivo principal de la computación basada en RNAs (neuro-computación) es desarrollar algoritmos matemáticos que permitan a las RNAs aprender imitando el procesamiento de la información y la adquisición de conocimiento en el cerebro humano (Basheer y Hajmeer, 2000).

Aunque las RNAs son abstracciones drásticas de las contrapartes biológicas, la idea de las RNAs no es replicar el funcionamiento de los sistemas biológicos sino hacer uso de lo que se sabe sobre la funcionalidad de las redes biológicas para resolver problemas complejos. Lo atractivo de las RNA proviene de las notables características de procesamiento de información del sistema biológico, como la no linealidad, el alto paralelismo, la robustez, la tolerancia a fallas, el aprendizaje, la capacidad de manejar información imprecisa y difusa, y su capacidad de generalizar (Jain et al., 1996).

5.4.2.1. Neurona biológica y neurona artificial

El sistema nervioso humano consiste en miles de millones de neuronas de varios tipos y longitudes relevantes para su ubicación en el cuerpo (Schalkoff, 1997). La Figura 1 muestra un esquema de una neurona biológica simplificada con tres unidades funcionales principales: dendritas, cuerpo celular y axón. El cuerpo celular tiene un núcleo que contiene

información sobre los rasgos hereditarios, y un plasma que contiene el equipo molecular utilizado para producir el material que necesita la neurona (Jain et al., 1996). Las dendritas reciben señales de otras neuronas y las pasan al cuerpo celular. El área receptora total de las dendritas de una neurona típica es de aproximadamente 0,25 mm² (Zupan y Gasteiger, 1993).

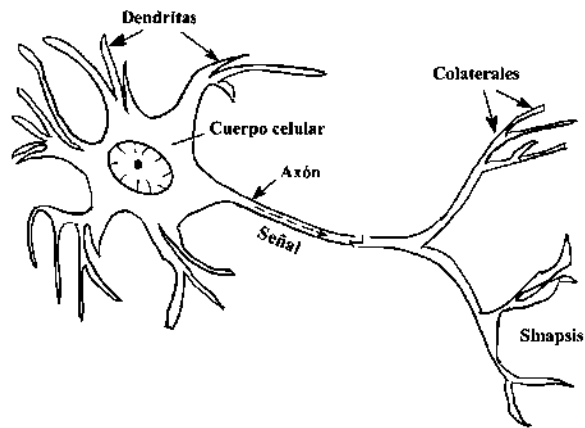


Figura 1. Esquema de una neurona biológica (Basheer y Hajmeer, 2000)

El axón, que se ramifica en colaterales, recibe señales del cuerpo celular y las lleva a través de la sinapsis (una brecha microscópica) a las dendritas de las neuronas vecinas. Una ilustración esquemática de la transferencia de señal entre dos neuronas a través de la sinapsis se muestra en la Figura 2. Un impulso, en forma de señal eléctrica, viaja dentro de las dendritas y a través del cuerpo celular hacia la membrana presináptica de la sinapsis a la llegada a la membrana de la sinapsis. Al llegar a la membrana, se libera un neurotransmisor (químico) de las vesículas en cantidades proporcionales a la fuerza de la señal entrante. El neurotransmisor se difunde dentro de la brecha sináptica hacia la membrana postsináptica y, finalmente, hacia las dendritas de las neuronas vecinas, obligándolas así (dependiendo del umbral de la neurona receptora) a generar una nueva señal eléctrica. La señal generada pasa a través de la(s) segunda(s) neurona(s) de una manera idéntica a la que acabamos de describir.

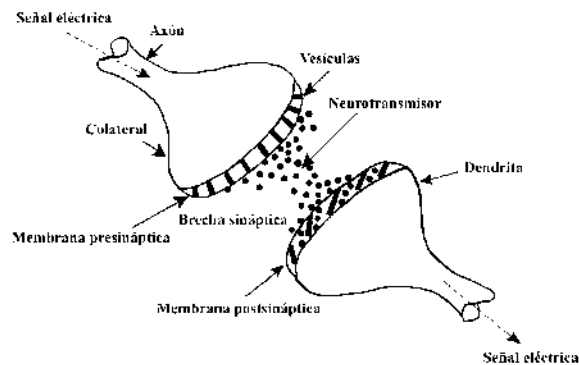


Figura 2. Mecanismo de transferencia de señales entre dos neuronas biológicas.(Basheer y Hajmeer, 2000)

La cantidad de señal que pasa a través de una neurona receptora depende de las neuronas que se alimentan, sus fuerzas sinápticas y el umbral de la neurona receptora. Debido a que una neurona tiene un gran número de dendritas / sinapsis, puede recibir y transferir muchas señales simultáneamente. Estas señales pueden ayudar (excitar) o inhibir el disparo de la neurona. Este mecanismo simplificado de transferencia de señal constituyó el paso fundamental del desarrollo temprano de la neuro computación (por ejemplo, la unidad de umbral binario de McCulloch y Pitts, 1943) y el funcionamiento de la unidad de construcción de las RNA.

La cruda analogía entre la neurona artificial y la neurona biológica es que las conexiones entre los nodos representan los axones y las dendritas, los pesos de conexión representan las sinapsis y el umbral se aproxima a la actividad en el soma (Jain et al., 1996). La Figura 3 ilustra n neuronas biológicas con varias señales de intensidad x y fuerza sináptica w alimentando a una neurona con un umbral de b , y el sistema de neuronas artificiales equivalente. Tanto la red biológica como la RNA aprenden ajustando gradualmente las magnitudes de los pesos o las fortalezas de las sinapsis (Zupan y Gasteiger, 1993).




Figura 3. Interacción de señales de n neuronas y analogía con la suma de señales en una neurona artificial que comprende el perceptrón de una sola capa (Basheer y Hajmeer, 2000)

5.4.2.2. Perceptrón

El perceptrón (Figura 3) puede ser entrenado sobre un conjunto de ejemplos utilizando una regla de aprendizaje especial (Hecht-Nielsen, 1990). Los pesos del perceptrón (incluido el umbral) se cambian en proporción a la diferencia (error) entre esa salida objetivo (correcta), Y , y la solución de perceptrón, y , para cada ejemplo. El error es una función de todos los pesos y forma un hiperplano complejo multidimensional irregular con muchos picos, puntos de silla y mínimos. Utilizando una técnica de búsqueda especializada, el proceso de aprendizaje se esfuerza por obtener el conjunto de ponderaciones que corresponde al mínimo global. Rosenblatt (1962) derivó la regla del perceptrón que producirá un vector de

peso óptimo en un número finito de iteraciones, independientemente de los valores iniciales de los pesos. Estas reglas, sin embargo, solo pueden funcionar con precisión con clases linealmente separables (Hecht-Nielsen, 1990), en las que un hiperplano lineal puede colocar una clase de objetos en un lado del plano y la otra clase en el otro lado. La Figura 4 muestra problemas de clasificación de dos objetos lineales y no lineales.

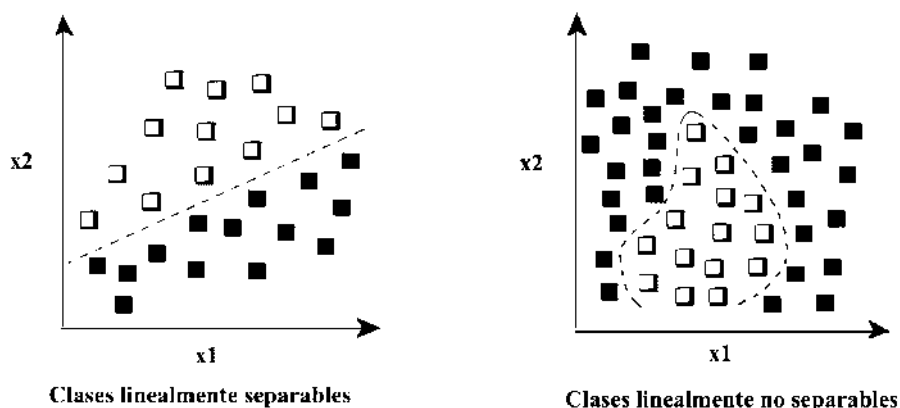


Figura 4. Separabilidad lineal vs no lineal (Basheer y Hajmeer, 2000)

Para hacer frente a problemas no separables, se necesitan capas adicionales de neuronas colocadas entre la capa de entrada (que contiene nodos de entrada) y la neurona de salida que conducen a la arquitectura del perceptrón multicapa (MLP) (Hecht-Nielsen, 1990), como se muestra en la Figura 5. Debido a que estas capas intermedias no interactúan con el entorno externo, se denominan capas ocultas y sus capas de nodos revivieron el perceptrón al extender su capacidad para resolver problemas de clasificación no lineal. Utilizando una dinámica neuronal similar, las neuronas ocultas procesan la información recibida de los nodos de entrada y los pasan a la capa de salida. El aprendizaje del MLP no es tan directo como el del perceptrón simple. Por ejemplo, la red Backpropagation (retro propagación) (Rumelhart et al., 1986) es un tipo de MLP entrenada por la regla de aprendizaje delta (Zupan y Gasteiger, 1993). Sin embargo, el procedimiento de aprendizaje es una extensión del algoritmo del perceptrón simple para manejar los pesos conectados a los nodos ocultos (Hecht-Nielsen, 1990).

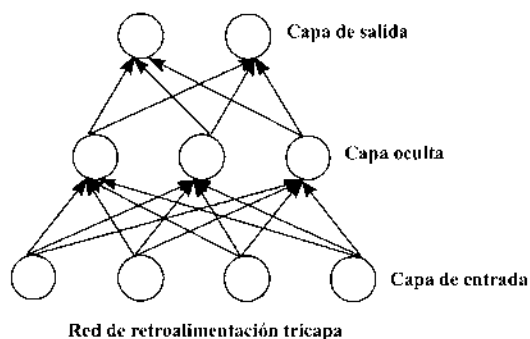


Figura 5. Perceptrón multicapa que contiene capas de entrada, oculta, de salida y nodos con enlaces de avance (Basheer y Hajmeer, 2000)

5.4.2.3. Algoritmo Backpropagation

Para ampliar la comprensión de las RNAs es imperativo familiarizarse con el cálculo y el diseño de una RNA. Para este objetivo, las Redes Neuronales Artificiales BackPropagation (RNABP) se discuten con más detalle, por su popularidad y su flexibilidad y adaptabilidad en el modelado de un amplio espectro de problemas en muchas áreas de aplicación.

El algoritmo de aprendizaje BackPropagation (BP) es el procedimiento más famoso para entrenar RNAs. El algoritmo se basa en la búsqueda de una superficie de error (error en función de los pesos de la RNA) utilizando el descenso de gradiente para puntos con un error mínimo. Cada iteración del algoritmo constituye dos barridos: activación hacia adelante para producir una solución, y una propagación hacia atrás del error calculado para modificar los pesos. En una RNA inicializada (es decir, una RNA con pesos iniciales asumidos), el barrido hacia adelante implica presentar la red con un ejemplo de entrenamiento. Esto comienza en la capa de entrada donde cada nodo de entrada transmite el valor recibido hacia adelante a cada nodo oculto en la capa oculta. El efecto colectivo en cada uno de los nodos ocultos se resume realizando el producto de puntos de todos los valores de los nodos de entrada y sus correspondientes pesos de interconexión, como se describe en la Ecuación (1).

$$y = \begin{cases} 1, & \text{if } \sum_{i=1}^n w_i x_i \geq b, \\ 0, & \text{if } \sum_{i=1}^n w_i x_i < b, \end{cases} \quad (1)$$

Una vez que se determina el efecto neto en un nodo oculto, la activación en ese se calcula utilizando una función de transferencia o activación (por ejemplo, función sigmoideal) para producir una salida entre 0 y +1 o -1 y +1. La cantidad de activación obtenida representa la nueva señal que se va a transferir hacia adelante a la capa posterior (por ejemplo, capa oculta o de salida). El mismo procedimiento de cálculo del efecto neto se repite para cada nodo oculto y para todas las capas ocultas. Los efectos netos calculados en el nodo o nodos de salida se transforman en consecuencias en activaciones utilizando una función de transferencia. Las activaciones que se acaban de calcular en los nodos de salida representan la solución de la RNA del ejemplo alimentado, que puede desviarse considerablemente de la solución de destino debido a los pesos de interconexión seleccionados arbitrariamente. En el barrido hacia atrás, la diferencia (es decir, el error) entre las salidas de la RNA y el valor objetivo, se utiliza para ajustar los pesos de interconexión, comenzando desde la capa de salida, a través de todas las capas ocultas, hasta la capa de entrada. Los barridos hacia adelante y hacia atrás se realizan repetidamente hasta que la solución de la RNA esté de acuerdo con el valor objetivo dentro de una tolerancia preespecificada. El algoritmo de aprendizaje BP proporciona los ajustes de peso necesarios en el barrido hacia atrás.

En los siguientes párrafos se describirá el algoritmo BP en su forma final. La derivación completa del algoritmo se puede encontrar en otros lugares (por ejemplo, Haykin, 1994;

Zupan y Gasteiger, 1993) y una clara derivación sistemática viene dada por Basheer (1998) y Najjar et al. (1997). Para poder ejecutar el algoritmo, es esencial definir la capa intermedia (intercapa) como el espacio entre dos capas sucesivas que encierra los pesos de conexión y contiene solo las neuronas de la capa superior, como se muestra en la Figura 6 (suponiendo que todas las capas se colocan por encima de la capa de entrada). Considerando una red MLP con intercapas l .

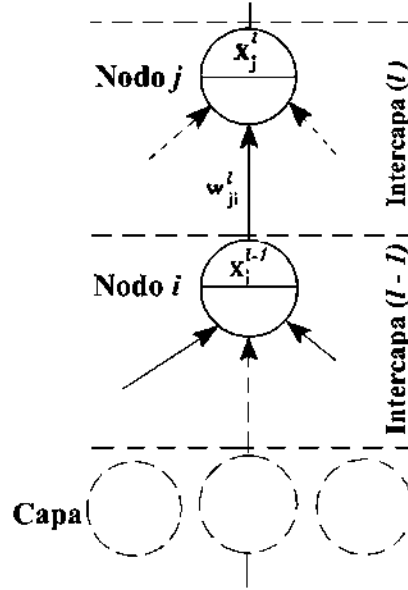


Figura 6. Indexación y notación generalmente usada en redes BP (Basheer y Hajmeer, 2000)

Para la intercapa $l \in \{1, 2, \dots, L\}$ existen N_l nodos y $N_l \times N_{l-1}$ enlaces de conexiones con pesos $\mathbf{W} \in R^{N_l \times N_{l-1}}$, donde N_l y N_{l-1} son los números de nodos (incluidos los umbrales) en las intercapas l y $l-1$, respectivamente (Figura 6). Un peso de conexión se denota por W_{ji}^l si reside en la intercapa l y conecta el nodo j de la intercapa l con el nodo i de la intercapa inferior (precedente) $l-1$ (el nodo i es el nodo de origen y el nodo j es el nodo de destino). En cualquier intercapa l , una neurona típica j integra la señal, x_j , incidiendo sobre ella, y produce un efecto neto, ε_j , de acuerdo con la dinámica lineal de la neurona:

$$\varepsilon_j^l = \sum_{i=1}^{N_{l-1}} w_{ji}^l x_i^{l-1} \quad (2)$$

La activación correspondiente, x_j^l , de la neurona se determina mediante una función de transferencia, σ , que convierte la señal total en un número real a partir de un intervalo acotado:

$$x_j^l = \sigma \left(\sum_{i=1}^{N_{l-1}} w_{ji}^l x_i^{l-1} \right) \quad (3)$$

Una función popular utilizada en BP es el sigmoide continuo básico:

$$\sigma(\varepsilon) = \frac{1}{1 + e^{-\varepsilon}} \quad (4)$$

Donde $-\infty < \varepsilon < \infty$ y $0 \leq \sigma \leq 1.0$. Las ecuaciones (2) a (4) se utilizan para todos los nodos para calcular la activación. Para los nodos de entrada, la activación es simplemente la entrada sin procesar. En cualquier intercapa, un peso arbitrario w_{ji}^l en la iteración (t) se actualizará desde su valor de estado anterior ($t - 1$) de acuerdo con:

$$w_{ji}^l(t) = w_{ji}^l(t - 1) + \Delta w_{ji}^l(t) \quad (5)$$

Donde Δw_{ji}^l es el cambio incremental (+/-) en el peso. El cambio de peso se determina a través de la regla delta modificada (Zupan y Gasteiger, 1993), que se puede escribir como:

$$\Delta w_{ji}^l = \eta \delta_j^l x_i^{l-1} + \mu \Delta w_{ji}^{l(\text{previo})} \quad (6)$$

Donde η es la tasa de aprendizaje que controla el tamaño del paso de actualización, μ es el coeficiente de momento y x_i^{l-1} es la entrada de la intercapa $l - 1$. La primera parte del lado derecho de la ecuación (6) es la regla delta original. El término de impulso adicional ayuda a dirigir la búsqueda en el hiperespacio al mínimo global al permitir que una parte de la actualización anterior (magnitud y dirección) se agregue al paso de actualización actual. Nótese que la ecuación (6) también se puede aplicar a cualquier umbral neuronal (sesgo) que pueda asumirse como un enlace, con un peso igual al valor umbral, para una neurona imaginaria cuya activación se fija en 1.0. El cambio de peso también se puede determinar utilizando un descenso de gradiente escrito en forma generalizada para una capa intermedia l :

$$\Delta w_{ji}^l = -k \left(\frac{\partial \varepsilon^l}{\partial w_{ji}^l} \right) \quad (7)$$

Por lo tanto, para determinar los cambios incrementales para la capa intermedia l th, la tarea principal es cuantificar el gradiente de error ($\partial \varepsilon^l / \partial w_{ji}^l$). Usando las ecuaciones (6) y (7), el cambio de peso requerido se puede derivar con diferentes expresiones dependiendo de si la neurona considerada está en la capa de salida o en una capa oculta. Si la neurona está en la capa de salida, entonces $l = L$. La ecuación (6), con δ_j^l calculada a partir de:

$$\delta_j^l = (x_j^l - y_j)x_j^l(1 - x_j^l) \quad (8)$$

Si la neurona está en una capa oculta, el cambio de peso también se calcula utilizando la ecuación (6) con δ_j^l determinada a partir de:

$$\delta_j^l = x_j^l(1 - x_j^l) \left(\sum_{k=1}^r \delta_k^{l+1} w_{kj}^{l+1} \right) \quad (9)$$

Donde δ_k^{l+1} se calcula para una capa dada que no es de salida (l) comenzando con una capa un nivel hacia arriba ($l + 1$) y moviéndose hacia abajo capa por capa. Es decir, para la última capa oculta (superior) en una red, δ_j^l se determina a través de δ_k^{l+1} de la capa de salida calculada utilizando la ecuación (8). Las ecuaciones delta anteriores, (8) y (9), se basan en la función de transferencia sigmoide dada en la ecuación (4). Para una función diferente, los términos $x_j^l(1 - x_j^l)$ y $x_j^l(1 - x_j^l)$ en las ecuaciones (8) y (9), respectivamente, deben reemplazarse por la primera derivada relevante de la función utilizada. Esta técnica de distribuir hacia atrás los errores a partir de la capa de salida hacia abajo a través de la capa oculta dio al método el nombre de Back Propagation (Retro Propagación) del error con la regla delta modificada (Rumelhart et al., 1986).

5.4.3. Lluvias intensas

La precipitación o lluvia es cualquier agua meteórica recogida sobre la superficie terrestre. Esto incluye básicamente: lluvia, nieve y granizo (también rocío y escarcha que en algunas regiones constituyen una parte pequeña pero apreciable de la precipitación total) (Sánchez, 2022).

Para un buen pronóstico cuantitativo es necesario caracterizar adecuadamente los eventos de lluvias que se pretenden predecir. Existen diversas formas para clasificar las lluvias, una de ellas es de acuerdo a su origen que se relaciona con los mecanismos de ascenso (convectivo, frontal, orográfico y convergencia) de la masa de aire húmedo que posteriormente precipitará. De acuerdo a su origen se pueden clasificar en las siguientes:

1) *Convectivas*

También se las llaman lluvias de tormentas y se producen por la ascendencia convectiva. Se caracterizan por su corta duración, abundantes montos pluviométricos y elevada intensidad. En general, las lluvias convectivas tienen carácter de chubascos, chaparrones, fuertes a torrenciales aguaceros y están asociados con otros fenómenos meteorológicos convectivos como granizos, fuertes vientos, relámpagos, rayos, entre otros (Jagsich, 1954). Los tipos de nubes asociados poseen un gran desarrollo vertical como las Cúmulus congestus y Cumulonimbus (Barry y Chorley, 1895).

2) *Frontales*

También denominadas ciclónicas o ciclónicas, se originan por medio de la ascendencia frontal. Sus características están determinadas por el tipo de sistema frontal y su edad, aunque es evidente que se producen por la convergencia horizontal de dos masas de aire con caracteres físicos y dinámicos distintos. En general, las precipitaciones son continuas, muy extensas, de intensidad variable y con nubes estratiformes asociadas (Cirrus, Nimbostratus, Altostratus, Cumulonimbus si el aire es muy inestable).

3) *Orográficas*

También denominadas lluvias de relieve, son aquellas que se generan por la ascendencia orográfica. En este caso, la configuración topográfica del espacio condicionará las características de las lluvias en su duración, proporción, intensidad, extensión y orientación. Así pues, el flujo del aire será modificado sustancialmente cuando se topa a su paso con altas montañas o mesetas, por ejemplo, en las latitudes medias, donde dominan las precipitaciones frontales, este fenómeno incrementa la frecuencia e intensidad de las lluvias invernales, mientras que en verano se activan ocasionalmente las precipitaciones por calentamiento in situ (Barry y Chorley, 1895).

Por otro lado, existe la clasificación de lluvias de acuerdo a su intensidad, es decir, la cantidad de lluvia que cae en un determinado intervalo de tiempo, generalmente medida en mm/hr. Generalmente, cada país tiene sus propios estándares para caracterizar las lluvias de acuerdo a su intensidad, en la Tabla 1, Tabla 2 y Tabla 3 podemos comparar los criterios de referencia y como se categoriza dicha lluvia.

Tabla 1. Clasificación de la intensidad de lluvia de acuerdo al Sistema Meteorológico Nacional de México.

Categoría	Intensidad (mm/hr)
Ligera	Menor a 5
Moderada	Entre 5.1 y 15
Fuerte	Entre 15.1 y 60
Torrencial	Mayor a 60

Tabla 2. Clasificación de la intensidad de lluvia de acuerdo al Agencia Estatal de Meteorología de España.

Categoría	Intensidad (mm/hr)
Débiles	Menor o iguales a 2
Sin adjetivar	Entre 2.1 y 15
Fuertes	Entre 15.1 y 30
Muy Fuertes	Entre 30.1 y 60
Torrenciales	Mayores a 60

Tabla 3. Clasificación de la intensidad de lluvia acuerdo al Servicio Meteorológico Nacional de los Estados Unidos de América.

Categoría	Intensidad (in/hr)
Ligera	Entre 0.01 y 0.10
Moderada	Entre 0.11 y 0.30
Fuerte	Mayor a 30

Es importante conocer el intervalo de tiempo en el que cae la lluvia. ¿Cayó durante varios días, empapándose gradualmente en el suelo? ¿O vino todo a la vez en un chaparrón, erosionando rápidamente el suelo, obstruyendo las alcantarillas de la ciudad y provocando inundaciones a lo largo de arroyos y ríos incapaces de manejar el aumento repentino del flujo? Las respuestas a estas preguntas determinan si un evento de lluvias intensas puede desencadenar una inundación repentina y fijan el umbral que será necesario superar para que el SAT emita una alerta.

6. Metodología

Para poder lograr los objetivos establecidos en este trabajo se optó por seguir la metodología mostrada en la Figura 7. Esta metodología se dividió en cuatro fases esenciales, las dos primeras fases tuvieron como finalidad construir una red de monitoreo en tiempo real que brindara la información necesaria para la elaboración de los pronósticos. La primera fase se enfocó en realizar un análisis de riesgo, que caracteriza la zona de estudio, la segunda fue orientada al diseño y creación de un conjunto de estaciones meteorológicas automáticas, las cuales son las encargadas de obtener los datos climáticos en tiempo real.

Las siguientes y últimas dos fases dieron forma al sistema de pronósticos de lluvia. Dentro de estas fases se encuentra la fase tres, la cual tiene como objetivo crear un modelo para el pronóstico de las lluvias intensas mediante el ajuste de una red neuronal artificial. Por último, aparece la fase cuatro cuya finalidad fue la elaboración de una aplicación/plataforma digital que se encargue de procesar los datos climáticos en tiempo real de la red de monitoreo, genere los pronósticos y a su vez emita las alertas en caso de que el umbral definido para las lluvias intensas sea sobrepasado.

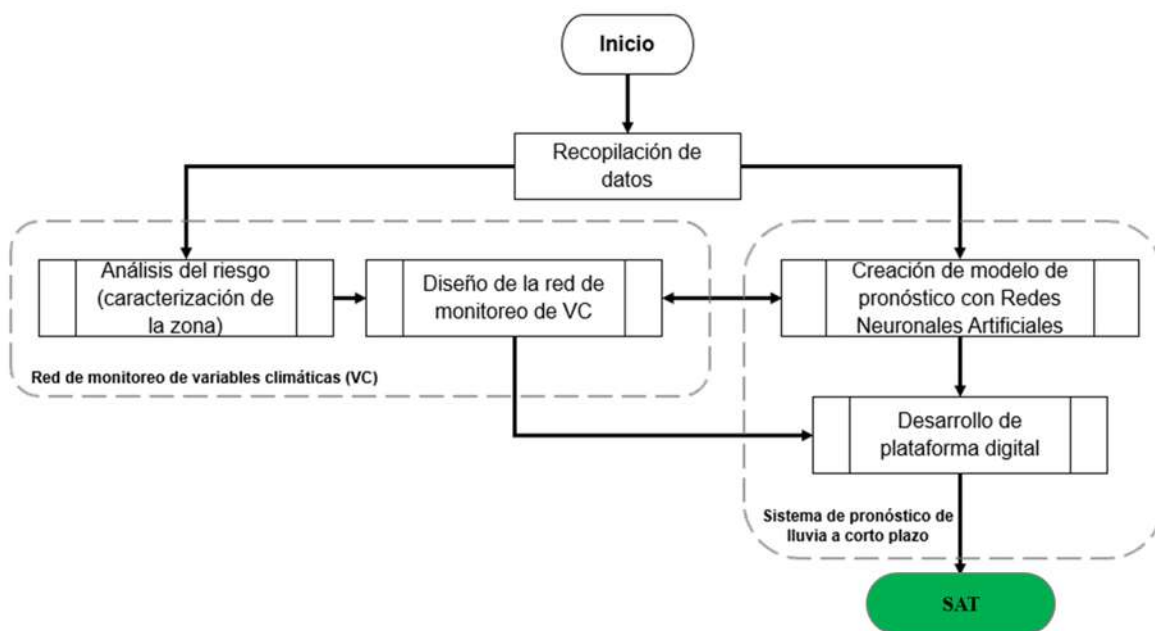


Figura 7. Ruta metodológica que se seguirá para crear el sistema de alerta temprana.

6.1. Recopilación de datos

Los datos recopilados fueron utilizados para realizar las fases de análisis del riesgo y la creación del modelo de pronóstico. Para el análisis del riesgo se recopilarán datos socioeconómicos del censo de población 2020 del INEGI a nivel de manzana, un conjunto de datos del terreno, clima y de distribución urbana de la ciudad de Morelia tales como elevación, pendiente, distancia con ríos y canales, usos de suelo, lluvia media anual,

además se realizó un inventario de los sitios con registros de lluvias intensas (artículos, notas periodísticas, etc), que hayan desencadenado inundaciones o afectaciones en la población.

Por otro lado, para crear el modelo de pronóstico se obtuvieron datos pluviométricos del Organismo Operador de Agua Potable, Alcantarillado y Saneamiento de Morelia (OAPAS). Se obtuvo la información de la estación automática 01-Acueducto, cuyos datos contenían información de variables climáticas como precipitación, temperatura, humedad, punto de rocío, entre otras.

6.2.Red de monitoreo de variables climáticas

6.2.1. Análisis del riesgo (caracterización de la zona de estudio)

Para esta fase se adaptó la metodología usada por Eini et al. (2020), el objetivo fue el generar un mapa de riesgo ante inundaciones que permitiera zonificar los sitios donde el SAT emitirá alertas. El riesgo se definió como el producto de dos probabilidades, ecuación (10). Por un lado, tenemos la probabilidad de que un fenómeno natural ocurra, es decir, una amenaza y por el otro lado la probabilidad de que el sitio en que ocurre dicha amenaza sea afectado, es decir, la vulnerabilidad.

$$Riesgo = Amenaza \cdot Vulnerabilidad \quad (10)$$

En este sentido fue necesario obtener dos mapas, uno de vulnerabilidad y otro de la amenaza. En la Figura 8 se muestran las dos rutas para obtener estos mapas.

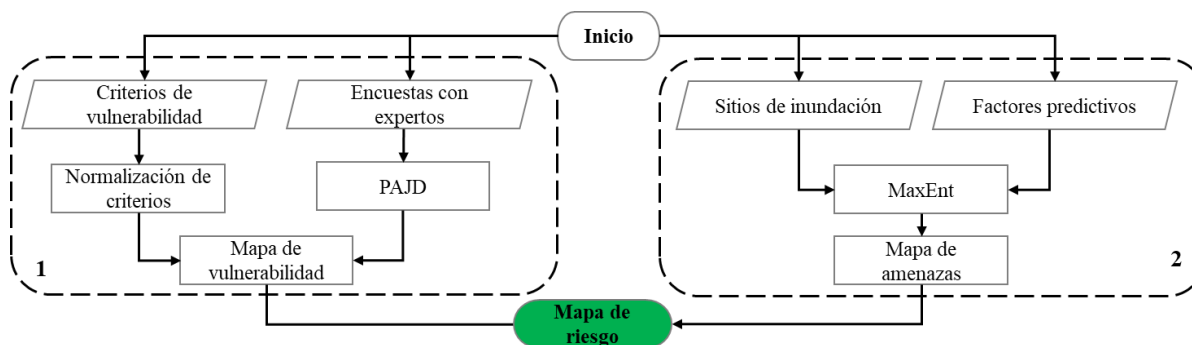


Figura 8. Ruta metodológica específica para el análisis del riesgo.

6.2.1.1. Mapa de vulnerabilidad

Resultado de la recopilación de datos, se obtuvo la información del censo de población 2020 del INEGI, la cual se clasificó en 12 subcriterios agrupados en tres criterios generales: económicos, sociales y de infraestructura (Tabla 4).

Tabla 4. Subcriterios utilizados en el Proceso Analítico Jerárquico Difuso.

Económicos	Sociales	Infraestructura
Empleos promedio	Densidad de población	Escuelas
Densidad de vivienda	Población marginada	Centros de salud
	Población discapacitada	Calles principales
	Población sin afiliación a servicios de salud	Sistema de drenaje
	Población en edad vulnerable	

Encuestas a expertos y Proceso Analítico Jerárquico Difuso (PAJD)

Se aplicó el PAJD con la finalidad de obtener un vector de ponderación que indicara la aportación de cada subcriterio al cálculo de la vulnerabilidad. Antes de iniciar con el PAJD se realizaron encuestas a un conjunto de expertos en el tema de inundaciones, en donde realizaron una serie de comparaciones pareadas, es decir, los expertos compararon la importancia de un subcriterio sobre otro usando los criterios de comparación mostrados en la Tabla 5.

Tabla 5. Criterios de comparación pareada (Saaty, 1980)

Importancia	Criterio de comparación
1	Igualdad de importancia
3	Importancia moderada
5	Importancia fuerte
7	Importancia muy fuerte
9	Importancia extrema

Las encuestas fueron traducidas a un conjunto de matrices de comparación, una matriz para el grupo de criterios generales (Figura 9) y tres para cada grupo de subcriterios como la que se muestra en la Figura 10.

	Económico	Infraestructura	Social
Económico	1	5	7
Infraestructura	1/5	1	5
Social	1/7	1/5	1

Figura 9. Matriz de comparación pareada entre los criterios generales que pertenecen a un mismo nivel jerárquico.

	Escuelas	Centros de salud	Calles principales	Sistemas de drenaje
Escuelas	1	3	5	7
Centros de salud	1/3	1	3	5
Calles principales	1/3	1/3	1	3
Sistemas de drenaje	1/7	1/5	1/3	1

Figura 10. Matriz de comparación pareada entre los subcriterios que pertenecen al grupo de infraestructura.

Para poder continuar con el PAJD fue necesario realizar un análisis de consistencia de cada una de las matrices de comparación pareada. Este análisis tuvo como finalidad corroborar que los juicios ejercidos por los expertos no fueran contradictorios, por ejemplo, si alguno

de los expertos afirmara, en términos de importancia, que *escuelas*>*centros de salud*, *centros de salud*>*calles principales* y *escuelas*<*calles principales*. Evidentemente existe una inconsistencia.

Si en el análisis de consistencia, el Ratio de Consistencia (*RC*) es menor que el valor indicado en la Tabla 6, se puede considerar que la matriz analizada es consistente y esta puede ser usada en el PAJD.

Tabla 6. Porcentajes máximos para el Ratio de Consistencia (Yepes Piqueras, 2022).

Tamaño de la matriz	Ratio de Consistencia (<i>RC</i>)
3 o menor	5%
4	9%
5 o mayor	10%

El Ratio de Consistencia se calculó mediante el cociente del Índice de Consistencia (*IC*) y el Índice Aleatorio (*IA*), ecuación (11).

$$CR = \frac{IC}{IA} \quad (11)$$

El Índice de Consistencia (*IC*) puede ser calculado mediante la ecuación (12) :

$$IC = \frac{\lambda_{max} - n}{n - 1} \quad (12)$$

Donde, λ_{max} es un valor escalar de la matriz y *n* es el tamaño de la matriz analizada. El Índice Aleatorio (*IA*), es un índice de una matriz de comparaciones pareadas generada de forma aleatoria. El índice aleatorio depende del número de elementos que se comparan. En la siguiente tabla se muestran los valores usados dependiendo del tamaño de la matriz.

Tabla 7. Valores de los índices aleatorios (*IA*) para las matrices propuestas por Saaty (1980).

Tamaño de la matriz	1x1	2x2	3x3	4x4	5x5	6x6	7x7	8x8
Índice Aleatorio	0.00	0.00	0.58	0.90	1.12	1.32	1.41	1.45

Una vez que se corroboró la consistencia de todas las matrices de comparación pareada, se procedió a obtener una sola representación de los juicios de todos los expertos. Esto se realizó obteniendo la media geométrica, ecuación (13), por grupo jerárquico y grupo de subcriterios, obteniendo así cuatro matrices en total.

$$MG = \sqrt[n]{x_1 + x_2 + x_3 + x_n} \quad (13)$$

El siguiente paso fue aplicar como tal la teoría difusa al proceso analítico jerárquico, transformando las matrices con una escala de Saaty a matrices con escala triangular difusa usando la Tabla 8.

Tabla 8. Escala de Saaty (1980) y escala triangular difusa Büyükožkan et al. (2004).

Criterio	Escala de Saaty	Escala Triangular Difusa			Escala Triangular Difusa Inversa		
		l	m	u	u	m	l
Igualdad de importancia	1	1/2	1	3/2	2/3	1	2
Importancia moderada	3	1	3/2	2	1/2	2/3	1
Importancia fuerte	5	3/2	2	5/2	2/5	1/2	2/3
Importancia muy fuerte	7	2	5/2	3	1/3	2/5	1/2
Importancia extrema	9	5/2	3	7/2	2/7	1/3	5/2

Posteriormente se procedió a calcular los vectores sintéticos difusos mediante la obtención de la extensión sintética difusa respecto a la i -ésima alternativa, ecuación (14).

$$S_i = \sum_{j=1}^m M_{gi}^j \otimes \left[\sum_{i=1}^n \sum_{j=1}^m M_{gi}^j \right]^{-1} \quad (14)$$

Donde los valores de la matriz difusa, se conocen como números difusos triangulares (NDT) que son representados con el termino $M_{gi}^j (j = 1, 2, 3, \dots, m)$.

Después de calcular la extensión sintética difusa se calculó el grado de posibilidad, en el que se comparan vectores sintéticos difusos para obtener el grado de posibilidad de que un número difuso sea mayor que otro. Si suponemos que se tienen dos números difusos $M_1 = (l_1, m_1, u_1)$ y $M_2 = (l_2, m_2, u_2)$, entonces el grado de posibilidad de que $M_2 \geq M_1$ se puede definir mediante la ecuación (15).

$$V(M_2 \geq M_1) = \sup_{y \geq x} [\min (\mu_{M_1}(x), \mu_{M_2}(y))] \quad (15)$$

De igual manera el grado de posibilidad puede ser entendido mediante la siguiente ecuación (16)

$$V(M_2 \geq M_1) = \begin{cases} 1 & \text{sí } m_2 \geq m_1 \\ 0 & \text{sí } l_1 \geq u_2 \\ \frac{l_1 - u_2}{(m_2 - u_2) - (m_1 - l_1)} & \text{de lo contrario} \end{cases} \quad (16)$$

El siguiente paso fue calcular el grado de posibilidad de que un número difuso convexo sea mayor que k números difusos convexos, y queda definido por la siguiente ecuación (17).

$$d'(A_i) = \min V(S_i \geq S_k), k = 1, 2, 3, \dots, n; k \neq i \quad (17)$$

Posteriormente, para el cálculo del vector de ponderación o de pesos se tomaron los valores obtenidos en el paso anterior de convexidad de vectores difusos de manera que el cálculo de este vector de ponderación queda dado por la ecuación (18)

$$W' = (d'(A_1), d'(A_2), \dots, d'(A_n))^T \quad (18)$$

Donde $A_i (i = 1, 2, 3, \dots, n)$ son n elementos convexos. En seguida se obtuvo el vector de ponderación normalizado W , dividiendo cada elemento entre la suma de todos los elementos del vector.

$$W = (d(A_1), d(A_2), \dots, d(A_n))^T \quad (19)$$

Cabe mencionar que este vector W es representativo de una sola matriz difusa local, es decir, que se obtuvieron cuatro vectores de pesos locales, por lo que fue necesario obtener un solo vector, W_G , que representara de manera global los pesos, P_s , de cada subcriterio s . Para obtener este vector global se multiplicaron los pesos locales de cada subcriterio por el peso local de la categoría a la que pertenecían.

$$W_G = (P_1, P_2, P_3, \dots, P_s) \quad (20)$$

Normalización de los criterios de vulnerabilidad

Los valores de los subcriterios obtenidos del censo de población del INEGI fueron normalizados individualmente entre los valores de 0 y 1, mediante la ecuación (21). Donde N_i^s es el valor ya normalizado de la i -ésima manzana de un subcriterio s , V_i^s es el i -ésimo valor a ser normalizado de un subcriterio s , mientras que V_{max}^s y V_{min}^s son los valores mínimos y máximos, respectivamente de cada subcriterio.

$$N_i^s = \frac{V_i^s - V_{min}^s}{V_{max}^s - V_{min}^s} \quad (21)$$

Finalmente, se obtuvo la vulnerabilidad de cada manzana mediante la ecuación (22) para posteriormente plasmar los resultados en un mapa de vulnerabilidad mediante una herramienta SIG.

$$Vul_i = \sum_{s=1}^m P_s \cdot N_i^s \quad (22)$$

Donde Vul_i es la vulnerabilidad de la i -ésima manzana, P_s el peso para cada subcriterio s y N_i^s el valor normalizado por cada subcriterio s para la i -ésima manzana.

6.2.1.2. Mapa de amenazas

Para crear el mapa de amenazas se utilizó el software llamado Maxent (Steven et al., 2020), al cual se le suministraron dos insumos principales, un conjunto de coordenadas geográficas de los sitios donde han ocurrido inundaciones además de un paquete de archivos raster en formato .ascii que contienen información de factores predictivos o de predicción de inundaciones.

Los sitios donde han ocurrido las inundaciones fueron recopilados mediante una revisión de fuentes periodísticas, revistas, noticieros web, información del OOAPAS, entre otras. Una vez que se localizaron los sitios de inundación se generó un archivo en formato .csv que contenía sus coordenadas, esto mediante el software QGIS 3.10.11.

Factores predictivos

Por otro lado, se crearon cinco archivos raster con los factores de elevación del terreno, pendiente del terreno, distancia con ríos y canales, uso de suelo y lluvia media anual. Estos archivos fueron creados con ayuda del software QGIS 3.10.11. mediante la aplicación de diferentes algoritmos y procesos dentro del mismo software.

Mediante el portal web del INEGI fue obtenido el raster de elevación del terreno, al cual se le aplicó el algoritmo *fill* del software QGIS 3.10.11 para la corrección de datos vacíos. El raster de distancia con ríos y canales fue creado a partir un archivo shape que contenía los cursos de los principales ríos y canales de la ciudad de Morelia, el algoritmo usado para obtener este raster fue *proximty raster* que calcula la distancia más cercana entre un determinado pixel del raster resultante y el río o canal.

La construcción del factor de uso de suelo se obtuvo a partir de imágenes satélites tomadas del satélite LANDSAT 8, con estas imágenes se realizó una clasificación supervisada con apoyo de un complemento llamado Semi-Automatic Classification (SCP) que se encuentra dentro del software QGIS. Para esta clasificación supervisada se tomaron en consideración ocho usos de suelo:

- Zonas residenciales
- Zonas abiertas sin vegetación aparente

- Vialidades
- Parques y jardines
- Zonas con vegetación sana
- Zona industrial
- Bosques
- Cuerpos de agua

Por último, para la generación del raster de lluvia media anual, se seleccionaron un conjunto de estaciones meteorológicas que cumplieron con la mejor puntuación en los siguientes criterios: total de datos efectivos, total de vacíos, años efectivos, años de servicio, porcentaje de vacíos, año de inicio, último año y distancia euclidiana con respecto al centroide de la mancha urbana de la ciudad de Morelia. De esta selección se eligieron las estaciones mostradas en la Tabla 9. El raster se construyó con los datos de precipitaciones medias anuales de cada estación mediante una interpolación IDW en QGIS 3.10.11.

Tabla 9. Estaciones meteorológicas usadas para la creación del mapa de precipitación media anual

Nombre	Código	Coordenada x (m)	Coordenada y (m)	Coordenada z (m)	PMA (mm)
Morelia (OBS)	16080	271142.77	2179754.23	1912.7	739.31
Morelia	16081	271881.60	2178482.36	1908.0	759.63
Quiro	16105	291014.24	2190305.57	1858.0	670.70
San Diego Curupatzco	16109	270625.66	2139154.35	1444.0	997.23
Santa Fé	16118	232001.73	2177320.67	2203.0	721.65
El Colegio	16512	271792.14	2187774.35	1880.0	665.56

MaxEnt

Antes de usar el software Maxent (Steven et al., 2020), fue necesario preparar los datos de entrada o insumos. Los sitios de inundación se formatearon en tipo csv (delimitado por comas), en el que la primera columna es el tipo de inundación, la segunda columna es la longitud y la tercera es la latitud, ambas coordenadas en un sistema referencial de coordenadas UTM mientras los factores predictivos se formatearon en tipo ascii.

En la Figura 11 se puede observar la ventana principal de Maxent, en donde se aprecia el ingreso de los dos insumos principales. Del lado derecho se pueden observar los factores predictores, mientras en el lado izquierdo se observan las muestras que corresponden a los sitios de inundación. Respecto a los factores predictivos fue necesario indicar si se trataban de variables continuas o categóricas. Para fines prácticos, a los factores predictivos se les asignó las siguientes claves: elevación del terreno (v1), pendiente del terreno (v2), distancia con ríos y canales (v3), uso de suelo (v4) y lluvia media anual (v5).

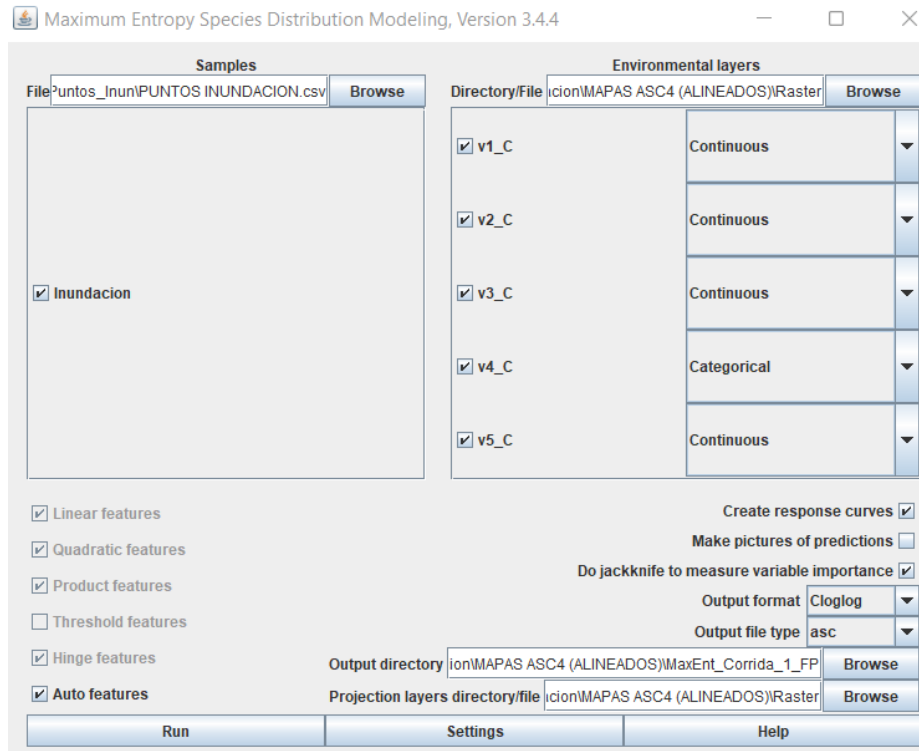


Figura 11. Entorno de MaxEnt con los datos para analizar los puntos de presencia de inundaciones pluviales y fluviales.

Se decidió usar la configuración por defecto del software, en donde la salida elegida es una transformación cloglog, que de acuerdo a algunos resultados en trabajos realizados como el de Hernández Ramos (2018), muestran que la salida cloglog es la que más apego tiene a la distribución potencial del fenómeno de inundación, además, es más fácil de conceptualizar pues da una estimación entre 0 y 1 de la probabilidad de ocurrencia.

6.2.1.3. Mapa de riesgo

Finalmente, para obtener el mapa de riesgo solo fue necesario realizar una multiplicación entre la probabilidad de que un fenómeno natural ocurra, es decir, una amenaza y por el otro lado la probabilidad de que el sitio en que ocurre dicha amenaza sea afectado, es decir, la vulnerabilidad, ecuación (10). Este proceso se realizó con el apoyo del software QGIS.

6.2.2. Diseño de la red de monitoreo de variables climáticas

Para el desarrollo de la red de monitoreo fue necesario seguir el procedimiento sistemático mostrado en la Figura 12, en donde se describen por separado las principales actividades en el desarrollo de las EMA's que integran la red de monitoreo.

1. *Identificación de los problemas y oportunidades:* En esta primera actividad, fue necesario identificar adecuadamente los problemas y oportunidades de los sistemas de monitoreo existentes en el área de estudio.

2. *Determinación de los requerimientos*: Se determinaron las necesidades de los usuarios involucrados. Además, también se determinaron los requerimientos del sistema que integraría la red de monitoreo, cuyo requerimiento principal fue el crear EMA's de bajo costo y software libre.
3. *Diseño de la red*: Una vez definidos los requerimientos se procedió a realizar una primera propuesta de una EMA considerando la elección y creación de los sensores adecuados, procedimientos de lecturas, protocolos de comunicación, base de datos e interfaz de visualización.
4. *Desarrollo de software*: Para esta fase fue necesario analizar las plataformas de programación con licencia libre orientados a la programación de sensores.
5. *Pruebas de funcionamiento*: En esta fase se probó el correcto funcionamiento y se detectaron problemas y errores en los procesos de las EMA's. Además, se realizó la calibración de los sensores utilizando datos reales de sistemas alternativos.
6. *Implementación y evaluación*: Por último, se realizó la instalación de las EMA's tomando como referencia el análisis del riesgo que reveló los sitios con mayor prioridad de ser monitoreados. También, se realizó la evaluación general de la red de monitoreo.



Figura 12. Proceso sistemático usado para el diseño de la red de monitoreo de variables climáticas.

6.3. Sistema de pronóstico de lluvia a corto plazo

6.3.1. Creación de modelo de pronóstico con Redes Neuronales Artificiales

Para crear el modelo que pronostique las lluvias intensas, se siguió el proceso iterativo que se muestra en la Figura 13. El objetivo principal de este proceso fue realizar el entrenamiento de una RNA del tipo Perceptrón Multi Capa (MLP por sus siglas en inglés) y posteriormente evaluar la capacidad de generalización de la RNA, esta generalización se refiere a la capacidad de pronosticar datos nuevos (que no fueron usados en la fase del entrenamiento), de una manera precisa.

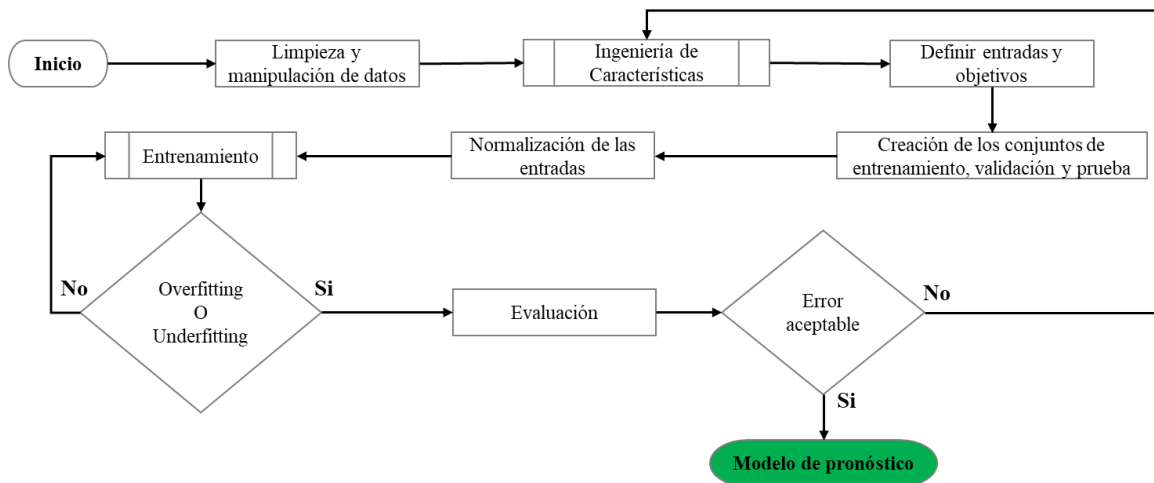


Figura 13. Procedimiento para la creación del modelo de pronóstico de lluvias con base en una red neuronal artificial.

Se utilizó el lenguaje de programación Python, el cual tiene librerías especializadas para realizar proyectos de machine learning, como lo son TensorFlow 2.3. y Keras 2.4.3. Además, se utilizaron los datos de la estación automática 01-Acueducto perteneciente al OOAPAS para realizar el entrenamiento de la RNA. A continuación, se describen cada una de las etapas del proceso iterativo de la Figura 13.

1. *Limpieza y manipulación de datos*: Esta etapa inicial tuvo como finalidad el eliminar las observaciones con datos vacío o nulos, encontrar y sustituir observaciones con valores no numéricos, además de adecuar los datos a un tipo y estructura necesarios para realizar las siguientes etapas.
2. *Ingeniería de características*: Conocido en inglés como feature engineering, es el proceso de utilizar el propio conocimiento sobre los datos y sobre el algoritmo de aprendizaje automático disponible (en este caso, una red neuronal) para hacer que el algoritmo funcione mejor mediante la aplicación de transformaciones de los datos antes de que se ingresen en el modelo. En muchos casos, no es razonable esperar que un modelo de aprendizaje automático pueda aprender con los datos completamente

arbitrarios de manera que estos deben presentarse al modelo de una manera que facilite el trabajo de aprendizaje (Chollet, 2018).

3. *Definición de entradas y objetivos:* En el aprendizaje supervisado el entrenamiento del modelo se realiza en función de un conjunto de valores de entrada, los cuales representan las variables independientes, con la finalidad de igualar un conjunto de valores objetivos, que son la o las variables dependientes. En este trabajo el objetivo fue la variable de precipitación, mientras que las entradas fueron las variables de temperatura, humedad relativa, punto de rocío, presión barométrica, entre otras. Cabe mencionar que uno de los objetivos del entrenamiento del modelo fue elegir aquellas variables de entrada que lograron mayor exactitud en las predicciones de la variable objetivo.
4. *Creación de los conjuntos de entrenamiento, validación y prueba:* Para la elaboración del modelo se dividieron los datos disponibles en tres sub conjuntos: entrenamiento, validación y prueba. No existe una referencia única de qué cantidad de datos se tiene que reservar para cada subconjunto, sin embargo, es recomendable dejar la mayor cantidad de datos para el proceso de entrenamiento (sub conjuntos de entrenamiento y validación), y el resto (sub conjunto de prueba), para realizar la evaluación del modelo entrenado. Del sub conjunto de entrenamiento se desprendió el sub conjunto de validación cuya finalidad fue realizar una evaluación del modelo en cada ajuste de pesos y sesgos que se realiza en el entrenamiento.
5. *Normalización de las entradas:* Por lo general no es recomendable alimentar una red neuronal con datos con rangos de valores distintos o con valores relativamente grandes. Lo anterior puede provocar grandes actualizaciones en el gradiente del algoritmo Backpropagation que evitarían que la red converja. Para facilitar el aprendizaje de la red se homogeneizaron, de manera independiente, los rangos de cada variable de entrada entre los valores de 0 y 1, mediante la ecuación (23).

$$V_n = \frac{V_i - V_{min}}{V_{max} - V_{min}} \quad (23)$$

Donde V_n es el valor normalizado, V_i el valor a normalizar, V_{min} el valor mínimo de cada variable de entrada y V_{max} el valor máximo de cada variable de entrada.

6. *Entrenamiento:* Es el sub proceso medular en la creación del modelo, cuya finalidad fue lograr el ajuste más óptimo, en donde se realizó el ajuste de los hiperparámetros de la red, pesos, sesgos, cantidad de neuronas y capas ocultas. El entrenamiento se dio por concluido cuando se superó el underfitting pero se evitó provocar un overfitting. Cuando la cantidad de neuronas y capas ocultas no es suficiente la red no tiene la capacidad suficiente para pronosticar nuevos datos, por lo que se cae en underfitting.

Por otro lado, cuando hay un exceso de neuronas y capas ocultas aumenta tanto la capacidad de generalización de la red que se produce un sobre ajuste o overfitting, por lo tanto, el punto óptimo se encuentra ajustando los hiperparametros sin caer en alguna de las dos situaciones anteriores.

7. *Evaluación:* Una vez que se supera la fase de entrenamiento de la red se procedió a realizar una última evaluación de la red con el sub conjunto de prueba. Dentro de las funciones ya programadas que ofrece la librería Keras, se encuentran funciones que permiten evaluar la exactitud de los valores pronosticados por la red contra los valores observados disponibles en el conjunto de entrenamiento. Estas funciones cuentan con el Error Cuadrático Medio o el Error Absoluto Medio, funciones que son muy útiles para obtener las métricas de validación al estar entrenando la red, sin embargo, no ofrecen una referencia objetiva de si el error obtenido es aceptable o no. Por esta razón se decidió usar un par de índices de bondad de ajuste Nash-Sutcliffe efficiency (Nash y Sutcliffe, 1970) y Kling-Gupta efficiency (Gupta et al., 2009), los cuales ofrecen una referencia objetiva de cuando dar por aceptado el error obtenido.

6.3.2. Desarrollo de plataforma digital

Esta plataforma digital es parte del sistema de pronóstico de lluvias intensas y tiene como objetivo ejecutar permanentemente el modelo de red neuronal. También, funciona como enlace entre la red de monitoreo de variables climáticas y el modelo de pronóstico que se alimenta de las lecturas en tiempo real que la red de monitoreo recolecta. Además, es la responsable del envío de alertas mediante el envío de correos electrónicos a los usuarios del sistema. En la Figura 14 se pueden observar las conexiones y el flujo de información que realiza la plataforma digital.

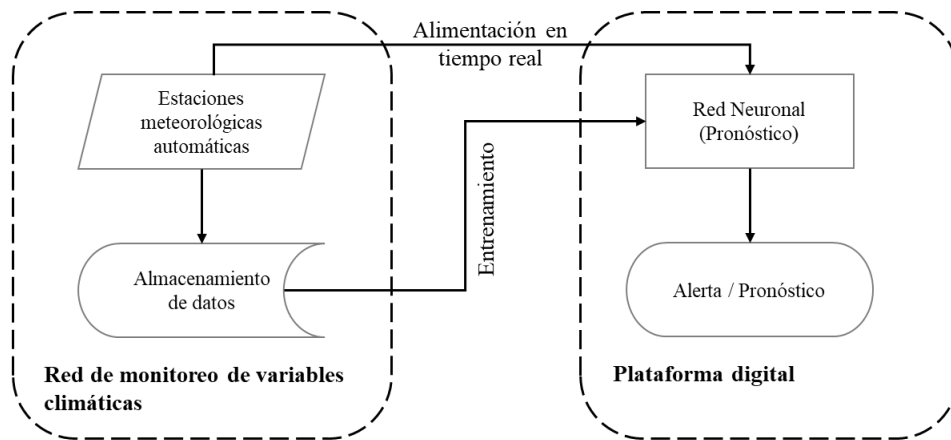


Figura 14. Enlaces y funcionamiento de la plataforma digital.

Para la creación de esta plataforma se utilizó el lenguaje de programación Python 3.9.1. Además, se hizo uso de ThingSpeak la cual es una plataforma de código abierto que permite a los usuarios comunicarse con dispositivos habilitados para Internet.

7. Resultados

En este capítulo se presentarán los resultados sustanciales de las diferentes fases de la metodología antes presentada, así como una breve discusión y análisis de dichos resultados.

7.1. Análisis del riesgo (caracterización de la zona de estudio)

7.1.1. Mapa de vulnerabilidad

Derivado del PAJD se obtuvieron un conjunto de pesos tanto locales como globales que se muestran en la Tabla 10. Los pesos locales representan la importancia de cada subcriterio o criterio con los demás en un mismo nivel jerárquico o matriz de valoración, por ejemplo, considerando el nivel de los subcriterios y dentro de la matriz de criterios económicos, podemos decir que el subcriterio de *empleos promedio* representa el 59.2% de importancia respecto del otro subcriterio de *densidad de vivienda* que obtuvo un 40.8%. Para encontrar los pesos globales bastó con obtener el producto del peso local de cada matriz por el peso local de la matriz un nivel por encima.

Tabla 10. Pesos locales y globales para cada criterio y subcriterio utilizados en el PAJD

Criterios	W (pesos locales)	Subcriterios	W (pesos locales)	W (pesos globales)
Económicos	0.3079	Empleos promedio	0.5920	0.1823
		Densidad de vivienda	0.4080	0.1256
Sociales	0.4478	Población discapacitada	0.2937	0.1315
		Población sin afiliación a servicios de salud	0.1033	0.0463
		Densidad de población	0.0000	0.0000
		Población en edad vulnerable	0.2162	0.0968
		Población marginada	0.3868	0.1732
Infraestructura	0.2443	Centros de salud	0.3995	0.0976
		Calles principales	0.3090	0.0755
		Escuelas	0.2091	0.0511
		Sistema de drenaje	0.0824	0.0201

Tomando estos pesos globales y la información recopilada del INEGI se aplicó la ecuación (22), con la cual se obtuvo la vulnerabilidad por manzana en la ciudad de Morelia. Posteriormente se plasmó el resultado en un mapa que se puede observar en la Figura 15 donde se pueden observar en color rojo las zonas de la ciudad con mayor vulnerabilidad ante un evento de inundación. En estas zonas más vulnerables inciden en mayor medida dos subcriterios, por un lado, el de *empleos promedio* (18.23%) que es un reflejo de la actividad económica de la ciudad y que se puede observar en la zona sureste, por otro lado, se encuentra una incidencia del subcriterio de *población marginada* (17.32%) en la zona norte y algunas tenencias de la ciudad.

Cabe mencionar que estos resultados estuvieron sujetos al criterio en conjunto de todos los expertos que emitieron sus juicios a través de las encuestas realizadas, por lo que estos resultados no representan una visión definitiva de qué subcriterios deberían ser tomados

como prioritarios, sin embargo, este procedimiento usado (PJAD) puede representar una herramienta muy útil para la toma de decisiones.

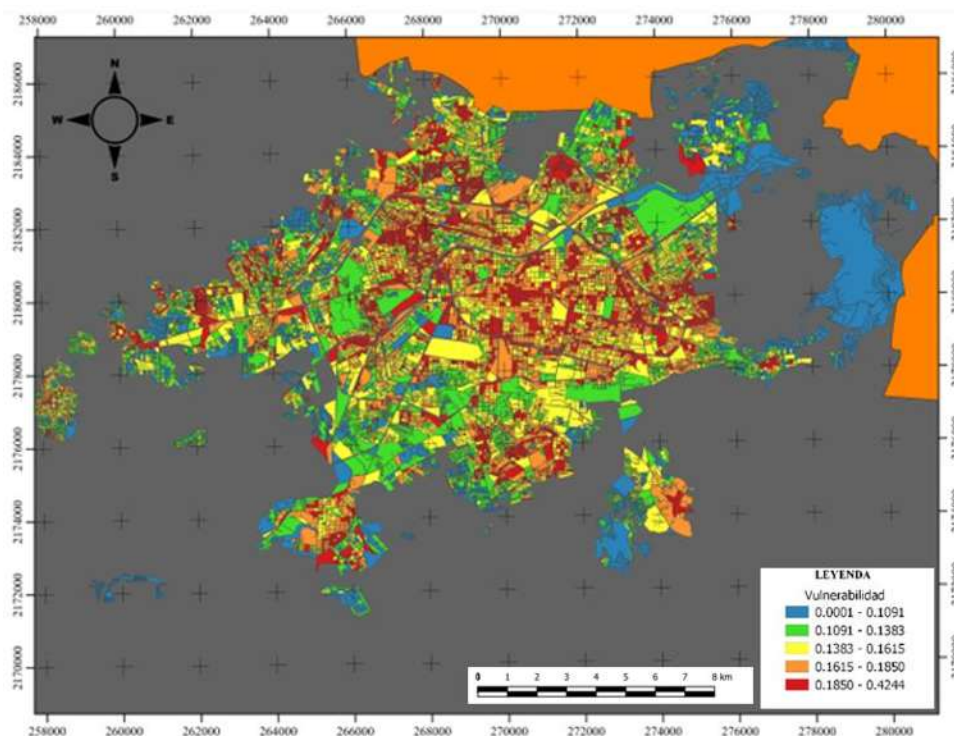


Figura 15. Mapa de vulnerabilidad ante inundaciones de la ciudad de Morelia.

7.1.2. Mapa de amenazas

Los factores predictivos de inundaciones fueron el resultado de múltiples subprocesos realizados con el apoyo QGIS 3.10.11. En la Figura 16 se pueden observar los cinco mapas resultantes, dentro de estos mapas se encontraron pendientes alrededor de los 1900 msnm, pendientes de hasta 35% en algunas zonas como Santa María y Jesús del Monte, además de una lluvia media anual de 800 mm siendo la zona sur en donde se precipita la mayor cantidad de lluvia. Estos mapas fueron usados posteriormente como insumos en el modelo MaxEnt.

Drenes como Itzicuaros, Barajas, Carlos Salazar, además del Río Grande de Morelia suelen presentar desbordamientos que causan inundaciones recurrentes en las zonas aledañas afectando zonas como San Juanito Itzicuario, la zona de “Policía y Tránsito”, colonias como Prados Verdes, Primo Tapia Poniente, La Huerta, Gertrudis Sánchez, Torreón Nuevo. No solo los drenes y ríos causan inundaciones sino también algunas condiciones como el mal funcionamiento o colapso de los sistemas de drenaje y en algunos casos la mala ubicación de las edificaciones en zonas naturalmente inundables. Estas zonas fueron plasmadas en un inventario de coordenadas (ver Figura 17), las cuales fueron el segundo insumo necesario para aplicar el modelo MaxEnt.

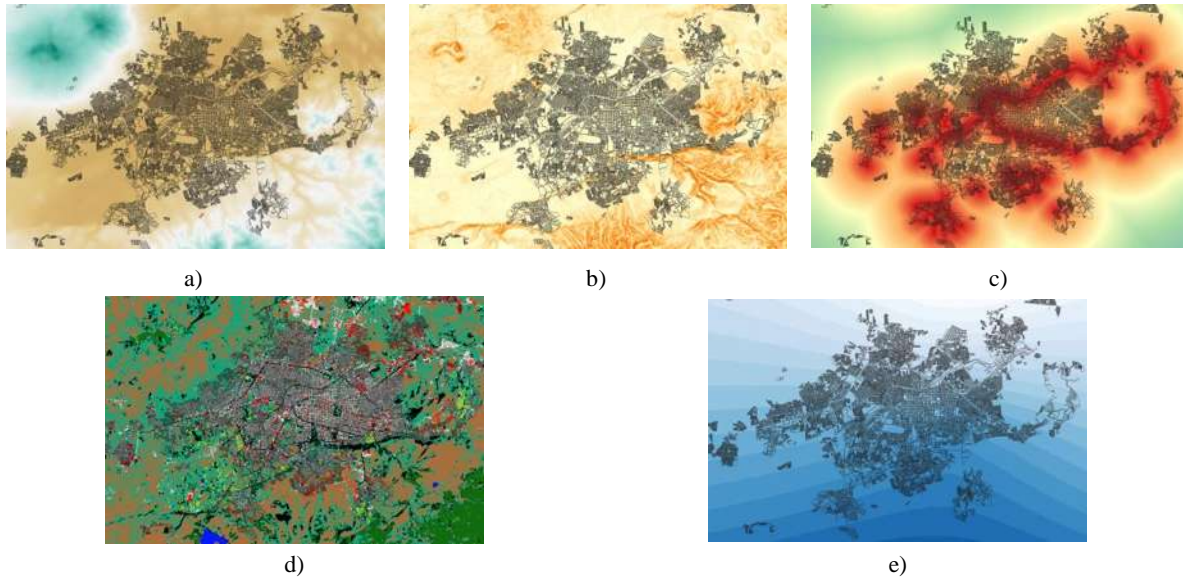


Figura 16. Factores predictivos de inundaciones. a) elevación del terreno, b) pendiente del terreno, c) distancia con ríos y canales, d) uso de suelo y e) lluvia media anual.

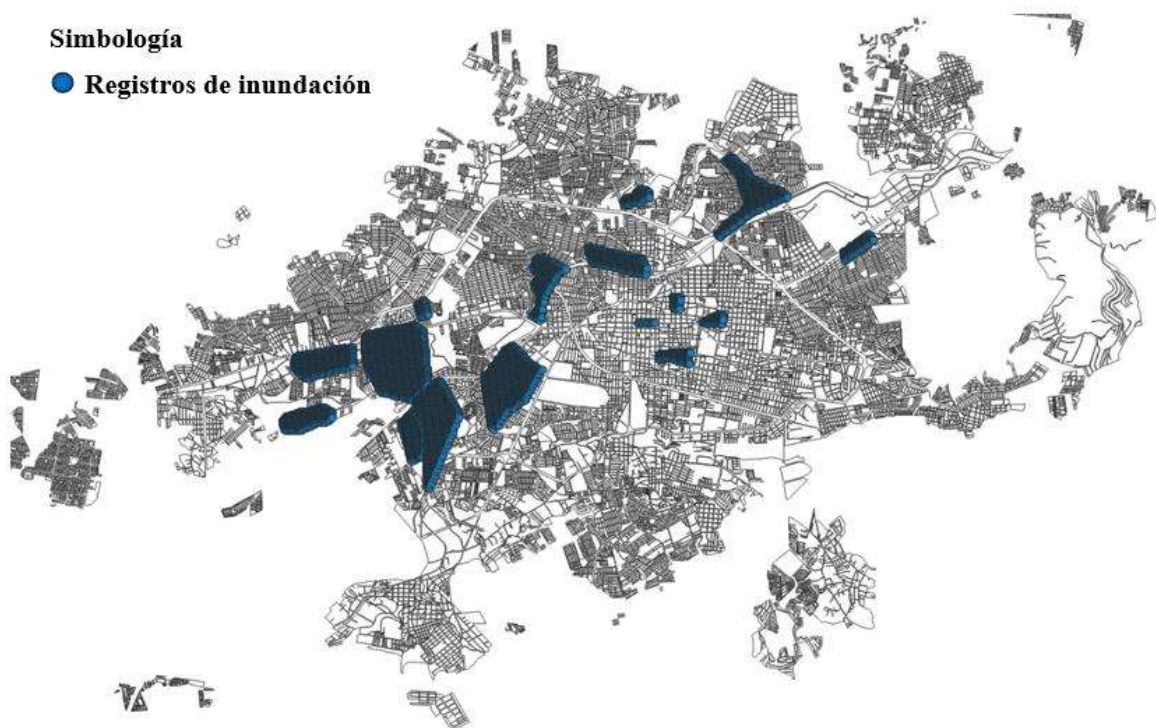


Figura 17. Sitios con registro de inundación en la ciudad de Morelia.

Con estos dos insumos, los factores predictivos y el inventario de sitios de inundación, fue posible ejecutar el modelo MaxEnt mediante el software Maximum Entropy Species Distribution Modeling 3.4.4 (Steven et al., 2020). Como resultado de algunas corridas del

software MaxEnt se obtuvo el mapa mostrado en la Figura 18, el cual representa la probabilidad de que ocurra un evento de inundación.

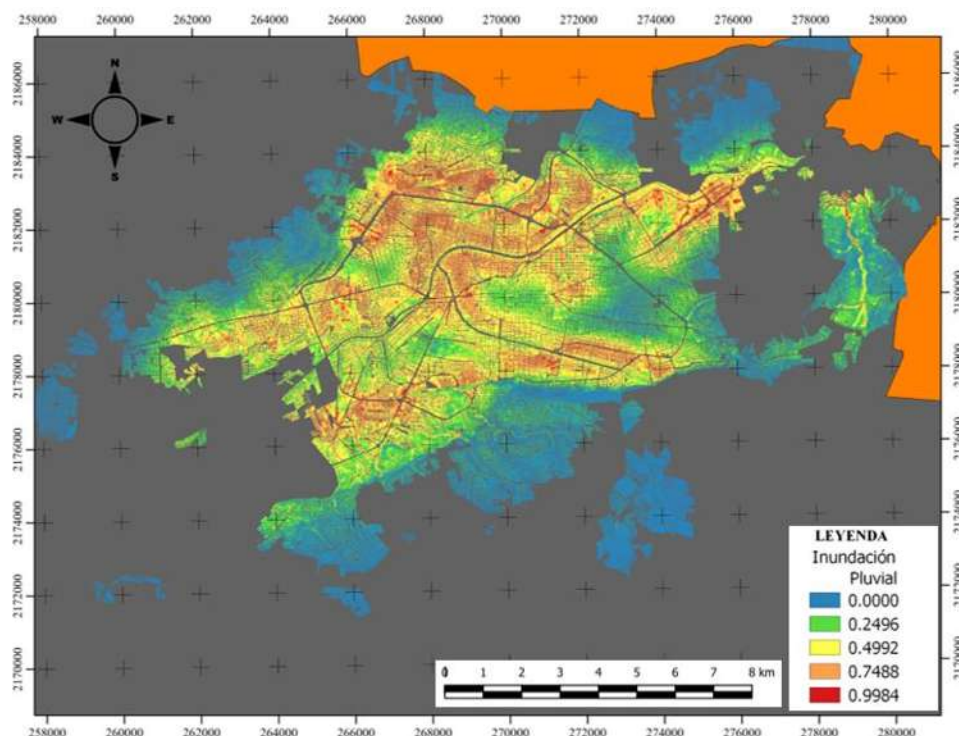


Figura 18. Mapa de probabilidad de inundación en la ciudad de Morelia (mapa de amenazas).

En la Tabla 11 se pueden apreciar los porcentajes de contribución de cada variable o factor predictivo en donde la variable de *distancia con ríos y canales* es la que mayor aportación genera con un 67.7 %, mientras que la segunda variable que más contribuye es la variable de *pendiente del terreno* con un 11.6%. Este porcentaje de contribución es un reflejo de la cantidad de información que el modelo toma de una variable para calcular la probabilidad de ocurrencia, en otras palabras, el factor predictivo de *distancias con ríos y canales* es el factor más influyente para que ocurra una inundación en la ciudad de Morelia.

Tabla 11. Porcentaje de contribución al modelo de los factores predictivos

Factor predictivo	Porcentaje de contribución
Distancia con ríos y canales	67.70
Pendiente del terreno	11.60
Uso de suelo	9.20
Elevación del terreno	8.50
Precipitación media anual	2.90

Analizando las curvas de respuesta (ver Figura 19), que el software MaxEnt entrega como producto de las ejecuciones del modelo, podemos encontrar la respuesta de la probabilidad de ocurrencia en función de cada uno de los valores de las variables predictoras. Encontramos que para la variable de *elevación del terreno* la probabilidad máxima se

presenta cerca de los 1900 msnm aproximadamente, para la *pendiente del terreno* se puede observar que la probabilidad se encuentra inversamente relacionada con esta, algo parecido ocurre con la *distancia con ríos y canales* donde a menor distancia mayor será la probabilidad de ocurrencia.

Por otro lado, los usos de suelo de zonas residenciales, vialidades, parques/jardines y zonas industriales (clases 1, 3, 4 y 6 respectivamente), son las clases que aumentan en mayor medida la probabilidad de ocurrencia, lo que puede estar relacionado con la gran cantidad de superficie pavimentada que impide la infiltración del agua, caso contrario de las clases 2 y 8 (zonas abiertas y bosques), que impiden los escurrimientos repentinos y favorecen la infiltración de las precipitaciones. Por último, se encontramos la curva de respuesta de la *precipitación media anual* donde se puede observar el pico máximo de probabilidad cerca de los 750 mm de precipitación. Se puede visualizar que el agrupamiento de los datos (curtosis) tiende a ser platicúrtica, lo que puede explicar la obtención del menor porcentaje de contribución al modelo.

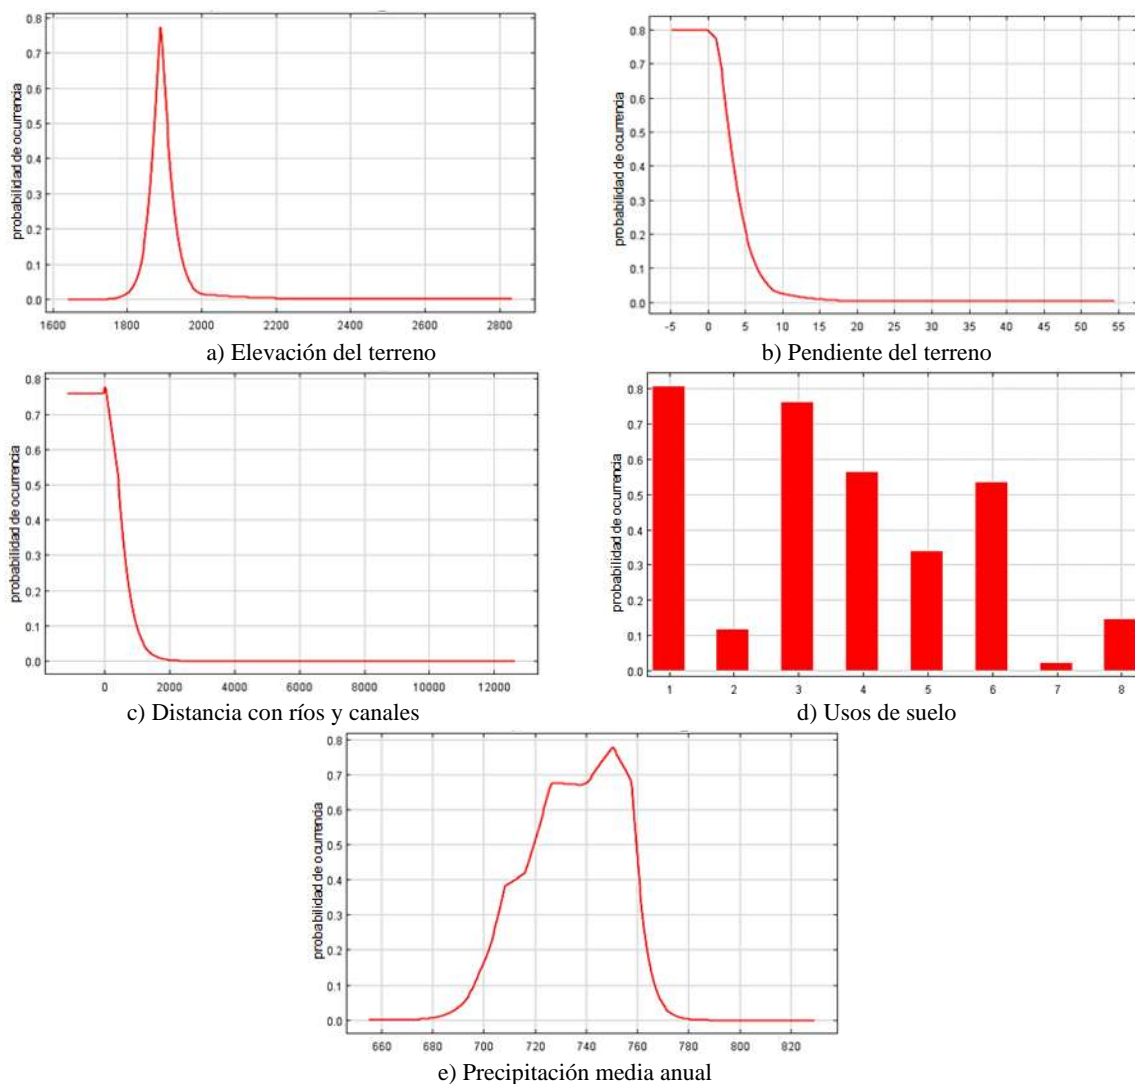


Figura 19. Curvas de respuesta resultado del modelo MaxEnt.

Como apoyo para validar el modelo generado se obtuvo la curva AUC-ROC, la cual es una métrica de evaluación que se usa para verificar el rendimiento de cualquier modelo de clasificación. El software calcula la curva ROC en función de la tasa de verdaderos positivos y la tasa de falsos positivos para posteriormente calcular el área bajo la curva (AUC por sus siglas en inglés). En la Figura 20 se pueden observar dos curvas ROC, una para el conjunto de entrenamiento y otra para el de prueba, en ambas se obtuvieron valores de 0.93 para el área bajo la curva AUC.

Una clasificación de forma aleatoria tiene un equivalente a una AUC de 0.5, y una clasificación perfecta alcanza una AUC de 1 (esto indicaría que el modelo separa las presencias de las usencias con un ajuste perfecto y sin errores). Tomando como punto medio entre una clasificación perfecta y una aleatoria el valor de 0.75, se puede considerar que cualquier modelo superior a 0.75 es un modelo útil (Elith, 2002). Otro criterio es el de De Larramendi Fortún (2017) quien establece la siguiente clasificación para decidir qué tan aceptable es un modelo:

- Modelo pobre si $AUC < 0.75$
- Modelo aceptable si $0.70 < AUC < 0.85$
- Modelo bueno si $0.85 < AUC < 0.95$
- Modelo excelente si $0.95 < AUC < 1.00$

Con lo anterior podemos considerar que el modelo que se obtuvo es un modelo bueno.




Figura 20. Resultados de validación del modelo MaxEnt mediante la curva AUC-ROC

También se puede realizar una comparación visual entre el mapa de amenazas obtenido con el modelo MaxEnt y el mapa interactivo de peligros (ver Figura 21), publicado por el Instituto Municipal de Planeación de Morelia (IMPLAN), en donde se pueden observar

similitudes en las zonas aledañas al Río Grande y Río Chiquito de Morelia, además de las llanuras de San Juanito Itzicuaro, las cuales son zonas que continuamente sufren de inundaciones.

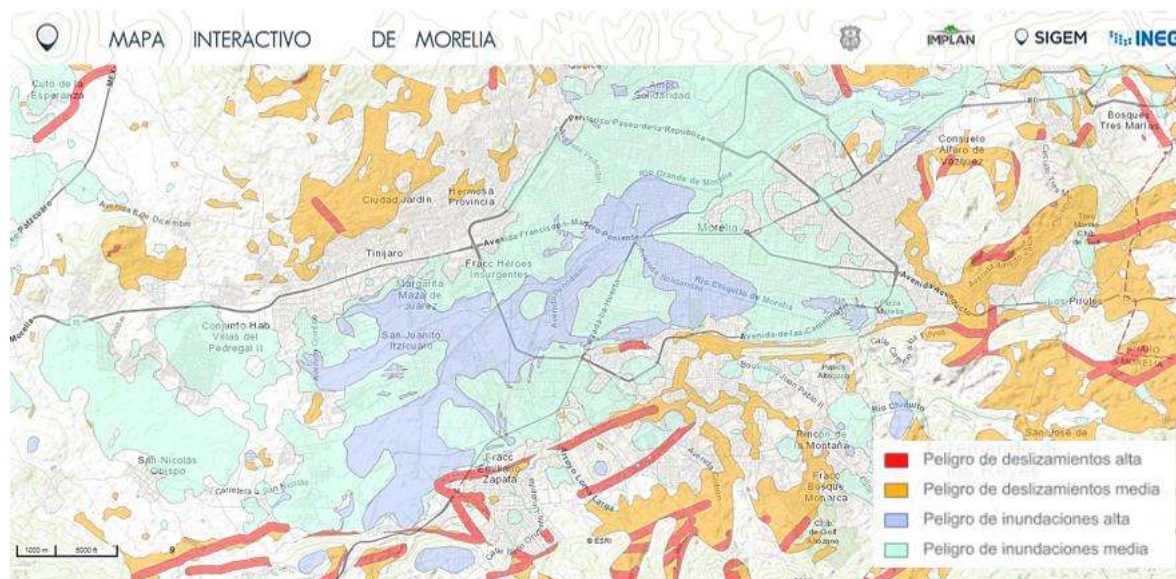


Figura 21. Mapa interactivo de peligros de la ciudad de Morelia. Fuente: IMPLAN <https://sigmorelia.gob.mx/>

7.1.3. Mapa de riesgo

Una vez que se obtuvieron los mapas de vulnerabilidad y amenaza fue posible crear el mapa de riesgo de la ciudad, obteniendo el producto entre la probabilidad de ambos mapas para así obtener el mapa de la Figura 22, el cual es el producto principal del análisis de riesgo.

En este mapa se pueden observar que las zonas de mayor riesgo se encuentran en las riberas de los ríos Grande y Chiquito, además de algunos drenes como el dren Barajas, Carlos Salazar y Itzicuaro. Sin duda, la causa de que esto sea así es por la gran contribución del factor predictivo de distancias con ríos y canales que fue usado en la elaboración del mapa de amenazas.

Existen algunas zonas como la zona centro histórico, que obtuvieron un alto nivel de vulnerabilidad, sin embargo, presentan un riesgo prácticamente nulo. Lo anterior se debe a que el riesgo se definió en función tanto de la probabilidad de que ocurra un evento de inundación como el grado de vulnerabilidad al que está sometida una determinada zona de la ciudad, ecuación (10). En este sentido, la ausencia de cualquiera de las dos variables dará como resultado un riesgo nulo.

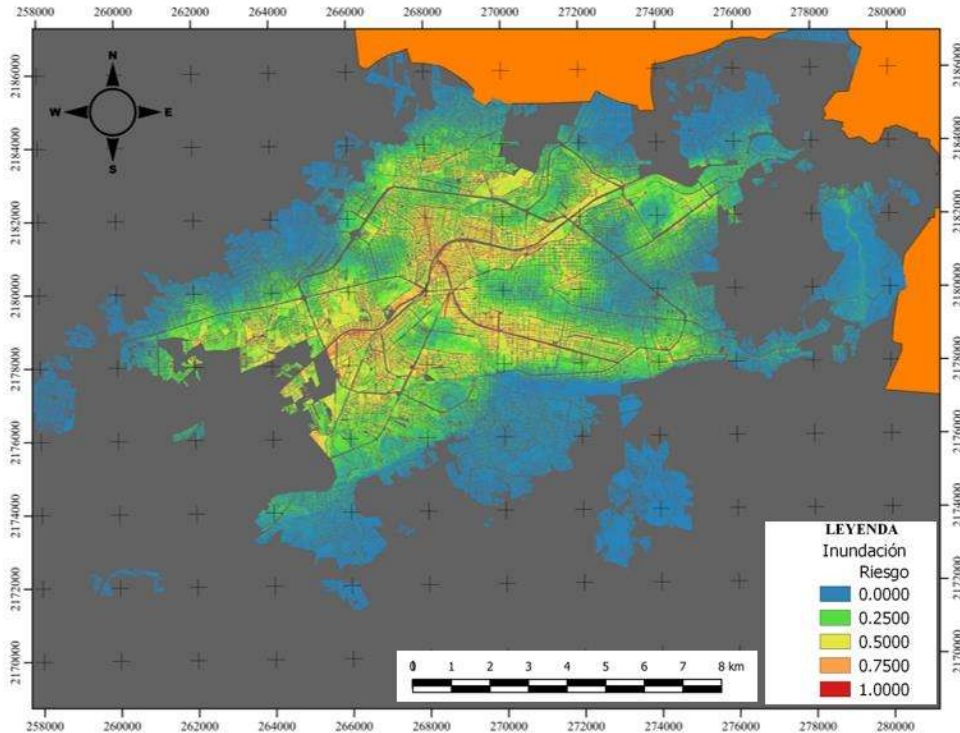


Figura 22. Mapa de riesgo ante inundaciones de la ciudad de Morelia.

7.2. Diseño de la red de monitoreo de variables climáticas

Como punto de partida, se decidió usar la red de monitoreo SAIH de Morelia desarrollada por Rodríguez et al. (2020), la cual contaba con protocolos de transmisión de información que funcionaban adecuadamente. Como resultado de aplicar el proceso sistemático (ver Figura 12) a la red SAIH se identificaron las áreas de oportunidad, además de se definieron los requerimientos necesarios para la nueva red.

Los nuevos requerimientos fueron realizar la modificación del sistema de alimentación de las EMA's para pasar del uso de paneles solares a ser alimentadas mediante corriente alterna de la red domestica de donde se realizó la instalación. Otro requerimiento importante fue diseñar un circuito impreso que permitiera un funcionamiento estable de las placas de desarrollo y sensores, además de permitir de manera más practica la reparación y mantenimiento de las estaciones, en la Figura 23 se puede observar las conexiones del circuito impreso desarrollado. Por último, se requirió crear una carcasa para el sensor de temperatura y humedad que evitará la acumulación de vapores y elevación de temperatura en horas pico de radiación solar.

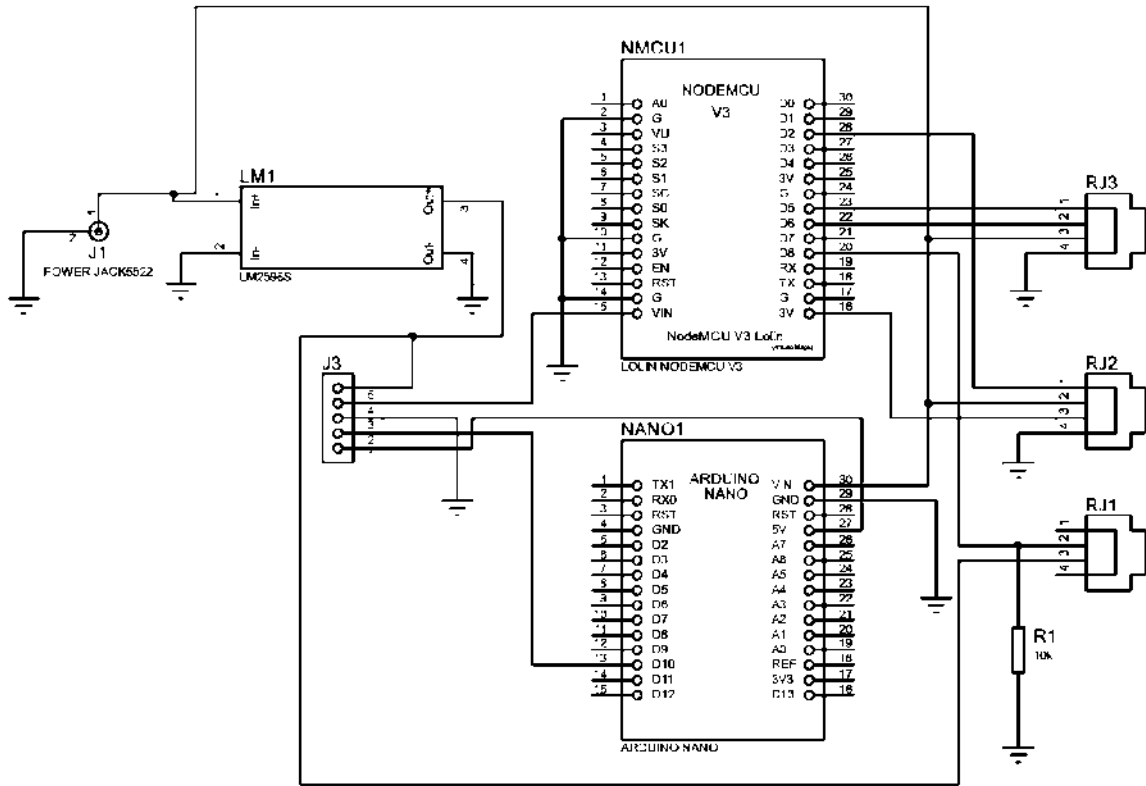



Figura 23. Diagrama de conexiones del circuito impreso desarrollado para la nueva configuración de las EMA's de la red SAIH.

Para la construcción de las EMA's (Figura 24) se decidió optar por la plataforma de prototipado Arduino, la cual cuenta con dos placas de desarrollo adecuadas para este proyecto. La placa Arduino Nano (Figura 25a) es una placa de desarrollo de tamaño compacto (lo que es ideal para el proyecto realizado), basada en el microcontrolador ATmega328P, posee las mismas capacidades que un Arduino UNO, tanto en potencia del microcontrolador como en conectividad. Esta placa cumple la tarea del reseteo de la estación cada determinado tiempo.



Figura 24. Ejemplo de construcción de la Estación Meteorológica Automática.

También se decidió usar una placa NodeMCU ESP8266 (Figura 25b), la cual es una tarjeta de desarrollo similar a Arduino, especialmente orientada al Internet de las cosas (IoT), característica importante para poder realizar el envío de información a la base de datos. Esta tarjeta se encarga de realizar las lecturas de los sensores además enviar las observaciones capturadas a la base de datos.



a) Placa de desarrollo Arduino Nano b) Placa de desarrollo NodeMCU ESP8266

Figura 25. Placas de desarrollo principales usadas en las EMA's de la red SAIH.

Respecto a los sensores, se optó por integrar un pluviómetro del tipo balancín (Figura 26) para medir precipitación. Este sensor funciona con un interruptor magnético que se activa cuando el balancín cambia de posición y hace pasar un pequeño imán cerca del interruptor.

El sensor DHT22 es el encargado de las lecturas de temperatura y humedad relativa del aire. Este integra un sensor capacitivo de humedad y un termistor para medir el aire circundante, su voltaje de operación es de 3V a 6V DC, puede medir temperaturas de -40°C a 80°C y su precisión es de $\pm 0.5^{\circ}\text{C}$, mientras que el rango de humedad va de 0 a 100 % con una precisión de 2%.



a) Pluviómetro de balancín con contador magnético b) Sensor de temperatura y humedad DHT22

Figura 26. Sensores usados en las EMA's de la red SAIH.

Para la base de datos se mantuvo la plataforma ThingSpeak de la red original SAIH, esta plataforma ofrece espacio de almacenamiento gratuito limitado, pero con el suficiente espacio para la cantidad de datos necesaria para la red. También cuenta con opciones de

visualización que permite graficar los datos obtenidos de las EMA's. Para el desarrollo del código de las tarjetas de desarrollo se usó el IDE de Arduino.

En las pruebas de funcionamiento se pudo observar un comportamiento estable de los protocolos de comunicación entre las EMA's y la base de datos. Respecto a la calibración de los sensores no existieron inconvenientes, con excepción del sensor DHT22 el cual mostraba tendencias en las temperaturas por arriba de los valores reales, esto debido a que la radiación solar aumentaba la temperatura del encapsulado del sensor. La solución a este problema fue recubrir el sensor con una carcasa (Figura 27) que permitiera el flujo del aire e impidiera que la radiación no llegara directamente al encapsulado.



Figura 27. Carcasa de recubrimiento para el sensor DHT22.

Para validar las lecturas del sensor DHT22 dentro de su nueva carcasa se realizó una comparación contra las lecturas de temperatura de la estación comercial Vantage Pro2 de la marca Davis Instruments, en la comparación de lecturas se muestra en la Figura 28.

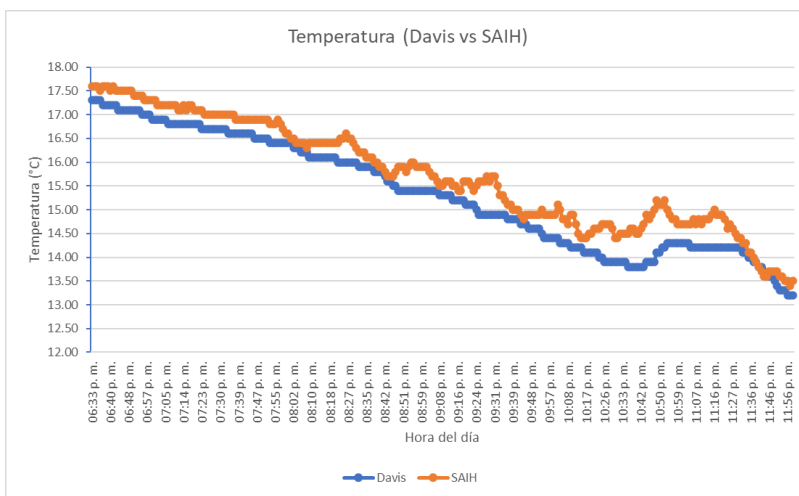


Figura 28. Comparación de lecturas de temperaturas entre el sensor una estación comercial Davis Instruments y el sensor de una EMA.

Se desplegaron un total de 12 EMA's con capacidad de recopilar datos de precipitación, temperatura y humedad relativa. El monitoreo se programó para que se realice a cada minuto y es mostrado en la página web <http://saihumich.com/> (Mejía F. et al., 2023), que cuenta con un conjunto de opciones de visualización que permite activar o desactivar variables climáticas, además de incorporar indicadores dinámicos de color que cambian de acuerdo a la intensidad de la lluvia.

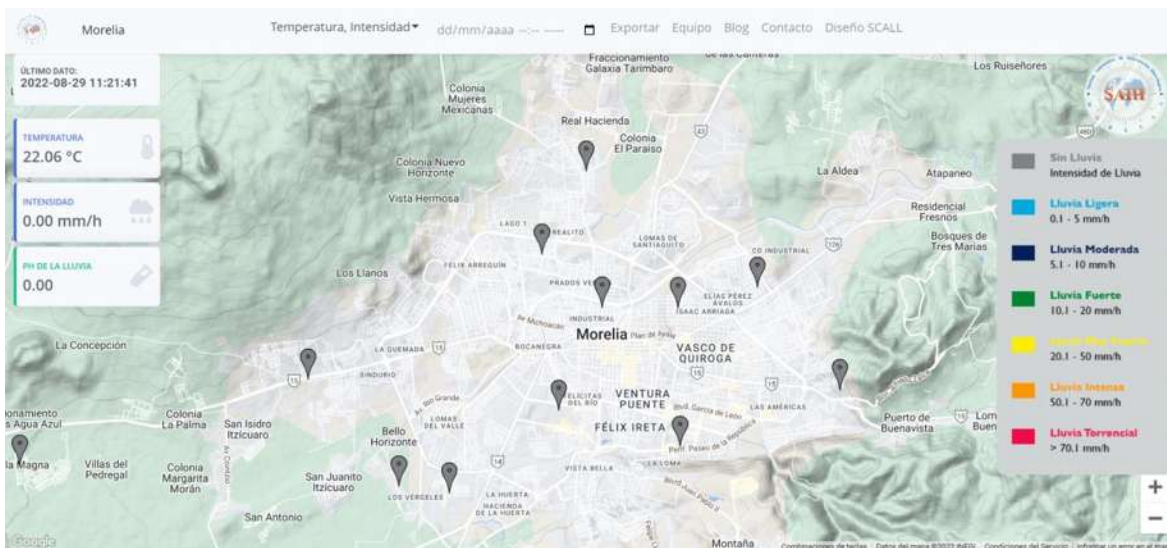


Figura 29. Plataforma web SAIH para la visualización de datos en tiempo real.

7.3. Modelo de pronóstico con Redes Neuronales Artificiales

En este subcapítulo se mostrarán los resultados más sustanciales que se obtuvieron en la fase de la creación del modelo de pronóstico con una red neuronal. Se hará énfasis en los subprocesos de ingeniería de características y el entrenamiento que pertenecen al proceso metodológico de la Figura 13.

Limpieza y manipulación de datos

Primeramente, se realizó la limpieza de datos que consistió en eliminar las observaciones nulas o anómalas para posteriormente realizar la manipulación de los datos que básicamente es el proceso de filtrar, transformar, agregar y visualizar las variables a utilizar. En la Figura 30 podemos observar la evolución de las variables utilizadas a lo largo de un día, este tipo de gráficos fueron útiles para entender el comportamiento de las variables antes y después de que ocurriera un evento de precipitación. Uno de los patrones que generalmente ocurren momentos antes de comenzar a llover es la caída repentina de la temperatura y el aumento de la humedad relativa generándose un cruce en el gráfico, minutos después de estos sucesos la precipitación suele ocurrir.




Figura 30. Patrón de comportamiento de la variable de precipitación contra las variables de temperatura y humedad relativa.

Ingeniería de características

Una vez analizado el comportamiento de los datos entre sí, se procedió estructurar los datos de tal forma que para la red neuronal fuera más sencillo extraer las características propias de los datos utilizados. Esta estructuración de los datos se refiere a cómo se relacionan los datos de entrada con los datos de salida para que la red neuronal aprenda a pronosticar un valor de salida en función de los datos de entrada. En la Figura 31 se puede observar la estructura base que se planteó para usarse en el entrenamiento de la red, con esta estructura se planteó pronosticar una o más observaciones de precipitaciones (barras azules), las cuales son los datos de salida, en función de un conjunto de observaciones de otras variables como temperatura y/o humedad relativa, las cuales fueron los datos de entrada, que en el caso de la Figura 31 solo se aprecian las observaciones de temperatura en color rojo.

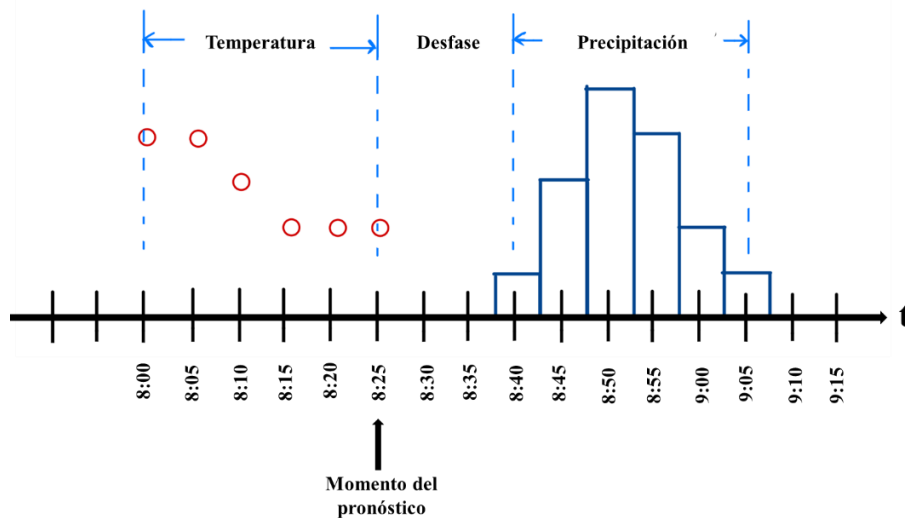


Figura 31. Estructura de datos básica de los datos de entrada y salida usados en el entrenamiento de la red neuronal.

Con la estructura anterior surgió la necesidad de encontrar los valores adecuados de algunos parámetros propios de la estructura, como lo fueron las variables de entrada a usar y su número de observaciones en el pasado, que en el caso de la Figura 31 se pueden ver seis observaciones de temperatura antes del momento del pronóstico. Otro parámetro a definir fue la cantidad de observaciones de precipitación que se podrían pronosticar de manera adecuada y por supuesto, también se tuvo que definir el tiempo de desfase entre las observaciones de entrada y las de salida, este tiempo de desfase se refiere al tiempo de anticipación con el cual se realizarían las predicciones a futuro, por ejemplo, en la Figura 31 se puede observar un tiempo de anticipación o desfase de 25 minutos, efectuándose el pronóstico a las 8:25 para conocer las precipitaciones que sucederían de las 8:40 a 9:05.

Con cada estructura planteada se completó el flujo de trabajo de la Figura 13 regresando a este punto (ingeniería de características) cada vez que el error no era aceptable con la finalidad de reestructurar los datos y encontrar relaciones ocultas entre los datos de entrada y salida. La estructura final que obtuvo mejores resultados se explica a continuación.

Uno de los supuestos que se habían planteado fue que los pronósticos podrían ser más precisos si se agregaban otras variables independientes (como temperatura y humedad relativa), como apoyo para predecir las observaciones de precipitación, sin embargo, se encontró que si se usaba la misma variable de precipitación como variable de entrada y de salida la precisión en los pronósticos aumentaba significativamente. Los datos de la Figura 32 representan una tormenta de ejemplo que se usará para explicar la estructura que se les dio a los datos utilizados en el entrenamiento.

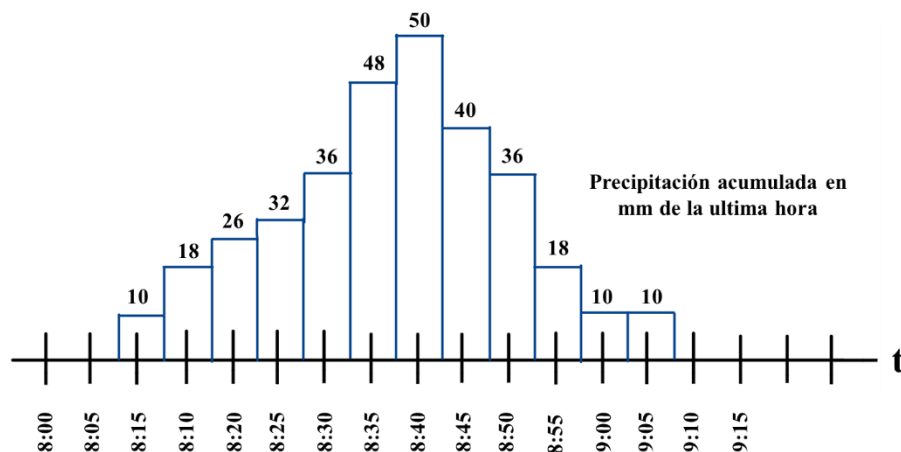


Figura 32. Datos de una tormenta de ejemplo con precipitaciones acumuladas en la última hora.

Originalmente las observaciones se encontraban en intervalos de 5 minutos por lo que se tuvo que pasar de precipitaciones acumuladas en la última hora, por ejemplo, la precipitación de 10 mm de las 8:15 que se observa en la Figura 32 representaría la precipitación que se acumuló de las 7:15 a las 8:15. Con lo anterior, se pretendió que la red neuronal pudiera pronosticar el volumen de precipitación además de darle más información a la red de lo que ha ocurrido en el pasado. El razonamiento de la decisión anterior se puede

explicar afirmando que a medida que la tormenta se va descargando disminuye su intensidad y a su vez el volumen de agua precipitable también baja, o en otras palabras, se puede decir que el volumen de agua precipitable en el futuro depende de lo que ya ha caído en minutos atrás. En la Figura 33 se puede observar la segmentación de la tormenta de la Figura 32 en muestras individuales, cada una de estas muestras es un patrón que la red neuronal tuvo que aprender.

Estas muestras están conformadas por un conjunto de datos de entrada (barras punteadas en rojo), que son las mismas precipitaciones acumuladas, pero en el pasado y la precipitación acumulada a pronosticar (barra sólida en azul). Al igual que la estructura de datos mostrada en la Figura 31, se tuvieron que ajustar ciertos parámetros propios de esta nueva estructura lo que derivó de un análisis de sensibilidad, donde se comparaba la precisión de los pronósticos en función del ajuste de estos parámetros.

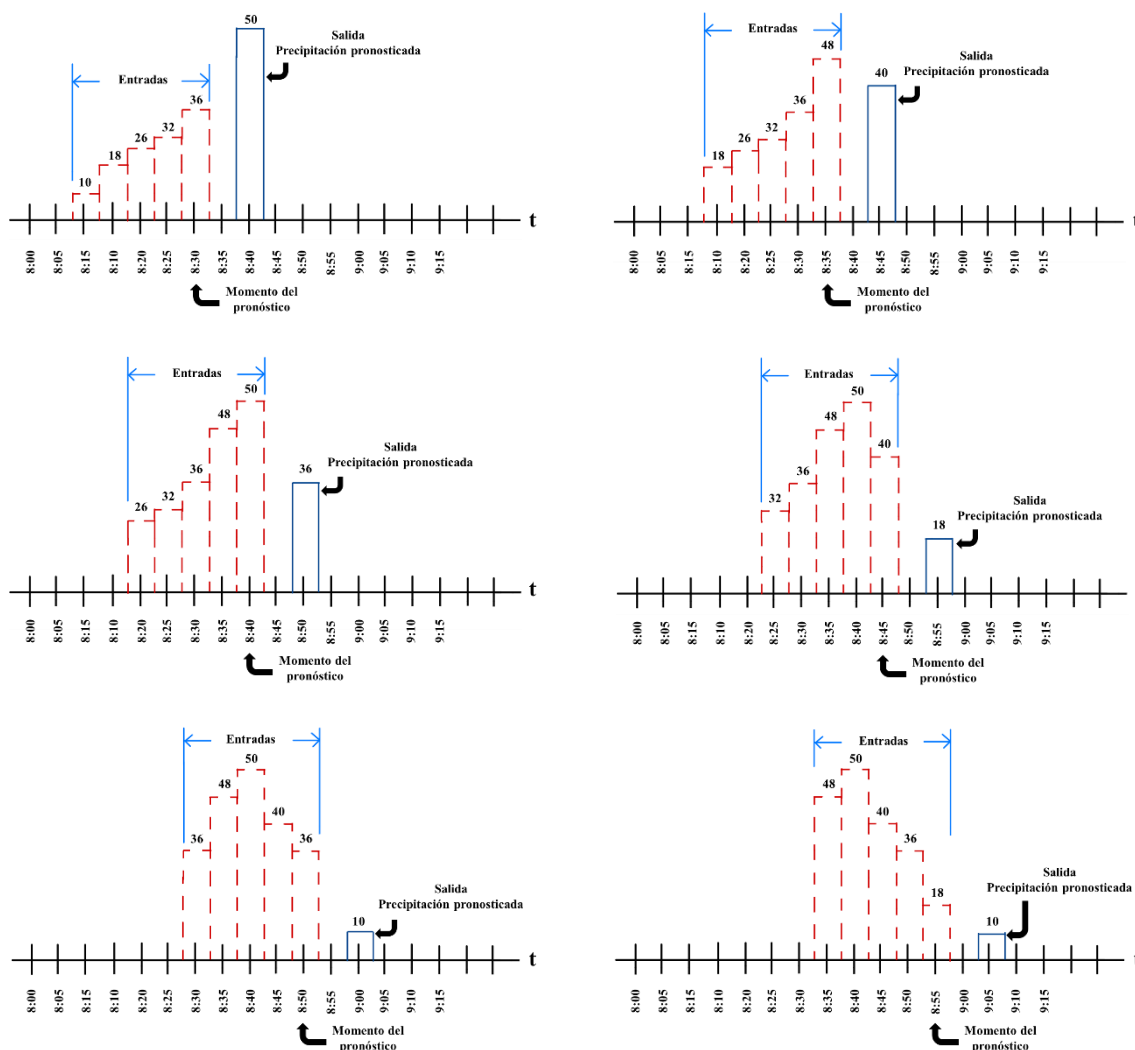


Figura 33. Segmentación de la tormenta en muestras individuales para ser ingresadas a la red neuronal.

Los parámetros que se tuvieron que ajustar se encuentran descritos en la Tabla 12. Al finalizar este subcapítulo se mostrarán los parámetros e hiperparámetros que mejor precisión dieron en los pronósticos de la etapa de evaluación.

Tabla 12. Parámetros de ajuste para la estructura final utilizada.

Parámetro	Descripción
Delta	Tiempo hacia atrás para la acumulación de la precipitación, en el caso de la Figura 32 se acumularon de la última hora.
Minutos de entradas	Tiempo que abarcaban las observaciones de entrada de la red neuronal o cantidad de observaciones a cada 5 minutos, en el caso de la Figura 33 se observan 20 minutos de observaciones de entrada.
Minutos de anticipo	Tiempo de desfase entre el momento del pronóstico y la precipitación pronosticada, en el caso de la Figura 33 se pronostica con un desfase de 10 minutos.
Entradas	VARIABLES de entrada de la red neuronal
Salidas	VARIABLES de salida de la red neuronal

Creación de los conjuntos de entrenamiento, validación y prueba.

Una vez definida la estructura de los datos a usarse en el entrenamiento fue necesario crear los conjuntos de entrenamiento y prueba. Aunque no existe un acuerdo en la cantidad de muestras que cada conjunto debe de contener se recomienda dejar la mayor cantidad de datos posible para el entrenamiento, así la red neuronal tendrá una cantidad mayor de patrones que aprender (Chollet, 2018). De las 715 000 muestras disponibles se decidió usar un 80 y 20 por ciento para los conjuntos de entrenamiento y prueba, respectivamente. Por otro lado, el conjunto de validación se desprendió del conjunto de entrenamiento usando un método llamado K-Fold que a continuación se describe.

Fue necesario barajar las muestras de manera aleatoria para evitar sesgos en el aprendizaje, posteriormente el conjunto total de entrenamiento se dividió en k subconjuntos, todos de igual tamaño. El objetivo era el realizar k entrenamientos de tal manera que el conjunto de validación iba cambiando de subconjunto para obtener un score o puntaje por entrenamiento, para posteriormente obtener un score promedio de todos los entrenamientos, la función usada para obtener este puntaje fue el error absoluto medio.

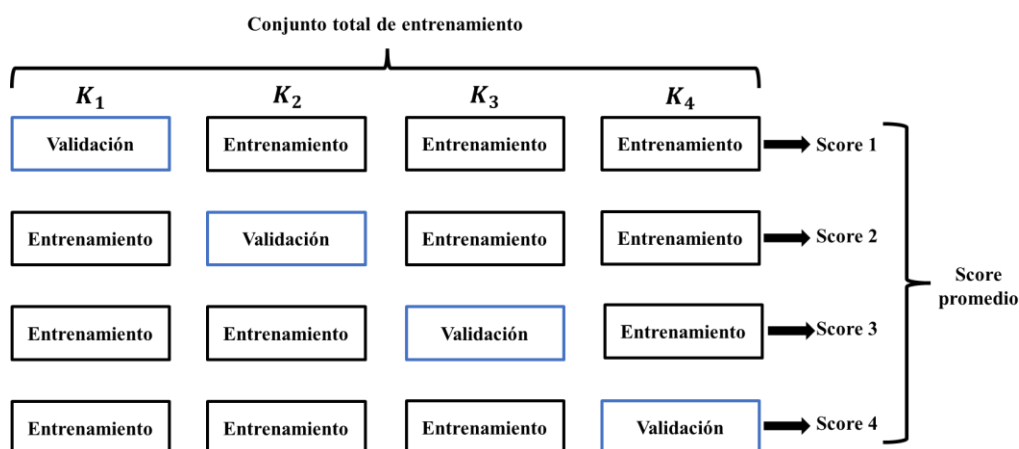


Figura 34. Metodo K-Fold para la evaluación del entrenamiento de una red neuronal.

Finalmente, los datos de entrada fueron normalizados como lo indica la ecuación (23) para poder iniciar con el proceso de entrenamiento.

Entrenamiento

Para ejecutar el entrenamiento fue necesario usar la librería de código abierto de Python, Keras 2.4.3. Esta librería ofrece una gran variedad de funciones precodificadas que optimizan el proceso de entrenamiento de una red neuronal. Recordando que el objetivo del entrenamiento es el ajuste de los hiperparametros de la red neuronal, es decir, encontrar el número adecuado de capas ocultas y cuantas neuronas contiene, además de definir algunos parámetros del aprendizaje como las funciones de activación de cada una de las capas de la red, la función optimizadora, de costo y la función de costo. Cabe mencionar que los hiperparametros de los pesos y sesgos se ajustan automáticamente por el algoritmo de Backpropagation ya codificado dentro de Keras.

Dado que este proceso de ajuste es un proceso iterativo se tuvo que crear una función que permitiera la modificación de manera sencilla de todos los parámetros antes mencionados, el fragmento del código de muestra a continuación.

```
def obtener_modelo():
    model = models.Sequential()
    model.add(layers.Dense(capas_ocultas[0], activation='relu',
                           input_shape=(entradas_train_rest.shape[1],)))

    for c in range(1, len(capas_ocultas)):
        model.add(layers.Dense(capas_ocultas[c], activation='relu'))
    model.add(layers.Dense(1))
    model.compile(optimizer=optimizador, loss=func_costo, metrics=[func_metrica])

    return model
```

Uno de los problemas que suelen presentarse en el proceso de entrenamiento es el overfitting, el cual representan un sobre ajuste de la red neuronal provocando que el conjunto de entrenamiento siga minimizando la función de costo mientras el conjunto de validación comienza a maximizar el costo, produciendo así pronósticos alejados de la realidad. En la Figura 35 se encuentra la curva de aprendizaje que se obtuvo de la mejor configuración para la red neuronal final, en ella se puede observar una línea punteada roja representando los datos de validación en un caso de overfitting mientras la línea sólida roja representa el caso de un ajuste adecuado de la red donde los costos del conjunto de validación y entrenamiento mantienen la misma tendencia, significando así que la red neuronal tiene la capacidad de asemejar sus predicciones a los datos reales.

El overfitting también puede ser corroborado si se grafica la curva de aprendizaje con la función usada para la evaluación del entrenamiento, ver Figura 36.

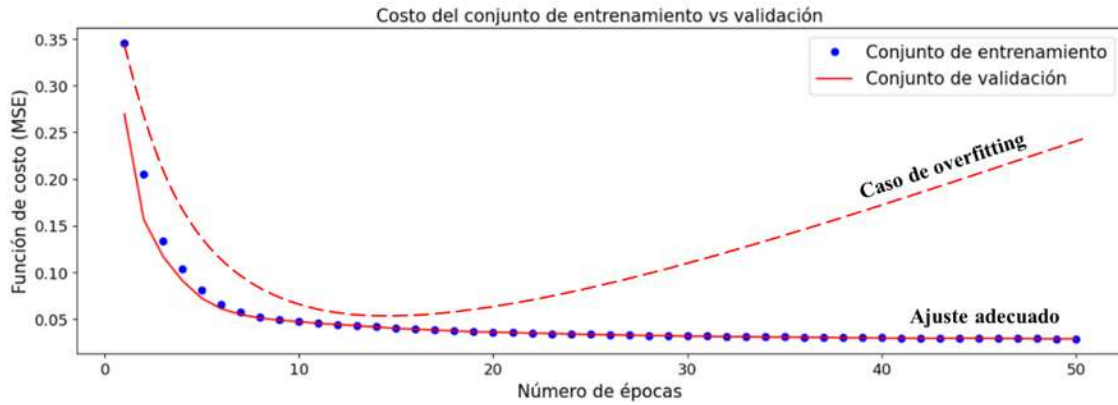


Figura 35. Curva de aprendizaje de la red usando la función de costo del error cuadrático media (MSE) con un ejemplo de overfitting.

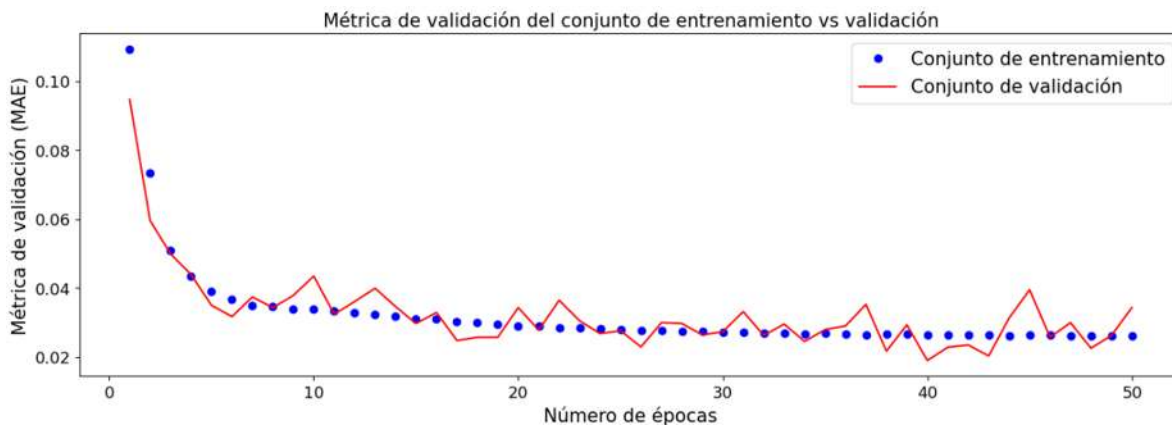


Figura 36. Curva de aprendizaje de la red usando la función de validación del error absoluto medio (MAE).

Para evitar el overfitting y encontrar el error más bajo se tuvieron que ajustar los hiperparámetros correctos de la red neuronal los cuales se muestran en la Tabla 13.

Tabla 13. Hiperparámetros y características ajustadas para la red neuronal utilizada.

Hiperparámetro o Característica	Descripción
Capa de entrada	Capa inicial única donde se ingresan las variables de entrada a la red neuronal, su cantidad de neuronales está definida por la estructura que se haya elegido.
Capas ocultas	Capa encargada de prender los patrones de los datos de entrenamiento, la cantidad de neuronas y capas es variable y depende del criterio de la persona que entrena la red.
Capa de salida	Capa final única donde salen las predicciones de la red la cantidad de neuronas depende de la cantidad de valores a predecir.
Optimizador	Mecanismo a través del cual la red se actualizará en función de los datos que ve y su función de pérdida, mecanismo que aplica el algoritmo Backpropagation.
Función de activación	Función que otorga a la red neuronal la no linealidad necesaria para ajustarse a las dimensiones necesarias de los datos utilizados
Función de costo	Función que la red trata de minimizar a cero para ajustar sus hiperparámetros.
Función de evaluación	Función que es usada para evaluar la calidad del entrenamiento.
Épocas	Numero de iteraciones en que la red pasa todo el conjunto de datos a través de ella.

El ajuste de los parámetros tanto de la Tabla 12 como de la Tabla 13 dieron como resultado un análisis de sensibilidad, en el cual se encontró la mejor configuración de la red neuronal que arrojaba los mejores índices de bondad de ajuste de Nash-Sutcliffe efficiency (NSE) y Kling-Gupta efficiency (KGE). En la Tabla 14 se muestra un resumen de todos los parámetros o características que se ajustaron para los mejores cinco entrenamientos, además de agregar los índices de bondad de ajuste alcanzados de NSE y KGE.

Tabla 14. Resultado del ajuste de parámetros de los mejores cinco entrenamientos.

Parámetro o Característica	Entrenamiento				
	1	2	3	4	5
Delta (minutos)	60	60	60	60	60
Minutos de entradas	30	30	30	30	30
Minutos de anticipo	10	10	10	10	10
Entradas	Precipitación	Precipitación	Precipitación	Temperatura, Humedad	Temperatura, Humedad
Salidas	Precipitación	Precipitación	Precipitación	Precipitación	Precipitación
Capa de entrada	[7]	[7]	[7]	[14]	[14]
Capas ocultas	[7]	[8]	[12]	[15]	[25]
Capa de salida	[1]	[1]	[1]	[1]	[1]
Optimizador	rmsprop	rmsprop	rmsprop	rmsprop	rmsprop
Función de activación	relu	relu	relu	relu	relu
Épocas	50	50	50	75	100
MSE	0.025	0.024	0.027	0.053	0.065
MAE	0.015	0.015	0.015	0.020	0.032
NSE	0.965	0.966	0.962	0.926	0.972
KGE	0.931	0.929	0.917	0.899	0.886

Evaluación de la red neuronal entrenada

Valores del NSE y KGE igual a 1 indican un acuerdo perfecto entre simulaciones y observaciones, análogamente un NSE y KGE igual a 0 indican lo contrario. Algunos autores afirman que $KGE < 0$ indica que la media de las observaciones proporciona mejores estimaciones que las simulaciones (Castaneda-Gonzalez et al., 2018; Koskinen et al., 2017), aunque otros afirman que esta interpretación no debe atribuirse a $KGE = 0$ (Gelati et al., 2018; Mosier et al., 2016). Varios autores utilizan valores KGE positivos como indicativos de simulaciones de modelos "buenos", mientras que los valores negativos de KGE se consideran "malos", sin indicar explícitamente que tratan $KGE = 0$ como su umbral entre el rendimiento "bueno" y "malo". Por ejemplo, Rogelis et al. (2016) consideran que el rendimiento del modelo es "pobre" para $0,5 > KGE > 0$, y no se mencionan los valores negativos de KGE mientras que Schönfelder et al. (2017) consideran que los valores negativos de KGE "no son satisfactorios".

Andersson et al. (2017) considera a los valores negativos de NSE y KGE como valores no deseados. Fowler et al. (2018) consideran deseable reducir el número de ocurrencias de

valores negativos de KGE. Siqueira et al. (2018) consideran que el comportamiento del conjunto es indeseable siempre que produzca valores negativos de KGE y NSE.

Existen algunos autores como Moriasi et al. (2007) que se atreven a delimitar aún más los puntajes alcanzados por el NSE. En la Tabla 15 se muestran la delimitación de cada uno de los rangos.

Tabla 15. Delimitación de los puntajes para el índice NSE. (Moriasi et al., 2007)

Descripción	Puntaje
Muy bueno	$0.75 < NSE \leq 1.00$
Bueno	$0.65 < NSE \leq 0.75$
Satisfactorio	$0.50 < NSE \leq 0.65$
No satisfactorio	$NSE \leq 0.50$

Se puede afirmar que la calidad y precisión de los pronósticos calculados fueron muy buenos de acuerdo a las referencias anteriormente mencionadas. Cabe mencionar que los índices NSE y KGE fueron calculados con el conjunto de prueba, el cual se reservó para ser utilizado con la red neuronal por lo que se puede decir que la capacidad de generalización de la red neuronal es alta. En la Figura 37 se pueden observar los datos observados contra los pronosticados.

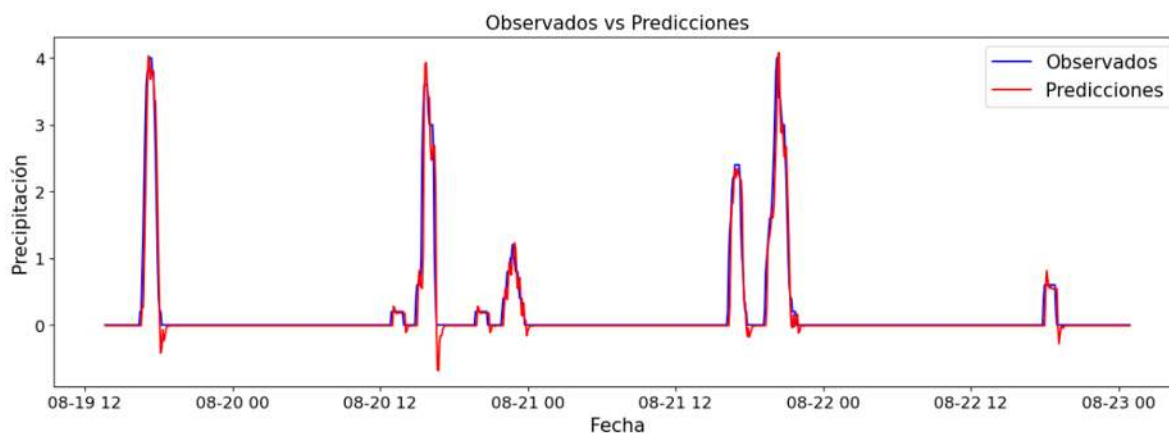


Figura 37. Comparación gráfica entre las precipitaciones observadas y pronosticadas por la red neuronal.

7.4. Plataforma digital

Como se mencionó anteriormente, esta plataforma digital es parte del sistema de pronóstico de lluvias intensas y tiene como objetivo ejecutar permanentemente el modelo de red neuronal ya entrenado, al cual se le ingresan las lecturas en tiempo real de las estaciones meteorológicas para generar los pronósticos de lluvia y en caso de superar el umbral establecido emitir una alerta. La red neuronal y su configuración entrenada fue exportada en un formato HDF5, el cual es un Formato de Dato Jerárquico o en inglés Hierarchical Data Format (HDF), que permite guardar información multidimensional útil para guardar toda la configuración, pesos y sesgos de la red neuronal.

En la Figura 38 se puede apreciar el diagrama de flujo que realiza la plataforma digital para producir los pronósticos y emitir las alertas en caso de que el umbral definido sea superado. La plataforma comienza por cargar una única vez el archivo HDF5 de la red neuronal, posteriormente entra en un bucle infinito donde cada 5 minutos está evaluando si existe una nueva lectura en la base de datos de ThingSpeak, la cual almacena las lecturas de las estaciones meteorológicas. Posteriormente es necesario realizar un acomodo de las lecturas de tal forma que se adecuen al formato de entrada de la red, debido a que esta necesita las últimas 7 observaciones disponibles de las estaciones meteorológicas. Una vez que se realiza dicha manipulación es posible generar el pronóstico ejecutando la red, si el pronóstico generado es superior al umbral definido se realiza el envío de la alerta a los usuarios del sistema mediante correo, en caso contrario la plataforma espera 5 minutos para volver a generar el pronóstico con las siguientes observaciones disponibles en la base de datos de ThingSpeak.

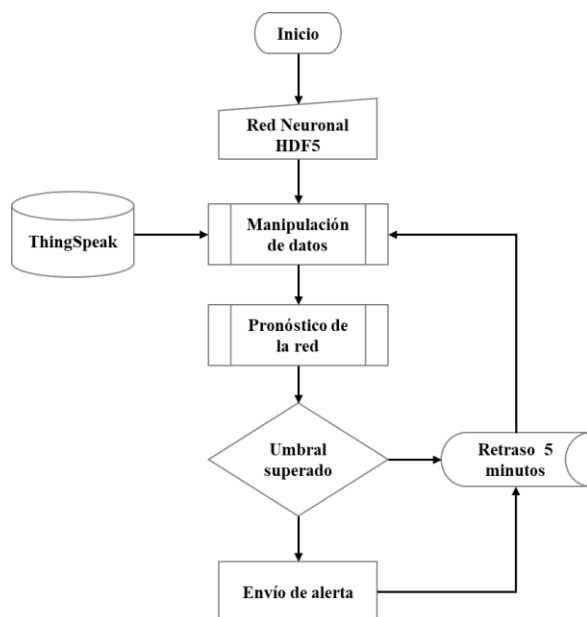


Figura 38. Diagrama de flujo de la plataforma digital para ejecutar los pronósticos y emisión de alerta.

8. Conclusiones

En este trabajo se desarrolló un Sistema de Alerta Temprana y se evaluó la fiabilidad de sus alertas y la precisión para pronosticar lluvias intensas a corto plazo en la ciudad de Morelia. Los índices de bondad de ajuste de Nash-Sutcliffe efficiency y Kling-Gupta efficiency mostraron que la precisión de los pronósticos fue muy buena, de acuerdo a los criterios de diversos autores.

También se desarrolló un conjunto de estaciones meteorológicas de bajo costo para elaborar una red de monitoreo de variables climáticas en tiempo real, obteniendo lecturas muy similares a las que llega a ofrecer un equipo profesional, con esto queda en evidencia las ventajas de utilizar este tipo de equipo que ofrece una buena relación costo-beneficio.

Por otro lado, se obtuvo un mapa de riesgo con la finalidad de zonificar los sitios de alto riesgo en la ciudad que estarían sujetos a sufrir daños con el desencadenamiento de una lluvia fuerte que provoque una inundación. Aunque el sistema no pronostica inundaciones fue necesario relacionar las lluvias pronosticadas con el evento resultante, que en este caso son las inundaciones causantes directas de las afectaciones a la población. Es importante señalar que el mapa de riesgo tiene un componente subjetivo, debido a los criterios dados por los expertos consultados para construir el mapa de vulnerabilidad por lo que este mapa no representa una zonificación del riesgo absoluto si no que queda sujeta a los subcriterios que se deseen resaltar para el mapa de vulnerabilidad.

Uno de los retos importantes fue la creación de un modelo de pronóstico mediante la implementación de una red neuronal artificial, específicamente en la etapa de ingeniería de características, en la cual se probaron distintas estructuras de datos que trataban de hacer evidentes las relaciones ocultas entre las variables independientes (entradas) y la variable dependiente (salida). Una de las asunciones que se tenían antes de comenzar la creación del modelo era que la precisión de los pronósticos resultaría más alta si se integraban más variables climáticas como variables independientes, sin embargo, con el análisis de sensibilidad realizado, se encontró que los pronósticos aumentaban su precisión utilizando como variable de entrada, pero con observaciones en el pasado, a la misma variable objetivo (precipitación).

El Sistema de Alerta Temprana desarrollado en este trabajo realiza pronósticos de lluvias intensas, los cuales son tomados para emitir una alerta si es que dicho pronóstico supera un umbral definido por las categorías del Servicio Meteorológico Nacional de México. Una de las líneas de investigación futuras sería el cálculo de dicho umbral mediante un análisis a profundidad de la relación lluvia-escurrimiento que indique, de forma más objetiva y específica de cada zona de la ciudad, cuál sería el umbral adecuado que se debería de tomar para emitir una alerta. Además de utilizar en un futuro, la información recolectada por las estaciones desarrolladas en este trabajo y integrar la componente espacial al modelo de pronóstico mediante redes neuronales.

9. Bibliografía

- Ahmad, S. S., & Simonovic, S. P. (2013). Spatial and temporal analysis of urban flood risk assessment. *Urban Water Journal*, 10(1), 26–49. <https://doi.org/10.1080/1573062X.2012.690437>
- Ahmed, B., Rahman, M. S., Islam, R., Sammonds, P., Zhou, C., Uddin, K., & Al-Hussaini, T. M. (2018). Developing a dynamic web-GIS based landslide early warning system for the Chittagong metropolitan area, Bangladesh. *ISPRS International Journal of Geo-Information*, 7(12). <https://doi.org/10.3390/ijgi7120485>
- Alcántara-Ayala, I. (2019). Desastres en México: mapas y apuntes sobre una historia inconclusa Disasters in Mexico. *Investigaciones Geográficas*, 100. <https://doi.org/10.14350/rig.60025>
- Andersson, J. C. M., Arheimer, B., Traoré, F., Gustafsson, D., & Ali, A. (2017). Process refinements improve a hydrological model concept applied to the Niger River basin. *Hydrological Processes*, 31(25), 4540–4554. <https://doi.org/10.1002/hyp.11376>
- Applequist, S., Garhs, G., & Pfeffer, R. (2002). Comparisons of methodologies for probabilistic quantitative precipitation forecasting. *Weather and Forecasting*, 17 (4), 783–799.
- Barry, R., & Chorley, R. (1895). *Atmósfera, Tiempo y Clima*. Omega.
- Basheer, I. ., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 43(1), 3–31. [https://doi.org/10.1016/S0167-7012\(00\)00201-3](https://doi.org/10.1016/S0167-7012(00)00201-3)
- Basheer, I. A. (1998). Neuromechanistic-based modeling and simulation of constitutive behavior of finegrained soils. In *PhD Dissertation*. Kansas State University.
- Basher, R. (2006). *Global early warning systems for natural hazards: systematic and people-centred*. June, 2167–2182. <https://doi.org/10.1098/rsta.2006.1819>
- Benzerra, A., Cherrared, M., Chocat, B., Cherqui, F., & Zekiouk, T. (2012). Decision support for sustainable urban drainage system management: A case study of Jijel, Algeria. *Journal of Environmental Management*, 101, 46–53. <https://doi.org/10.1016/j.jenvman.2012.01.027>
- Berkhahn, S., Fuchs, L., & Neuweiler, I. (2019). An ensemble neural network model for real-time prediction of urban floods. *Journal of Hydrology*, 575(May), 743–754. <https://doi.org/10.1016/j.jhydrol.2019.05.066>
- Briones-Gamboa, F. (2007). La complejidad del riesgo: breve análisis transversal. *Revista de La Universidad Cristóbal Colón*, 20, 9–19.
- Büyüközkan, G., Ertay, T., Kahraman, C., & Ruan, D. (2004). Determining the importance weights for the design requirements in the house of quality using the fuzzy analytic network approach. *International Journal of Intelligent Systems*, 19(5), 443–461.
- Caram, M., & Pérez, S. (2006). Entre el riesgo ambiental y el riesgo social: buscando una

salida a la tenencia irregular. *Revista Argentina de Sociología*, 4(6), 50–64.

- Castaneda-Gonzalez, M., Poulin, A., Romero-Lopez, R., Arsenault, R., Chaumont, D., Paquin, D., & Brissette, F. (2018). Impacts of Regional Climate Model Spatial Resolution on Summer Flood Simulation. *13th International Conference on Hydroinformatics*, 372–362.
- Cavazos, T. (1997). Downscaling large-scale circulation to local winter rainfall in North-Eastern Mexico. *International Journal of Climatology*. *International Journal of Climatology*, 17, 1069–1082.
- Chang, D. Y. (1996). Applications of the extent analysis method on fuzzy AHP. *European Journal of Operational Research*, 95(3), 649–655. [https://doi.org/10.1016/0377-2217\(95\)00300-2](https://doi.org/10.1016/0377-2217(95)00300-2)
- Chollet, F. (2018). Deep Learning with Python. In *Deep Learning with Python*. Manning Publications Co. <https://doi.org/10.1007/978-1-4842-5364-9>
- D. N. Moriasi, J. G. Arnold, M. W. Van Liew, R. L. Bingner, R. D. Harmel, & T. L. Veith. (2007). Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3), 885–900. <https://doi.org/10.13031/2013.23153>
- Darabi, H., Choubin, B., Rahmati, O., Torabi Haghghi, A., Pradhan, B., & Kløve, B. (2019). Urban flood risk mapping using the GARP and QUEST models: A comparative study of machine learning techniques. *Journal of Hydrology*, 569, 142–154. <https://doi.org/10.1016/j.jhydrol.2018.12.002>
- De Larramendi Fortún, M. R. (2017). *Diseño de metodología y desarrollo de recursos para la modelización de especies exóticas invasoras; análisis de su aplicabilidad en el caso de Vespa velutina* [Universidad Pública de Navarra]. <https://hdl.handle.net/2454/25899>
- Eini, M., Kaboli, H. S., Rashidian, M., & Hedayat, H. (2020). Hazard and vulnerability in urban flood risk mapping: Machine learning techniques and considering the role of urban districts. *International Journal of Disaster Risk Reduction*, 50(May), 101687. <https://doi.org/10.1016/j.ijdr.2020.101687>
- Elith, J. (2002). Quantitative Methods for Modeling Species Habitat: Comparative Performance and an Application to Australian Plants. *Springer-Verlag*.
- Espinosa-Aranda, J. M., Cuellar, A., Garcia, A., Ibarrola, G., Islas, R., Maldonado, S., & Rodriguez, F. H. (2009). Evolution of the Mexican Seismic Alert System (SASMEX). *Seismological Research Letters*, 80(5). <https://doi.org/10.1785/gssrl.80.5.694>
- Feng, Q., Liu, J., & Gong, J. (2015). Urban flood mapping based on unmanned aerial vehicle remote sensing and random forest classifier-A case of yuyao, China. *Water (Switzerland)*, 7(4), 1437–1455. <https://doi.org/10.3390/w7041437>
- Fowler, K., Coxon, G., Freer, J., Peel, M., Wagener, T., Western, A., Woods, R., & Zhang, L. (2018). Simulating Runoff Under Changing Climatic Conditions: A Framework for Model Improvement. *Water Resources Research*, 54(12), 9812–9832. <https://doi.org/10.1029/2018WR023989>

- Füssel, H. M. (2010). How inequitable is the global distribution of responsibility, capability, and vulnerability to climate change: A comprehensive indicator-based assessment. *Global Environmental Change*, 20(4), 597–611. <https://doi.org/10.1016/j.gloenvcha.2010.07.009>
- Gelati, E., Decharme, B., Calvet, J.-C., Minvielle, M., Polcher, J., Fairbairn, D., & Weedon, G. P. (2018). Hydrological assessment of atmospheric forcing uncertainty in the Euro-Mediterranean area using a land surface model. *Hydrology and Earth System Sciences*, 22(4), 2091–2115. <https://doi.org/10.5194/hess-22-2091-2018>
- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F. (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91. <https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Hall, T. (1999). Precipitation forecasting using a neural network. *Weather and Forecasting*, 14, 338–345.
- Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*. In *Macmillan*.
- Hecht-Nielsen, R. (1990). *Neurocomputing*. Addison-We.
- Hernández, J., & Vieyra, A. (2010). Riesgo por inundaciones en asentamientos precarios del periurbano. Morelia, una ciudad media mexicana. ¿el desastre nace o se hace? *Revista de Geografía Norte Grande*, 62(47), 45–62. <https://doi.org/10.4067/s0718-34022010000300003>
- Hong, W.-C. (2008). Rainfall forecasting by technological machine learning models. *Applied Mathematics and Computation*, 200(1), 41–57. <https://doi.org/10.1016/j.amc.2007.10.046>
- Hsu, K. -I., Gao, X., Sorooshian, S., & Gupta, H. V. (1997). Precipitation estimation from remotely sensed information using artificial neural networks. *J. Appl. Meteorol.*, 36, 1176–1190.
- IPCC. (2013). Preguntas frecuentes Cambio climático 2013 Bases físicas Resumen para responsables de políticas. In *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. https://www.ipcc.ch/site/assets/uploads/2018/03/WG1AR5_SummaryVolume_FINAL_SPANISH.pdf
- ISDR. (2006). *International Strategy for Disaster Reduction*. The Four Elements of Effective Early Warning Systems. <https://www.unisdr.org/2006/ppew/whats-ew/basics-ew.htm>
- ISDR. (2009). 2009 UNISDR Terminología sobre Reducción del Riesgo de Desastres. *Estrategia Internacional Para La Reducción de Desastres de Las Naciones Unidas (UNISDR)*, 43. <https://www.undrr.org/publication/2009-unisdr-terminology-disaster-risk-reduction>
- Jagsich, J. (1954). *Meteorología Física*. Kapelusz.

- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: a tutorial. *Comput*, 31–44.
- Jeréz-Ramirez, D. (2014). Prevención y mitigación de desastres en Colombia: Racionalidad comunicativa en políticas públicas. *20° Encuentro Nacional Sobre Desarrollo Regional En México. (2014)*.
- Karmakar, S., Simonovic, S. P., Peck, A., & Black, J. (2010). An Information System for Risk-Vulnerability Assessment to Flood. *Journal of Geographic Information System*, 02(03), 129–146. <https://doi.org/10.4236/jgis.2010.23020>
- Kashiwao, T., Nakayama, K., Ando, S., Ikeda, K., Lee, M., & Bahadori, A. (2017). A neural network-based local rainfall prediction system using meteorological data on the Internet: A case study using data from the Japan Meteorological Agency. *Applied Soft Computing Journal*, 56, 317–330. <https://doi.org/10.1016/j.asoc.2017.03.015>
- Koizumi, K. (1999). An objective method to modify numerical model forecasts with newly given weather data using an artificial neural network. *Weather Forecasting*, 14, 109–118.
- Koks, E. E., Jongman, B., Husby, T. G., & Botzen, W. J. W. (2015). Combining hazard, exposure and social vulnerability to provide lessons for flood risk management. *Environmental Science and Policy*, 47, 42–52. <https://doi.org/10.1016/j.envsci.2014.10.013>
- Koskinen, M., Tahvanainen, T., Sarkkola, S., Menberu, M. W., Laurén, A., Sallantausta, T., Marttila, H., Ronkanen, A.-K., Parviainen, M., Tolvanen, A., Koivusalo, H., & Nieminen, M. (2017). Restoration of nutrient-rich forestry-drained peatlands poses a risk for high exports of dissolved organic carbon, nitrogen, and phosphorus. *Science of The Total Environment*, 586, 858–869. <https://doi.org/10.1016/j.scitotenv.2017.02.065>
- Kuligowski, R. J., & Barros, A. P. (1998). Experiments in short-term precipitation forecasting using artificial neural networks. *Mon. Weather Rev.*, 126, 470–482.
- Lavell, A. (1999). Gestión de Riesgos Ambientales Urbanos. *Red de Estudios Sociales En Prevención de Desastres En America Latina*.
- Lavell, A. (2000). *Sobre la gestión del riesgo: apuntes hacia una definición (correspondencia personal)*. USAID.
- Lavell, A. (2002). *Consideraciones en torno al enfoque, los conceptos y los términos que rigen con referencia a la reducción del riesgo y la atención de desastres en los países Andinos miembros del CAPRADE*. Predecán. <http://www.comunidadandina.org/predecán/Talleres/TallerNacE-C/3aDefinicion.pdf>
- Le Cozannet, G., Kervyn, M., Russo, S., Ifejika Speranza, C., Ferrier, P., Foumelis, M., Lopez, T., & Modaresi, H. (2020). Space-Based Earth Observations for Disaster Risk Management. *Surveys in Geophysics*, 41(6), 1209–1235. <https://doi.org/10.1007/s10712-020-09586-5>
- Lee, J., Kim, J., Lee, J. H., Cho, I. H., Lee, J. W., Park, K. H., & Park, J. (2012). Feature selection for heavy rain prediction using genetic algorithms. *6th International*

Conference on Soft Computing and Intelligent Systems, and 13th International Symposium on Advanced Intelligence Systems, SCIS/ISIS 2012, 1, 830–833. <https://doi.org/10.1109/SCIS-ISIS.2012.6505383>

- Liu, J. N. K., Li, B. N. L., & Dillon, T. S. (2001). An improved Naïve Bayesian classifier technique coupled with a novel input solution method. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, 31(2), 249–256. <https://doi.org/10.1109/5326.941848>
- Luk, K. C., Ball, E., & Sharma, A. (2001). An Application of Artificial Neural Networks for Rainfall Forecasting. *Pergamon*, 33, 683–693.
- Marzbam, C., & Stumpf, G. (1996). Neural Network for tornado prediction based on Doppler radar derived attributes. *Journal of Applied Meteorology*, 35, 617–626.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.*, 5, 115–133.
- Mejía F., L. D., Sánchez Q., S. T., & Apolinar C., J. (2023). *Sistema Automático de Monitoreo de la cantidad y calidad del agua de lluvia en la ciudad de Morelia*. Universidad Michoacana de San Nicolás de Hidalgo.
- Meyer, H., Kühnlein, M., Appelhans, T., & Nauss, T. (2015). Comparison of four machine learning algorithms for their applicability in satellite-based optical rainfall retrievals. *Atmospheric Research*. <https://doi.org/10.1016/j.atmosres.2015.09.021>
- Mosier, T. M., Hill, D. F., & Sharp, K. V. (2016). How much cryosphere model complexity is just right? Exploration using the conceptual cryosphere hydrology framework. *The Cryosphere*, 10(5), 2147–2171. <https://doi.org/10.5194/tc-10-2147-2016>
- Najjar, Y., Basheer, I., & Hajmeer, M. (1997). Computational neural networks for predictive microbiology. *Food Microbiol*, 34, 27–49.
- Narváez, L., Lavell, A., & Pérez-Ortega, O. (2009). *La Gestión del Riesgo Un enfoque basado en procesos* (A. Campos-García (ed.); Primera). Comunidad Andina.
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Nasiri, H., Mohd Yusof, M. J., & Mohammad Ali, T. A. (2016). An overview to flood vulnerability assessment methods. *Sustainable Water Resources Management*, 2(3), 331–336. <https://doi.org/10.1007/s40899-016-0051-x>
- Pelling, M. (2005). *Measuring vulnerability to urban disaster risk* (1st ed.).
- Phillips, S. J., Anderson, R. P., & Schapire, R. E. (2006). Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190(3–4), 231–259. <https://doi.org/10.1016/j.ecolmodel.2005.03.026>
- Phillips, S. J., & Dudík, M. (2008). Modeling of species distributions with Maxent: New extensions and a comprehensive evaluation. *Ecography*, 31(2), 161–175. <https://doi.org/10.1111/j.0906-7590.2008.5203.x>

- Ramón-Valencia, J. A., Palacios-González, J. R., Santos-Granados, G. R., & Ramón-Valencia, J. D. (2019). *Early warning system on extreme weather events for disaster risk reduction*. 92, 96–104. <https://doi.org/10.17533/udea.redin.20190628>
- Ramos, J. H., Santos, R. R., Ramos, A. H., Cuevas, X. G., Hernández-Máximo, E., Uicab, J. V. C., & López, D. S. (2018). Historical, current and future distribution of *Cedrela odorata* in Mexico. *Acta Botanica Mexicana*, 2018(124), 117–134. <https://doi.org/10.21829/abm124.2018.1305>
- Reyes Rivero, A. C., Montilla Pacheco, A. D. J., Castillo Garcia, P. G., & Zambrano Vera, M. N. (2017). Amenaza, vulnerabilidad y riesgo ante eventos naturales. Factores socialmente construidos. *Journal of Science and Research: Revista Ciencia e Investigación*, 1(6), 22–28. <https://doi.org/10.26910/issn.2528-8083vol2iss6.2017pp22-28>
- Ridolfi, E., Montesarchio, V., Russo, F., & Napolitano, F. (2011). An entropy approach for evaluating the maximum information content achievable by an urban rainfall network. *Natural Hazards and Earth System Science*, 11(7), 2075–2083. <https://doi.org/10.5194/nhess-11-2075-2011>
- Rodriguez L., D., Sánchez Q., S. T., & Domínguez M., F. J. (2020). *Sistema Automático de Información Hidrológica de Morelia*. Universidad Michoacana de San Nicolás de Hidalgo.
- Rogelis, M. C., Werner, M., Obregón, N., & Wright, N. (2016). Hydrological model assessment for flood early warning in a tropical high mountain basin. *Hydrol. Earth Syst. Sci. Discuss.*, 1–36. <https://doi.org/doi:10.5194/hess-2016-30>, 2016.
- Romero, Gilberto; Maskrey, A. (1993). *Los desastres no son naturales* (pp. 1–7).
- Rosenblatt, R. (1962). *Principles of Neurodynamics*. Spartan Books.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). *Learning internal representation by error propagation* (1st ed.). MIT Press.
- Saaty, T. L. (1980). *Multicriteria Decision Making: The Analytic Hierarchy Process*. McGraw-Hill.
- Sadeghi-Pouya, A., Nouri, J., Mansouri, N., & Kia-Lashaki, A. (2017). An indexing approach to assess flood vulnerability in the western coastal cities of Mazandaran, Iran. *International Journal of Disaster Risk Reduction*, 22, 304–316. <https://doi.org/10.1016/j.ijdrr.2017.02.013>
- Sánchez, F. J. (2022). Precipitaciones. In *Hidrología Superficial y Subterránea* (2nd ed., Vol. 2). Kindle Direct Publishing. <http://hidrologia.usal.es/temas/Precipitaciones.pdf>
- Schalkoff, R. J. (1997). *Artificial Neural Networks*. McGraw-Hill.
- Schönfelder, L. H., Bakken, T. H., Alfredsen, K., & Adera, A. G. (2017). *Application of HYPE in Norway*.
- Seng, D. C. (2012). Improving the Governance Context and Framework Conditions of Natural Hazard Early Warning Systems. *Journal of Integrated Disaster Risk*

- Management*, 2(1), 1–25. <https://doi.org/10.5595/idrim.2012.0020>
- Siqueira, V. A., Paiva, R. C. D., Fleischmann, A. S., Fan, F. M., Ruhoff, A. L., Pontes, P. R. M., Paris, A., Calmant, S., & Collischonn, W. (2018). Toward continental hydrologic-hydrodynamic modeling in South America. *Hydrology and Earth System Sciences*, 22(9), 4815–4842. <https://doi.org/10.5194/hess-22-4815-2018>
- Steven, J. P., Miroslav, D., & Robert, E. S. (2020). *Maxent software for modeling species niches and distributions* (3.4.1.). http://biodiversityinformatics.amnh.org/open_source/maxent/
- UNDRR. (2020). *United Nations Office for Disaster Risk Reduction*. Building Risk Knowledge: Terminology. <https://www.undrr.org/terminology/early-warning-system>
- Usda, S. C. S. (1986). Urban hydrology for small watersheds. *Technical Release*, 55, 2–6.
- Valverde Ramírez, M. C., De Campos Velho, H. F., & Ferreira, N. J. (2005). Artificial neural network technique for rainfall forecasting applied to the São Paulo region. *Journal of Hydrology*, 301(1–4), 146–162. <https://doi.org/10.1016/j.jhydrol.2004.06.028>
- Villagrán de León, J. C., Bogardi, J., Dannenmann, S., & Basher, R. (2006). Early Warning Systems in the context of Disaster Risk Management. *Entwicklung und Ländlicher Raum*, 2, 23–25. https://www.unisdr.org/2006/ppew/info-resources/docs/ELR_dt_23-25.pdf
- Waidyanatha, N. (2010). Towards a typology of integrated functional Early Warning Systems. *International Journal of Critical Infrastructures*, 6(1), 31–51. <https://doi.org/10.1504/IJCIS.2010.029575>
- Yan, J., Jin, J., Chen, F., Yu, G., Yin, H., & Wang, W. (2018). Urban flash flood forecast using support vector machine and numerical simulation. *Journal of Hydroinformatics*, 20(1), 232–245. <https://doi.org/10.2166/hydro.2017.175>
- Yepes Piqueras, V. (2022). *Cálculo de la consistencia y el vector propio en AHP*. <https://victoryepes.blogs.upv.es/2022/02/15/calculo-de-la-consistencia-y-el-vector-propio-en-ahp/>
- Youssef, A. M., Pradhan, B., & Sefry, S. A. (2016). Flash flood susceptibility assessment in Jeddah city (Kingdom of Saudi Arabia) using bivariate and multivariate statistical models. *Environmental Earth Sciences*, 75(1), 1–16. <https://doi.org/10.1007/s12665-015-4830-8>
- Zachos, L. G., Swann, C. T., Altinakar, M. S., McGrath, M. Z., & Thomas, D. (2016). Flood vulnerability indices and emergency management planning in the Yazoo Basin, Mississippi. *International Journal of Disaster Risk Reduction*, 18, 89–99. <https://doi.org/10.1016/j.ijdr.2016.03.012>
- Zupan, J., & Gasteiger, J. (1993). *Neural Networks For Chemists: An Introduction*. VCH.