



**UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO**  
**PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA**  
**INGENIERÍA CIVIL – HIDRÁULICA**

**PRONÓSTICO PROBABILISTA DE INUNDACIONES PARA LA CIUDAD DE**  
**MÉXICO**

**TESIS**  
**QUE PARA OPTAR POR EL GRADO DE:**  
**DOCTOR EN INGENIERÍA**

**PRESENTA:**  
**MARCO RODRIGO LÓPEZ LÓPEZ**

**TUTOR PRINCIPAL**  
**Dr. ADRIÁN PEDROZO ACUÑA**  
**INSTITUTO MEXICANO DE TECNOLOGÍA DEL AGUA**

**CIUDAD UNIVERSITARIA, CD. MX. ENERO 2023**



Universidad Nacional  
Autónoma de México

Dirección General de Bibliotecas de la UNAM

**Biblioteca Central**



**UNAM – Dirección General de Bibliotecas**  
**Tesis Digitales**  
**Restricciones de uso**

**DERECHOS RESERVADOS ©**  
**PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

**JURADO ASIGNADO:**

Presidente: Dr. Escalante Sandoval Carlos A.  
Secretario: Dr. Hernández Espriú José Antonio  
1 er. Vocal: Dr. Pedrozo Acuña Adrián  
2 do. Vocal: Dra. Arganis Juárez Maritza Liliana  
3 er. Vocal: Dr. Breña Naranjo José Agustín

Lugar o lugares donde se realizó la tesis: Ciudad Universitaria, CD. MX.

**TUTOR DE TESIS:**

Dr. Pedrozo Acuña Adrián

A handwritten signature in dark ink is written over a horizontal dashed line. The signature is stylized and appears to be the name 'Dr. Pedrozo Acuña Adrián'.

*Dedico este trabajo a mi familia, quienes con su apoyo me han permitido cumplir un sueño más en mi desarrollo personal y profesional. Gracias por inculcar en mí el ejemplo de la enseñanza y la academia.*

*A mi compañera de vida Marcela, por siempre creer en mí, por las palabras de aliento, por apoyarme en los momentos más difíciles y acompañarme en todos mis sueños y metas*

## **Agradecimientos**

Mi profundo agradecimiento a la Universidad Nacional Autónoma de México, mi alma máter, por abrirme las puertas y apoyarme en mis estudios de doctorado.

De igual manera, mi agradecimiento al Instituto de Ingeniería, por permitirme realizar todo el proceso investigativo dentro de su establecimiento educativo; y al Consejo Nacional de Ciencia y Tecnología (CONACYT) por su apoyo económico durante mis estudios.

Quiero expresar mi más grande y sincero agradecimiento a mi Tutor principal, el Dr. Adrián Pedrozo Acuña; quien con su dirección, conocimiento, enseñanza y colaboración permitió el desarrollo de este trabajo.

A mis sinodales Dr. Carlos Agustín Escalante Sandoval, Dra. Maritza Liliana Arganis, Dr. José Antonio Hernández Espriú y Dr. José Agustín Breña Naranjo; quienes con la enseñanza de sus valiosos conocimientos hicieron que pueda crecer día a día como profesional, gracias a cada uno de ustedes por su paciencia, dedicación y apoyo incondicional.

Un especial agradecimiento a los Doctores Thomas Nipen y Mike Gibson por su ayuda y asesoría para la aplicación de las herramientas “Verif” y “CADDIES-caflood” respectivamente.

Agradezco a mis compañeros y amigos, quienes me brindaron la ayuda, y asesoría en los momentos más oportunos y que de una u otra forma me acompañan en todos mis sueños y metas.

Quiero agradecer a mi familia, mis padres y hermanos; gracias a su apoyo, a su amor incondicional, a su enorme amabilidad y acompañamiento, llevar a feliz término este proyecto se hizo una realidad.

Gracias a mi compañera Marcela por entenderme en todo, gracias porque en todo instante fue un acompañamiento incondicional en mi vida, por su apoyo durante todo el desarrollo y la realización de este proyecto.

¡Gracias, gracias, gracias!

## Resumen

El pronóstico se ha vuelto esencial para responder a la demanda de una mejor gestión del riesgo debido a la exposición de la infraestructura y las personas ante las inundaciones. A medida que el mundo continúa urbanizándose, es necesario incluir esfuerzos para forjar un nuevo marco de desarrollo urbano. Estudios recientes relacionados con la predicción y mitigación de inundaciones han demostrado que los Sistemas de Predicción por Ensamblados (EPS) constituyen una herramienta valiosa y esencial para un Sistema de Alerta Temprana. Sin embargo, se requiere un mayor entendimiento en cuanto al uso de EPS para el pronóstico de inundaciones pluviales urbanas.

La Ciudad de México es una de las metrópolis más grandes del mundo con más de 22 millones de habitantes y serias dificultades de infraestructura hídrica. La Ciudad depende completamente de su sistema de drenaje para prevenir y mitigar inundaciones. Por estas razones, el objetivo principal de este trabajo fue investigar el uso potencial del Sistema de Predicción Operacional por Ensamblados; emitido por el ECMWF (Centro Europeo de Pronósticos Meteorológicos de Plazo Medio), para la predicción probabilista de inundaciones en la Ciudad de México. Esta información sirvió como insumo de un modelo Automata Celular llamado “WCA2D”; parte del Proyecto CADDIES – caflod, para la determinación de zonas que son susceptibles a ser afectadas por inundaciones en la ciudad.

Para tener una medida de la calidad de los pronósticos del ECMWF, esta investigación realizó una *verificación de pronósticos* para dos zonas de estudio: 1) Cuenca del Valle de México y 2) Ciudad de México; en donde se aplicaron métricas para los atributos escalares: precisión, confiabilidad, resolución, discriminación y desempeño.

Posteriormente, este trabajo planteó el objetivo de cumplir con la arquitectura de un sistema estándar de pronóstico de inundaciones. Para conformar este sistema, se construyó una herramienta de toma de decisiones, mediante la implementación de un modelo predictivo de regresión logística. El modelo predictivo se alimentó de información histórica de lluvia pronosticada y observada, con el fin de predecir la probabilidad de ocurrencia de un evento mayor a 10 milímetros de lluvia acumulada en 24 horas para la CDMX. Finalmente; se generaron mapas probabilistas de inundación para comunicar la amenaza a usuarios finales y público en general.

El análisis preliminar de verificación de pronósticos evidenció una mayor confiabilidad de los pronósticos deterministas para el rango de 2 a 10 mm de lluvia acumulada en 24 horas, y las primeras 36 horas del horizonte de tiempo resultaron ser las más confiables. Adicionalmente, los pronósticos revelaron una buena discriminación de eventos observados y no observados. Al finalizar, los hallazgos indicaron que los ensamblados meteorológicos del ECMWF tienen suficiente resolución y precisión para la predicción de inundaciones en la Ciudad de México, y se destaca que algunos miembros del ensamble fueron representativos de eventos extremos.

El modelo predictivo de regresión logística demostró ser una herramienta útil para la alerta y toma de decisiones. Por otro lado, el modelo Automata Celular resultó ser eficaz para la reproducción de los flujos de inundación en la Ciudad de México; debido a su rapidez de cálculo computacional y su habilidad de simular lluvia espacialmente variada bajo un esquema de dominio de cálculo expandible.

Los resultados de esta investigación representan un paso más hacia el desarrollo de un Sistema de Alerta de Inundaciones a nivel local basado en Ensamblados de Pronóstico.

## Abstract

Forecast has become essential to respond to demand for better risk management due to the exposure of infrastructure and people to flood events. As the world continues to urbanize, including efforts to forge a new framework of urban development is necessary. Recent studies related to flood prediction and mitigation have shown that Ensemble Prediction Systems (EPS) constitute a valuable and essential tools for an Early Warning System. However, the use of EPS for urban pluvial flood forecasting has yet to be understood.

Currently, Mexico City is one of the largest metropolis of the world with more than 22 million inhabitants and serious difficulties of hydraulic infrastructure. The city depends completely on the sewage system to prevent and mitigate floods. For this reasons, the principal objective of this work was to investigate the potential use of the Operational Ensemble Prediction System; issued by the European Centre for Medium-Range Weather Forecasts (ECMWF), for probabilistic flood prediction in Mexico City.

In order to have a measure of the quality of ECMWF forecasts, this research carried out a forecast verification for two study zones: 1) Valley of Mexico Basin and 2) Mexico City; where metrics were applied for the scalar attributes: precision, reliability, resolution, discrimination and performance.

Subsequently, this work raised the objective of complying with the architecture of a Standard Flood Forecasting System. To form this system, a decision-making tool was built by implementing a predictive logistic regression model. The predictive model was fed with historical information of predicted and observed rainfall, in order to predict the probability of occurrence of an event greater than 10 millimeters of accumulated rainfall in 24 for CDMX. Finally; probabilistic flood maps were generated to communicate the threat to end users and general public.

Preliminary forecast verification analysis showed a higher reliability of deterministic forecasts for the range of 2 to 10 mm of accumulated rainfall in 24 hours, and the first 36 hours of the time horizon turned out to be the most reliable. In addition, the forecasts revealed a good discrimination of observed and non-good observed events. At the end, the findings showed that the EPS have sufficient resolution and accuracy for flood forecasting in Mexico City, noting that some members of the ensemble were representative of extreme events.

The logistic regression predictive model proved to be a useful tool for warning and decision making. On the other hand, the Cellular Automata model turned out to be effective for the reproduction of flood flows in Mexico City; due to its speed of computational calculation; under an expandable computational domain scheme, and its ability to simulate spatially distributed rain.

Results of this research represent another step towards the development of a local Flood Warning System based on Ensemble Forecasts.

## Trabajos de investigación relacionados

### Artículos de Investigación:

- López-López Marco Rodrigo; Pedrozo-Acuña, A. and Severiano Covarrubias, M. L.: **Evaluation of ECMWF's forecasting system for probabilistic urban flood prediction: a case study in Mexico City**, J. Hydroinformatics, 00(0), 1–18, doi:10.2166/hydro.2021.072, 2021.

### Participación en congresos:

- López-López Marco Rodrigo; Pedrozo-Acuña A. 2020. **Verification of Probabilistic Precipitation Forecasts in Metropolitan Area of Valley of Mexico Using the ECMWF Ensemble Prediction System**. European Geosciences Union, EGU 2020; Vienna, Austria.

- López-López Marco Rodrigo, 2020. **Hacia un Pronóstico Probabilista de Inundaciones en la Ciudad de México -Verificación de Ensamblados Meteorológicos del ECMWF en la Zona Metropolitana del Valle de México**. Primer seminario virtual – Diáspora Hídrica, agosto 2020.

- López-López Marco Rodrigo; Pedrozo-Acuña A. 2021. **Evaluation of the ECMWF Operational Forecasting System for Probabilistic Flood Prediction in Mexico City**. European Geosciences Union, EGU 2021; Vienna, Austria.

- López-López Marco Rodrigo; Pedrozo-Acuña A. 2021. **Modelación para Pronóstico Probabilista de Inundaciones en la Ciudad de México**. XXIX Congreso Latinoamericano de Hidráulica. México, 15 al 19 de noviembre de 2021. Evento virtual.



# Contenido

<b>Capítulo 1. Introducción y objetivos.....</b>	<b>1</b>
1.1. Introducción .....	1
1.2. Objetivos .....	6
1.3. Estructura de la tesis .....	7
<b>Capítulo 2. Problemática: Las inundaciones en Ciudad de México .....</b>	<b>9</b>
2.1. Contexto geográfico de la Ciudad de México (CDMX).....	9
2.2. Historia de las inundaciones en Ciudad de México – Drenado del Lago .....	13
2.3. Contexto actual de las inundaciones en Ciudad de México.....	18
2.3.1. Hundimientos .....	22
2.3.2. Eventos de inundación y afectaciones.....	25
<b>Capítulo 3. Contexto de la investigación .....</b>	<b>33</b>
3.1. Predicción probabilista de inundaciones.....	33
3.2. El pronóstico en Ciudad de México.....	38
3.3. Desafíos y futuras oportunidades en el uso de Ensamblados para pronóstico de inundaciones.....	41
<b>Capítulo 4. Marco teórico .....</b>	<b>45</b>
4.1. Sistemas de Alerta contra Inundaciones pluviales.....	46
4.2. Sistemas de Predicción por Ensamblados (EPS) .....	49
4.2.1. ECMWF .....	50
4.2.2. Ventajas y desventajas de los EPS .....	53
4.2.3. Calibración .....	55
4.2.4. Fuentes de incertidumbre .....	56
4.3. Verificación de pronósticos .....	57
4.3.1. Método categórico o basado en umbrales .....	61
4.3.2. Verificación de Ensamblados de Pronóstico .....	65
4.3.3. Verificación de campos atmosféricos.....	68

4.4. Probabilidad de los Ensambls .....	70
4.4.1. Modelos Predictivos .....	70
4.5. Modelación de inundaciones.....	72
4.5.1. Modelos simplificados 2D .....	73
4.5.2. Modelos Digitales de Elevaciones .....	75
4.5.3. Mapas probabilistas de inundación .....	79
4.6. Comunicación del riesgo e incertidumbre del pronóstico.....	81
<b>Capítulo 5. Metodología.....</b>	<b>85</b>
5.1. Arquitectura del sistema de pronóstico.....	85
5.2. Datos de Entrada.....	89
5.2.1. Datos de pronóstico .....	89
5.2.2. Datos observados.....	93
5.3. Marco de trabajo para verificación de pronósticos .....	95
5.3.1. Modelo de regresión logística .....	98
5.3.2. Métodos de verificación probabilistas.....	101
5.4. Herramientas de toma de decisiones.....	104
5.4.1. Construcción del modelo predictivo de regresión logística .....	104
5.5. Proceso de Emergencia.....	106
5.5.1. Puesta a punta del modelo Autómata Celular .....	108
5.5.2. Generación de mapas probabilistas de inundación.....	116
<b>Capítulo 6. Análisis y discusión de resultados .....</b>	<b>119</b>
6.1. Verificación de pronósticos en zona 1: Cuenca del Valle de México .....	119
6.1.1. Exploración preliminar de los pronósticos .....	120
6.1.2. Verificación no probabilista .....	123
6.1.3. Verificación probabilista .....	126
6.2. Verificación de pronósticos en zona 2: Ciudad de México .....	128
6.2.1. Exploración preliminar.....	129
6.2.2. Verificación probabilista .....	131
6.3. Evaluación del modelo Predictivo .....	133
6.4. Pronóstico probabilista de inundaciones en CDMX.....	148

6.4.1. Evaluación preliminar del modelo CADDIES-caflood.....	148
6.4.2. Pronóstico y generación de mapas probabilistas de inundación .....	152
6.4.3. Publicación de mapa WEB (ejemplo) .....	161
<b>Capítulo 7. Conclusiones.....</b>	<b>163</b>
<b>Capítulo 8. Referencias .....</b>	<b>169</b>
<b>Capítulo 9. Anexos.....</b>	<b>181</b>
9.1. Ejemplo de código de Python para la petición de descarga de información en lotes del ECMWF.....	181
9.2. Lista de estaciones Climatológicas .....	182
9.3. Implementación de la Regresión Logística.....	187
9.3.1. Estimación con máxima verosimilitud.....	189
9.3.2. Parámetros del modelo de Regresión Logística para Cuenca del Valle de México .....	194
9.3.3. Parámetros del modelo de Regresión Logística para CDMX. Lluvia acumulada cada 6 horas para $t = 0 + 90$ h.....	196
9.3.4. Parámetros del modelo de Regresión Logística para el Modelo 1. Lluvia acumulada en 24 horas para $t = 0 + 72$ h.....	197
9.4. Parámetros del modelo WCA2D CADDIES_caflood .....	198

## Tabla de Figuras

Figura 2.1. Ubicación geográfica de la Ciudad de México. ....	10
Figura 2.2. Mapa cartográfico de la Ciudad de México. Alcaldías y Áreas Geostatísticas Básicas Urbanas (AGEB). ....	11
Figura 2.3. Mapa de corrientes superficiales y cuerpos de agua de la Ciudad de México. ....	12
Figura 2.4. Lago de Texcoco y Mapa de Nuremberg, 1524.....	14
Figura 2.5 Ciudad de México en la época colonial .....	15
Figura 2.6. Inundación de la ciudad de México en 1951. Centro Histórico.....	16
Figura 2.7. Sistema de drenaje de la Ciudad de México. ....	17
Figura 2.8. Mapa Mental. Problemática de las inundaciones en CDMX.....	18

Figura 2.9. Crecimiento exacerbado de la Ciudad de México y drenado del lago.....	20
Figura 2.10. Presa Becerra A. Fecha: 11/08/2020.....	21
Figura 2.11 Vista detallada de la velocidad de desplazamiento vertical en la Ciudad de México en 2017-2019.....	23
Figura 2.12 Distorsiones angulares $\beta$ . Análisis del peligro de fallas superficiales inducidas por subsidencia en la Ciudad de México en 2017-2019.....	24
Figura 2.13. Mapa de riesgo de inundaciones asociadas eventos con periodo de retorno de 5 años.....	26
Figura 2.14 Mapa de Incidentes de encharcamientos e inundaciones en la CDMX para los años 2016 -2019.....	27
Figura 2.15. Mapas de lluvia para diferentes periodos de retorno en Ciudad de México y Cuenca del Valle de México.....	28
Figura 3.1 Amenaza de inundaciones con periodo de retorno de 100 años. Sistema GloFAS.....	36
Figura 3.2. Mapa de ubicación de los casos de estudio investigados por Wu et al., (2020).....	38
Figura 3.3. Pronóstico de acumulado total de precipitación de 5 días emitido por el Servicio Meteorológico Nacional. Seguimiento del Huracán Genevieve.....	39
Figura 3.4. Mapa mental. Resumen de los desafíos y atención a brechas existentes en el pronóstico de inundaciones basado en Sistemas de Predicción por Ensamblés.....	42
Figura 4.1. Factores que influyen en un sistema de pronóstico de inundaciones.....	47
Figura 4.2. Esquema del concepto de ensamblés de pronóstico.....	50
Figura 4.3. Ejemplo de pronóstico emitido por el ECMWF a escala global.....	51
Figura 4.4. Simetría de pronósticos emitidos por el ECMWF.....	52
Figura 4.5. Beneficios potenciales de los pronósticos probabilistas.....	54
Figura 4.6. Ejemplo de Diagrama de Confiabilidad y curva ROC.....	67
Figura 4.7. Comparación visual de los modelos de elevación: SRTM, AW3D, LiDAR de Terreno y superficie. Resolución de 30 x 30 metros.....	77
Figura 4.8. Ejemplo de mapa probabilista de inundaciones. Probabilidad de exceder una profundidad mayor a 10 cm. Zona sur CDMX. Evento del 27 de mayo de 2017.....	80
Figura 5.1. Arquitectura de casa para un sistema de pronóstico de Inundaciones.....	86
Figura 5.2. Diagrama de flujo de la metodología.....	88

Figura 5.3. Componentes del Sistema Integrado de Pronóstico (IFS) del ECMWF.....	89
Figura 5.4. 50 miembros perturbados del ensamble de pronóstico (ejemplo).....	92
Figura 5.5. Estructura de hipercubo del formato GRIB. ....	92
Figura 5.6. Mapa de localización de las estaciones climatológicas en la CVM.....	94
Figura 5.7. Distribución de estaciones de medición para los años 2017 - 2019 del OH- IIUNAM. ....	94
Figura 5.8. Función sigmoidea.....	99
Figura 5.9. Esquema de la técnica k-fold cross-validation.....	101
Figura 5.10. Ejemplo de las retículas de cálculo del Modelo CA del proyecto CADDIES-caflood.....	108
Figura 5.11. Unión de información LiDAR para el dominio de cálculo. ....	110
Figura 5.12. Mapa hillshade de DEM corregido. Resolución 1.5 x 1.5 m. ....	111
Figura 5.13. Cajas de lluvia (Rain Boxes), uso de suelo y coeficiente de rugosidad en el dominio de cálculo.....	114
Figura 5.14. Display de Mapbox Studio. ....	117
Figura 6.1. Mapas “Eyeball”. Lluvia promedio de 24 horas en CVM. Periodo 2007 – 2014. ....	121
Figura 6.2. Sesgo y Error Medio Cuadrático de los productos HRES y EMEAN en la Cuenca del Valle de México.....	123
Figura 6.3. Métricas de desempeño de pronósticos HRES y EMEAN para la cuenca del Valle de México.....	124
Figura 6.4. Mapa de dispersión de los ensambles en CVM. ....	126
Figura 6.5 . Curvas de Confiabilidad y curvas ROC para t = 24 horas en la Cuenca del Valle de México.....	128
Figura 6.6. Mapa de impacto y correlación de Pearson para distintas ventanas de tiempo. ....	130
Figura 6.7. Meteograma de precipitación promedio para la ciudad de México. ....	131
Figura 6.8. Curvas de Confiabilidad y ROC para t = 6 horas y lt= 0+90 h en CDMX. ....	132
Figura 6.9. Índice de Brier para eventos de precipitación de 0 a 5 mm acumulados en 6 horas.....	132
Figura 6.10. Diagrama de confiabilidad y curvas ROC para los modelos predictivos descritos en la Tabla 6-1. Resultados para un umbral de lluvia mayor a 10 mm en 24 h. ....	134

Figura 6.11. Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 h, estimadas a partir del modelo predictivo. Evento con tiempo base 28-05-2017 12 UTC y horizonte de tiempo de 72 horas. Gráficas en hora local.....	136
Figura 6.12 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 27-06-2017 12 UTC y horizonte de tiempo de 72 horas. ....	137
Figura 6.13 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 30-08-2017 12 UTC y horizonte de tiempo de 72 horas. ....	138
Figura 6.14 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 06-09-2017 12 UTC y horizonte de tiempo de 72 horas. ....	140
Figura 6.15 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 04-08-2018 12 UTC y horizonte de tiempo de 72 horas. ....	141
Figura 6.16 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 19-08-2018 12 UTC y horizonte de tiempo de 72 horas. ....	142
Figura 6.17 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 26-08-2018 12 UTC y horizonte de tiempo de 72 horas. ....	143
Figura 6.18 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 21-09-2018 12 UTC y horizonte de tiempo de 72 horas. ....	144
Figura 6.19 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 17-07-2019 12 UTC y horizonte de tiempo de 72 horas. ....	145
Figura 6.20 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 09-09-2019 12 UTC y horizonte de tiempo de 72 horas. ....	146
Figura 6.21. Comparación de los resultados del modelo LISFLOOD-FP vs CADDIES-caflood. ....	148

Figura 6.22. Hietograma del evento del 27-08-2018 registrado por la estación CCHOTE del OH-IIUNAM. Inundación sobre Calz. Ignacio Zaragoza en dirección al Pte. desde República Federal hasta Guelatao (@C5_CDMX).....	149
Figura 6.23. Comparación de CAFLOOD vs LISFLOOD para evento de del 27-08-2018. Zona de Calzada Ignacio Zaragoza.....	151
Figura 6.24. Afectaciones del evento del 28-06-2017.....	153
Figura 6.25. Afectaciones del evento del 06-09-2017.....	155
Figura 6.26. Afectaciones del evento del 27-08-2018.....	156
Figura 6.27. Mapas probabilistas de inundación pluvial en la zona de circuito interior y Reforma. ....	158
Figura 6.28. Mapas probabilistas de inundación pluvial en la zona sur de la CDMX. ....	159
Figura 6.29. Mapas probabilistas de inundación pluvial en la zona oriente de la CDMX. ....	160
Figura 6.30. Publicación de mapa probabilista de inundaciones en CDMX. Mapas WEB con la plataforma Mapbox Studio. Versión de PC.....	161
Figura 6.31. Publicación de mapa probabilista de inundaciones en CDMX. Mapas WEB con la plataforma Mapbox Studio. Versión en dispositivo móvil.....	162

## Índice Tablas

Tabla 2-1. Eventos de inundación en CDMX. Años 2017 y 2019.....	29
Tabla 3-1. Clasificación de los niveles de alerta por fenómenos meteorológicos.....	40
Tabla 4-1. Orden de prioridad para la creación de un Sistema de Alerta de Inundaciones.....	48
Tabla 4-2. Razones para verificar un pronóstico.....	59
Tabla 4-3. Tipos de bondad de un pronóstico.....	59
Tabla 4-4. Atributos escalares de calidad de un pronóstico.....	60
Tabla 4-5. Métodos de verificación de pronósticos.....	61
Tabla 4-6. Estructura de tabla de contingencia.....	62
Tabla 4-7. Métricas para método dicotómico de verificación.....	63
Tabla 4-8. Modelos Digitales de elevaciones y resoluciones.....	76
Tabla 5-1. Descripción de productos atmosféricos HRES y ENS del ECMWF.....	91
Tabla 5-2. Horarios de emisión de productos del modelo atmosférico.....	91
Tabla 5-3. Resumen de los productos utilizados en este trabajo.....	95

Tabla 5-4 Formato recomendado por el autor y utilizado por la herramienta "Verif" para el arreglo de los datos (ejemplo).....	97
Tabla 5-5. Descripción de datos para la construcción de los modelos predictivos como herramienta de toma de decisiones .....	106
Tabla 5-6. Formato para la generación de cajas de lluvia. Modelo CADDIES_caflood (Ejemplo) .....	112
Tabla 5-7. Coordenadas de pixeles y parámetros para la definición de cajas de lluvia en el dominio de cálculo.....	112
Tabla 6-1. Reporte de resultados del Modelo Predictivo para lluvia mayor a 10 milímetros en 24 horas.....	133
Tabla 6-2. Medidas de desempeño de los modelos predictivos .....	147
Tabla 6-3. Resultados de tiempos de cálculo para los modelos de inundación LISFLOOD y CAFLOOD con información de elevación de SRTM, ALOS y LiDAR. ....	152
Tabla 6-4. Tiempos de cálculo para los eventos de estudio y generación de mapas probabilistas de inundación. ....	157
Tabla 9-1. Lista de estaciones climatológicas del Sistema CLICOM. Estaciones utilizadas para la verificación de pronósticos del ECMWF en la Cuenca del Valle de México.....	182
Tabla 9-2. Lista de estaciones del OH-IIUNAM. Estaciones utilizadas para la verificación de pronósticos del ECMWF en la Ciudad de México.....	185
Tabla 9-3. Coeficientes beta del modelo de Regresión Logística para distintos umbrales de lluvia en la Cuenca del Valle de México .....	194
Tabla 9-4 Coeficientes beta del modelo de Regresión Logística para distintos umbrales de lluvia en CDMX.....	196
Tabla 9-5. Coeficientes beta del modelo de Regresión Logística para el Modelo 1 descrito en el Capítulo 5.4 .....	197



## Abreviaturas y siglas

<b>1D</b>	:	Una dimensión
<b>2D</b>	:	Dos dimensiones
<b>AGEB</b>	:	Área Geoestadística Básica
<b>ANRI</b>	:	Atlas Nacional de Riesgo por Inundaciones
<b>BIAS</b>	:	BIAS o Sesgo
<b>BSS</b>	:	Brier Skill Score
<b>C5</b>	:	Centro de Comando, Control, Cómputo, Comunicaciones y Contacto Ciudadano
<b>CA</b>	:	Autómata Celular (Cellular Automata)
<b>CADDIES-caflood</b>	:	Cellular automata dual-drainage Simulation
<b>CDMX</b>	:	Ciudad de México
<b>CENAPRED</b>	:	Centro Nacional de Prevención de Desastres
<b>CF</b>	:	Control Forecast (Pronóstico de Control)
<b>CDF</b>	:	Cumulative Distribution Function (Función de distribución Acumulativa)
<b>CONAGUA</b>	:	Comisión Nacional del Agua
<b>CP</b>	:	Convective Precipitation (Precipitación convectiva)
<b>CSI</b>	:	Critical succes index (Total de amenazas, TS)
<b>DEM</b>	:	Digital Elevation Model (Modelo Digital de Elevación)
<b>DSM</b>	:	Modelo Digital de Superficie
<b>DTM</b>	:	Digital Terrain Model (Modelo Digital del Terreno)
<b>ECMWF</b>	:	European Centre for Medium Range Weather Forecast (Centro Europeo para la Predicción de Clima de Plazo Medio)
<b>EDA</b>	:	Ensemble Data Assimilation (Sistema de Ensamblés de Asimilación de Datos)
<b>EFAS</b>	:	European Flood Alert System (Sistema Europeo de Alerta Contra Inundaciones)
<b>EMEAN</b>	:	Ensemble Mean (Media de los Ensamblés)
<b>ENS</b>	:	Ensemble Forecast (Ensamble de Pronósticos)

<b>EPS</b>	:	Ensemble Prediction System (Sistemas de Predicción por Ensamblados)
<b>EX ANTE</b>	:	Pronóstico de un evento antes de que este ocurra (Predicción genuina)
<b>EX POST</b>	:	Pronóstico de periodos históricos en donde los datos observados están disponibles
<b>F</b>	:	Tasa de Falsa Alarma (probabilidad de falsa alarma, POFD)
<b>FAR</b>	:	False Alarm Ratio (Proporción de Falsa Alarma)
<b>fcst</b>	:	Predicción determinista
<b>FP</b>	:	False Positive
<b>FN</b>	:	False Negative
<b>GDEM</b>	:	Global Digital Elevation Model
<b>GloFAS</b>	:	Global Flood Awareness System
<b>GRIB</b>	:	Formato para almacenar y compartir datos meteorológicos de campos atmosféricos
<b>H</b>	:	Hit rate o Tasa de Aciertos
<b>h</b>	:	Horas
<b>HSS</b>	:	Heidke Skill Score
<b>HRES</b>	:	High Resolución Forecast (Pronóstico de Alta Resolución)
<b>IFS</b>	:	Integrated Forecasting System (Sistema Integrado de Pronóstico)
<b>INEGI</b>	:	Instituto Nacional de Estadística y Geografía
<b>JAXA</b>	:	Agencia de Exploración Aeroespacial de Japón (JAXA)
<b>JRC</b>	:	Joint Research Centre (Centro de Investigación Conjunta)
<b>lat</b>	:	Latitud en coordenadas geográficas
<b>lon</b>	:	Longitud en coordenadas geográficas
<b>LiDAR</b>	:	Light Detection and Ranging
<b>LEPS</b>	:	Linear Error in Probability Space
<b>LSP</b>	:	Large Scale Precipitation (Precipitación a Gran Escala o estratiforme)
<b>lt</b>	:	Lead Time (Horizonte de tiempo)
<b>MARS</b>	:	Meteorological Archival Retrieval System (sistema de almacenamiento de archivos meteorológicos del ECMWF)
<b>MJJASON</b>	:	Temporada de lluvias: Mayo, Junio, Julio, Agosto, Septiembre, Octubre y Noviembre

<b>mm</b>	:	Milímetros
<b>m s. n. m.</b>	:	Metros sobre el nivel del mar
<b>NANs</b>	:	Redes Neuronales Artificiales
<b>NGA</b>	:	Agencia Nacional de Inteligencia Geoespacial (NGA)
<b>NWP</b>	:	Numerical Weather Prediction (Predicción Numérica del Clima)
<b>obs</b>	:	Valor observado
<b>OR</b>	:	Odds ratio o Tasa de probabilidades
<b>OSM</b>	:	Open Street Map
<b>OH-IIUNAM</b>	:	Observatorio Hidrológico del Instituto de Ingeniería de la UNAM
<b>PC</b>	:	Proportion Correct
<b>POD</b>	:	Probability of Detection (Probabilidad de Detección del Evento de Interés)
<b>POT</b>	:	Administración Nacional de Aeronáutica y del Espacio
<b>PYTHON</b>	:	Lenguaje de Programación
<b>ROC</b>	:	Relative Operating Characteristic
<b>SACMEX</b>	:	Sistema de Aguas de la Ciudad de México
<b>SIAT-CT</b>	:	Sistema de Alerta Temprana para Ciclones Tropicales
<b>SINAPROC</b>	:	Sistema Nacional de Protección Civil
<b>SMN</b>	:	Servicio Meteorológico Nacional
<b>SRTM</b>	:	Shuttle Radar Topography Mission
<b>SV</b>	:	Técnica Singular Vector
<b>SWEs</b>	:	Shallow Water Equations
<b>TEO</b>	:	Túnel Emisor Oriente
<b>TN</b>	:	True Negative
<b>TP</b>	:	True Positive
<b>tp</b>	:	Total Precipitation (precipitación total)
<b>Tr</b>	:	Periodo de retorno
<b>TS</b>	:	Índice de Amenazas o Threat Score
<b>UTC</b>	:	Coordinated Universal Time
<b>Verif</b>	:	Herramienta de verificación de pronósticos en lenguaje Python

<b>WCA2D</b>	:	Modelo Ponderado Autómata Celular (Weighted Cellular Automata 2D model)
<b>WMO</b>	:	World Meteorological Organization (Organización Meteorológica Mundial)
<b>WRF</b>	:	Weather Research and Forecasting model
<b>xarray</b>	:	Librería en lenguaje Python para lectura y procesamiento de arreglos de datos multidimensionales.
<b>ZMVM</b>	:	Zona Metropolitana del Valle de México



# Capítulo 1. Introducción y objetivos

*El Principio de incertidumbre propuesto por Werner Heisenberg en 1926 acabó con la teoría de un modelo determinista del universo; sobre todo porque, “no se pueden predecir los acontecimientos futuros con exactitud si ni siquiera se puede medir el estado presente del universo de forma precisa”*

**Hawking, (1988)**

## 1.1. Introducción

La urbanización trae consigo diversas oportunidades para el desarrollo económico y bienestar de la sociedad. Tan sólo en el último siglo, las zonas urbanas han sobrepasado a las zonas rurales en casi todas las dimensiones del desarrollo económico, sea la tasa de innovación, el nivel educativo, salud, esperanza de vida, mortandad infantil, y acceso al agua potable y servicios de sanidad. Con la alta densidad poblacional, la concentración de bienes y más del 80% de las ciudades localizadas en cuencas, las inundaciones representan un reto significativo para su sostenibilidad en el futuro. Las proyecciones no son muy optimistas por temas como el uso del suelo, y los cambios demográficos y socio-económicos. Las Naciones Unidas estiman que la población mundial que vive en áreas urbanas tendrá un aumento global del 68% para 2050 (United Nations, 2018). La mayor parte de este crecimiento ocurrirá en países en desarrollo, principalmente en mega ciudades

como la Ciudad de México, así como en ciudades intermedias; con el consiguiente aumento del número de personas expuestas a inundaciones.

Para 2018, el número de ciudades en el mundo con al menos 1 millón de habitantes aumentó a 548. De estas ciudades, 63 están en América Latina (United Nations, Department of Economic and Social Affairs, 2018); con Ciudad de México y São Paulo, cada una con alrededor de 22 millones de habitantes.

La mayoría de las ciudades son vulnerables a al menos un tipo de desastre natural; y dadas las proyecciones climáticas que indican eventos cada vez más extremos de lluvia y sequía (Quevauviller, 2015), la disponibilidad de pronósticos es fundamental.

En general la toma de decisiones para el control de inundaciones se basa en registros climatológicos históricos en donde se asume que el futuro es reflejo del pasado (Rayner et al., 2005). Estos registros históricos son imperfectos y en ocasiones su información no es adecuada para predecir eventos extremos. Así mismo, la gestión de inundaciones tradicional se basa en la protección a partir de medidas estructurales para la reducción del gasto pico y extensión de la inundación; no obstante, dichas medidas no logran eliminar el riesgo por completo (Jain et al., 2018). Estas medidas se ven aún más limitadas debido a la incertidumbre en la magnitud, tiempo, plazo de ocurrencia, extensión geográfica e interacciones geofísicas de las inundaciones (Moore et al., 2005). Por estas razones, el pronóstico se ha vuelto imprescindible para dar respuesta a la demanda de un mejor manejo del riesgo por exposición de infraestructura y personas ante eventos de inundación; y aunado a la incertidumbre de los eventos futuros (Krzysztofowicz, 2001).

La habilidad de predecir, cuantificar y administrar el riesgo por inundaciones recae en predecir la lluvia, siendo esencial para proteger al público, propiedades e infraestructura (Pedrozo-Acuña et al., 2014). Sin embargo, pronosticar la lluvia es un proceso complejo. Para compensar esta dificultad, dentro de las mejoras incorporadas en el uso de modelos climáticos destacan la asimilación y percepción remota; una mejor descripción física de los fenómenos meteorológicos, y el uso de varias realizaciones para definir un posible pronóstico, todo sustentado en el continuo incremento del poder de cómputo (Roulin, 2006). Este avance tecnológico ha dado lugar al uso de Modelos para la Predicción Numérica del Clima (Numerical Weather Prediction, NWP). Estos modelos permiten a los

pronosticadores evaluar cuantitativamente el nivel de confianza de un pronóstico para los usuarios finales (Bauer et al., 2015); y se ha considerado su encadenamiento unidireccional con modelos hidrológicos para la predicción de avenidas (Schumann, 2011).

Como resultado de la Predicción Numérica del Clima, los Sistemas de Predicción por Ensamblados (EPS); constituyen una herramienta útil para el pronóstico probabilista de inundaciones; y surgieron para contrarrestar las limitaciones asociadas a los modelos deterministas (Jain et al., 2018). Los EPS representan el intento de estimar el rango de posibles escenarios basados en un conjunto de condiciones iniciales; y han sido reconocidos en la literatura como herramientas valiosas y primordiales para un buen Sistema de Alerta Temprana (Pappenberger et al., 2008).

Investigaciones han demostrado que la predicción probabilista de inundaciones puede desempeñar un papel crucial para garantizar una toma de decisiones más consciente; considerando la incertidumbre de los fenómenos meteorológicos, tanto a nivel global y regional (p.ej., Emerton et al., 2016; Lee et al., 2018; Moore et al., 2005; Pedrozo-Acuña et al., 2013; Revilla-Romero et al., 2015; Verbunt et al., 2007); y entre las nuevas metodologías y técnicas de investigación para la reducción y mitigación del riesgo por inundaciones basadas en EPS, se encuentran las utilizadas por el Centro Europeo para la Predicción de Clima de Plazo Medio (ECMWF, <https://www.ecmwf.int/>) y el Centro de Investigación Conjunta (JRC); que consisten en sistemas de pronóstico de variables climáticas a escala global, con el fin de emitir información en una situación de emergencia para otorgar un tiempo de respuesta adecuado, y proporcionan una herramienta eficaz para pronosticadores y tomadores de decisiones. Plataformas como el Sistema de Alerta por Inundaciones Europeo (EFAS, Thielen et al., 2008) y el Sistema Global de Concientización sobre Inundaciones (GloFAS, Alfieri et al., 2013), son un ejemplo de cómo se han utilizado los EPS para la predicción de inundaciones fluviales, a resoluciones superiores a 30 km.

Los Sistemas de Predicción por Ensamblados también se han utilizado para la predicción de inundaciones en cuencas definidas; como el río Meuse en los Países Bajos y el río Odra en Polonia (Gouweleeuw et al., 2005). En México, una de las primeras implementaciones de un EPS fue documentada por Rodríguez-Rincón et al., (2015), quienes utilizaron un Modelo Numérico de Predicción Climática en combinación con un modelo



hidrológico distribuido para la generación de un ensamble de avenidas, en el río Tonalá, Tabasco.

Por otra parte, debido a la incertidumbre en el pronóstico de inundaciones, es necesario caracterizar y evaluar el desempeño y calidad de los pronósticos. Para ello, se examinan diferentes atributos, como la confiabilidad, resolución, discriminación y nitidez de una predicción (p.ej., Buizza et al., 2000; Murphy, 1993) y dentro de la comunidad científica atmosférica, a este proceso se le conoce como “Verificación de Pronósticos”. Ahora bien, la mayoría de los estudios sobre predicción de inundaciones y verificación de pronósticos se han limitado a tratar solo con inundaciones fluviales; y se han realizado a escala continental y regional con una resolución temporal mayor o igual a 12 horas. En consecuencia, es necesario abordar el uso de los EPS para el pronóstico de inundaciones no fluviales; como en el caso de la Ciudad de México, donde las inundaciones son causadas principalmente por lluvias convectivas y se presentan otras consideraciones a tener en cuenta; como la existencia de estructuras y drenaje.

El incremento del riesgo por inundaciones en zonas urbanas se debe en gran medida por el aumento de la exposición poblacional y de bienes; sobre todo en ciudades de crecimiento acelerado (Tingsanchali, 2012) como la Ciudad de México. La delicada posición geográfica de la Ciudad de México dentro de una cuenca endorreica (Cuenca del Valle de México), combinada con las presiones sociales, ha creado una situación compleja y ha alterado significativamente su ciclo hidrológico original (Salinas et al., 2016). Como resultado, la Ciudad de México depende completamente de su sistema de drenaje para prevenir y mitigar las inundaciones. Por estos motivos, las estrategias de prevención para mitigar las inundaciones actuales y futuras en la Ciudad requieren la correcta estimación de las condiciones atmosféricas que pudieran presentarse en el futuro.

De igual modo, los desafíos actuales en el pronóstico de inundaciones deben extender el uso de los ensambles de pronóstico para los sistemas operativos e incluirlos en la cadena para la toma de decisiones de emergencia y la gestión del agua. Por ende, es importante que el trabajo actual y futuro sobre predicción de inundaciones apunte a eventos a escala local, que están relacionados con inundaciones urbanas o súbitas (Wu et al., 2020).

Con base en lo anterior, el objetivo de este estudio es sentar las bases para la construcción de una herramienta para la predicción probabilista de inundaciones en la Ciudad de México.

La hipótesis que se pondrá a prueba es la factibilidad de generar un pronóstico probabilista de inundaciones; confiable y preciso, a partir de ensambles de lluvia emitidos por el ECMWF (Centro Europeo para la Predicción de Clima de Plazo Medio).

Este estudio busca investigar el potencial del Sistema de Predicción por Ensamblados del ECMWF, como una herramienta para el pronóstico de inundaciones pluviales urbanas y contestar las siguientes preguntas de investigación: qué tan bien se corresponden los pronósticos del ECMWF con la precipitación observada en el Valle de México; cuál es la precisión y confiabilidad de los pronósticos, y si su resolución es suficiente para la predicción de inundaciones en la Ciudad de México.

Para ello, se realizó una verificación de pronósticos considerando dos zonas de estudio: 1) Cuenca del Valle de México (MVB) y 2) Ciudad de México (CDMX). Para la zona 1, los pronósticos se verificaron contra la lluvia observada de 24 horas emitida por el sistema CLICOM ([clicom-mex.cicese.mx](http://clicom-mex.cicese.mx)), durante 2007 - 2014. Para la zona 2, los pronósticos se verificaron contra los datos observados en tiempo real emitidos por el Observatorio Hidrológico del Instituto de Ingeniería de la UNAM (OHIUNAM, <https://ohiiunam.mx/>), durante la temporada de lluvias (MJASON, mayo a noviembre) de 2017-2019. La verificación se realizó en términos de los siguientes atributos escalares: precisión, confiabilidad, resolución, discriminación y desempeño. Las probabilidades del Ensamble se estimaron mediante un modelo predictivo para la posterior aplicación de métodos de verificación probabilistas.

Una vez verificada la calidad de los ensambles de pronóstico, estos servirán como insumo de un modelo Automata Celular (parte del proyecto CADDIES-caflood), para la generación de flujos de inundación en calles y avenidas de la ciudad; para posteriormente, generar mapas probabilistas que permitan identificar las zonas que son susceptibles de ser afectadas por inundaciones en la Ciudad de México.

Este trabajo busca acortar las limitaciones de investigaciones previas, evaluando los pronósticos a una resolución temporal menor a 12 horas; y brinda una importante

oportunidad para avanzar en el desarrollo de un Sistema de Pronóstico de Inundaciones para la Ciudad de México.

Los resultados evidenciaron una buena confiabilidad del Sistema de Predicción por Ensamblados (EPS) para un umbral de lluvia acumulada de hasta 20 mm en 24 horas, siendo las primeras 36 horas del horizonte de pronóstico las más confiables. Asimismo, el Ensamble de Pronósticos demostró tener la resolución y precisión suficientes para la predicción de inundaciones en la Ciudad de México. Del mismo modo, el modelo Autómata Celular probó ser una excelente herramienta para la simulación de múltiples escenarios; debido a su rapidez de cálculo, y su habilidad de simular lluvia espacialmente variada bajo un esquema de cálculo de dominio expandible.

Por último, los conocimientos obtenidos de este estudio pueden ser de ayuda para motivar al uso de productos de pronóstico para la implementación de Sistemas de Alerta de Inundaciones a nivel local.

## 1.2. Objetivos

El objetivo de esta investigación es desarrollar una metodología de pronóstico probabilista de inundaciones en la Ciudad de México. Esta metodología se realizará a partir de pronósticos de lluvia emitidos por el Sistema de Predicción por Ensamblados (EPS) del Centro Europeo para la Predicción de Clima de Plazo Medio (ECMWF); en combinación con un modelo Autómata Celular.

En una primera fase, este estudio tuvo como objetivo abordar las siguientes preguntas de investigación: qué tan bien se corresponden los pronósticos del ECMWF con la precipitación observada en el Valle de México; cuál es la precisión y confiabilidad de los pronósticos y si su resolución es suficiente para la predicción de inundaciones en la Ciudad.

Para cumplir con los objetivos mencionados se realizaron las siguientes actividades:

1. Análisis y reconocimiento del Sistema de Predicción por Ensamblados (EPS) del ECMWF:
  - Reconocimiento de: plataforma de descarga; variables; arreglo y formato de los productos de pronóstico.

2. Recopilación de información histórica de lluvia; tanto de pronóstico como observada.
3. Cumplir con la arquitectura de un sistema de pronóstico estándar (Henonin et al., 2013).
4. Evaluación de calidad del EPS mediante su comparación contra información climatológica observada en la Zona Metropolitana del Valle de México (ZMVM).
5. Estimación de las probabilidades dadas por el Ensamble para pronosticar la ocurrencia de eventos de interés.
6. Puesta a punto del modelo Automata Celular (CA) para la simulación en tiempo real de los flujos de inundación en Ciudad de México.
7. Validación del Sistema Ensamble-Modelo Automata Celular, en la generación de manchas probabilistas de inundación.
8. Ejemplo de comunicación del riesgo mediante la publicación de los mapas de inundación en plataforma WEB.

### 1.3. Estructura de la tesis

Los capítulos siguientes en este trabajo se describen a continuación:

#### **Capítulo 2. Problemática: Las Inundaciones en Ciudad de México**

Describe la zona de estudio; su ubicación y el problema de las inundaciones en la ciudad por medio de un resumen de la historia de su sistema de drenaje; el cual está ligado al drenado de la Cuenca del Valle de México. Esta sección concluye con una recopilación de eventos de inundación en la Ciudad de México durante el periodo 2017 - 2019.

#### **Capítulo 3. Contexto de la investigación**

Describe los antecedentes sobre las metodologías que se han utilizado para pronosticar inundaciones con un enfoque probabilista; en donde se analizan las brechas existentes; las recomendaciones y futuras líneas de investigación requeridas. Este resumen se basa en la revisión de la literatura y el trabajo realizado por Wu et al., (2020), quienes analizaron 70 trabajos de investigación sobre el uso de ensambles de pronóstico en las últimas dos décadas.

## **Capítulo 4. Marco teórico**

En esta sección se aborda la definición de conceptos, hipótesis y explicación del porqué de las teorías y métodos utilizados para el pronóstico probabilista de inundaciones. Se describen nuevamente los objetivos de este trabajo; así como un análisis más amplio sobre la importancia de la verificación de pronósticos.

## **Capítulo 5. Metodología**

Describe los conjuntos de datos observados y productos de pronóstico utilizados; así como el marco de trabajo para la verificación de pronósticos aplicado a dos zonas de estudio: 1) Cuenca del Valle de México y 2) Ciudad de México. La verificación de pronósticos a nivel cuenca permitió tener más puntos de referencia y; por lo tanto, una visión general del desempeño de los productos del ECMWF en la zona. Por último, se describe el modelo Automata Celular utilizado para la generación de escenarios de inundación probabilistas en CDMX.

## **Capítulo 6. Análisis y discusión de Resultados**

Esta sección presenta los resultados obtenidos del proceso de verificación en la Cuenca del Valle de México y Ciudad de México; así como los resultados del Modelo Predictivo de regresión logística construido a partir de la información histórica. Por último, se muestra el análisis del desempeño del modelo Automata Celular y la generación de mapas probabilistas de inundación para tres casos de estudio en la Ciudad. De igual forma, se discuten los resultados obtenidos.

## **Capítulo 7. Conclusiones**

Este capítulo resume las conclusiones más importantes de este trabajo; junto con algunas sugerencias respecto a las futuras líneas de investigación, contribuciones y limitaciones que se desprenden de esta tesis.

## Capítulo 2. Problemática: Las inundaciones en Ciudad de México

*La anticipación y preparación ante un evento de inundación de gran escala es la clave en la mitigación del impacto y optimización de planes de estrategia de los recursos hídricos.*

**Alfieri et al., (2013)**

### 2.1. Contexto geográfico de la Ciudad de México (CDMX)

La ciudad de México se ubica a más de 2000 metros sobre el nivel del mar dentro de la subcuenca del Lago de Texcoco y Zumpango; perteneciente a la Cuenca del Valle de México (Pachuca – Cd. De México) en la Región Hidrológica 26 (Pánuco).

La Cuenca del Valle de México (CVM) se ubica en una zona geográfica rodeada de montañas y volcanes (Once TV México, 2013); y su aportación a la ciudad de México se encuentra delimitada al norte por la Sierra de Guadalupe, al sur por la Sierra de Chichinautzin, al este por la Sierra Nevada y los volcanes Iztaccíhuatl y Popocatepetl; y al oeste por la sierra de las Cruces (Figura 2.1).

Las lavas que depositó el vulcanismo de las Sierras Nevada, de Las Cruces y posteriormente la Sierra de Chichinautzin, formaron la base en donde se acumularían los depósitos aluviales que constituyen en la actualidad el acuífero superior de la Cuenca de México, el cual tiene entre 600 y 700 metros de espesor, y en donde subyace la actual Ciudad de México (Espinoza et al., 2012).

La geología de la ciudad está compuesta tanto por rocas de origen volcánico como basaltos y andesitas, así como por rocas sedimentarias originadas en el lago, compuestas en su mayoría por arcillas y arena.

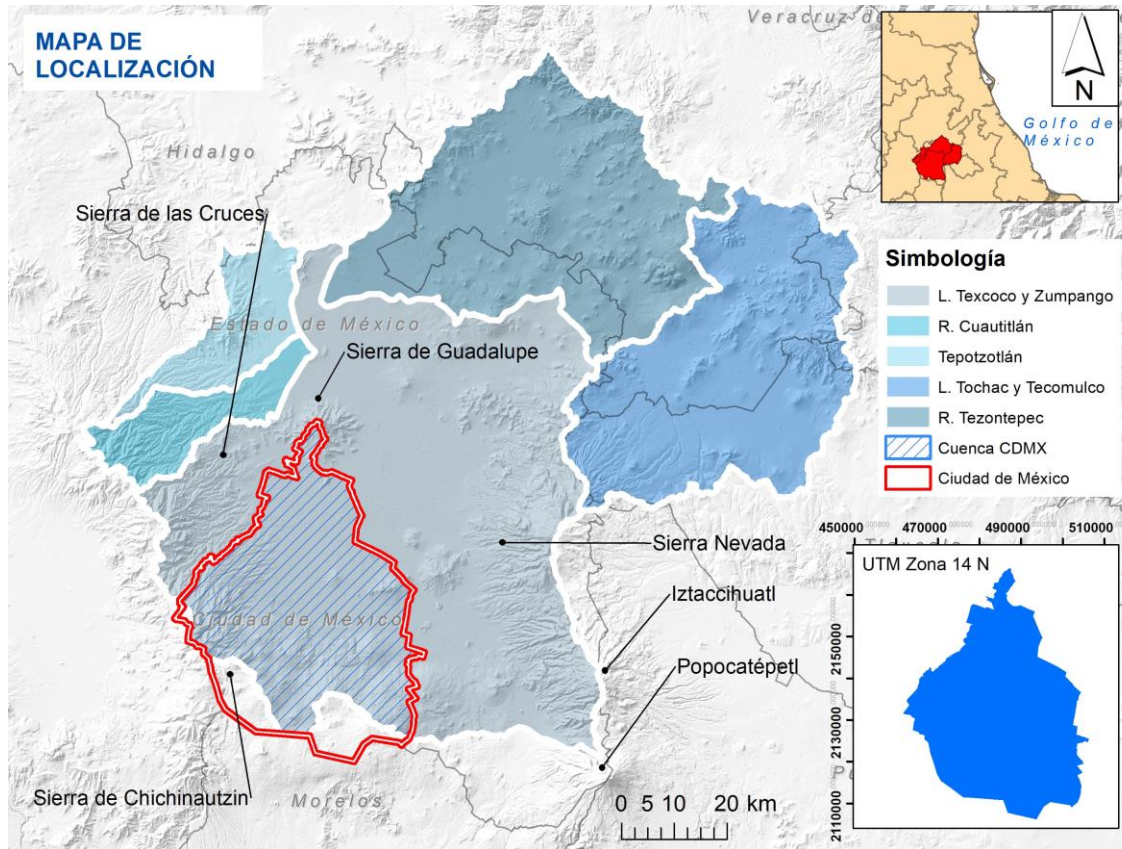


Figura 2.1. Ubicación geográfica de la Ciudad de México.

Políticamente, la Ciudad de México está dividida en 16 alcaldías (Figura 2.2). En general, la mancha urbana se extiende a lo largo de estas 16 demarcaciones, con excepción de las alcaldías Tlalpan, Milpa Alta y Xochimilco; las cuales cuentan con mayor superficie de suelo de conservación<sup>1</sup>; le siguen Cuajimalpa, Magdalena Contreras, Álvaro Obregón, Tláhuac y parte de Iztapalapa (el cerro de la Estrella). La mayoría de las zonas afectadas por la mancha urbana están al sur y al oriente de la capital (P. López, 2019).

Po otra parte, la diferencia de alturas dentro del estado de México ocasiona que se presente desde un clima húmedo en la zona montañosa, hasta otro seco y caliente en las zonas más bajas del valle. La precipitación promedio anual varía en un rango de los 600 a los 1500 milímetros, distribuyéndose por lo general de mayo a octubre (MJJASON); y las

<sup>1</sup> El suelo de conservación en la capital del país es una delimitación entre el suelo urbano y el que no lo es. Esta zona de transición la hay solamente en Ciudad de México por decreto, desde 1987.

lluvias se desplazan generalmente del noreste al suroeste de la Ciudad de México (León & Neri, 2010).

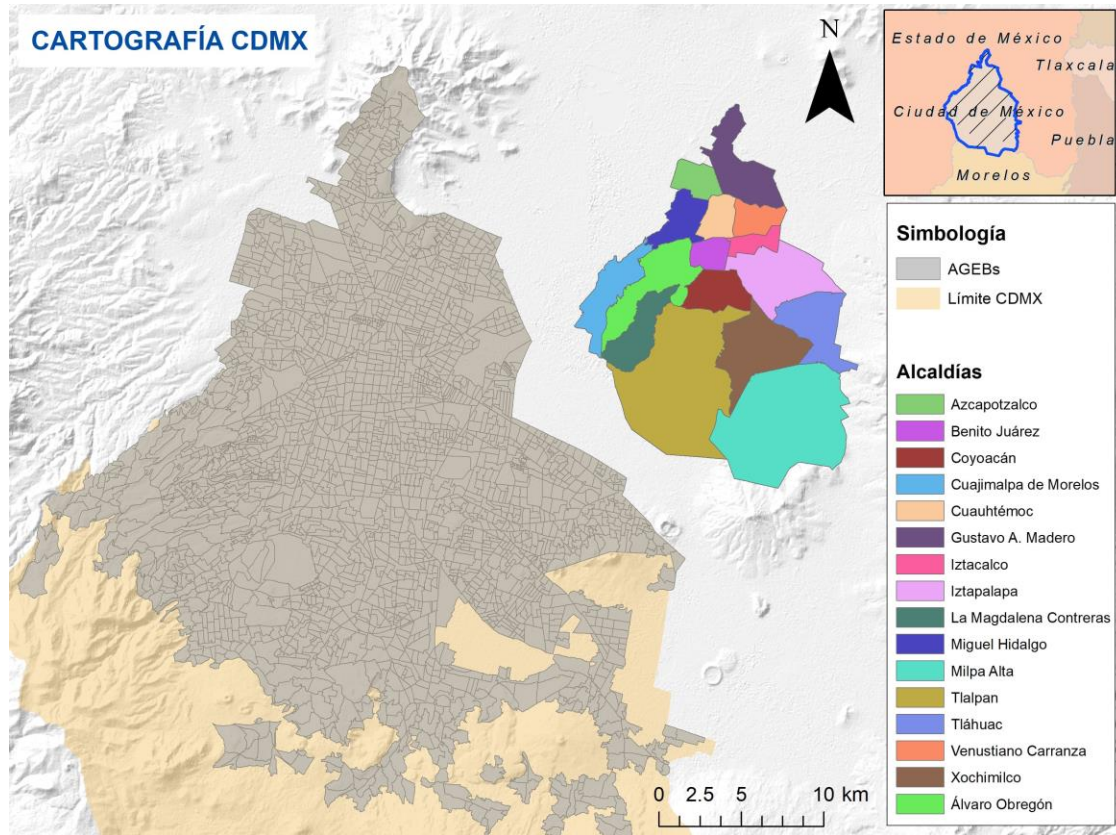


Figura 2.2. Mapa cartográfico de la Ciudad de México. Alcaldías y Áreas Geoestadísticas Básicas Urbanas (AGEB<sup>2</sup>).

Fuente: Información vectorial obtenida de INEGI, (2021b).

La pérdida de agua de lluvia por el escurrimiento natural ocurre en la zona de conservación. Una porción de la lluvia que cae en dicha zona, escurre a través de la Sierra de Chichinautzin; mientras que una gran parte de la lluvia que genera escurrimientos entra al sistema de drenaje en la zona urbanizada situada en el límite inferior entre el valle y la zona de conservación. Este volumen de agua presenta un gran riesgo debido a las altas velocidades alcanzadas en las pendientes fuertes del terreno.

<sup>2</sup> Área geográfica ocupada por un conjunto de manzanas que generalmente va de 1 a 50, perfectamente delimitadas por calles, avenidas, andadores o cualquier otro rasgo de fácil identificación en el terreno y cuyo uso del suelo sea principalmente habitacional, industrial, de servicios, comercial, etcétera, sólo se asignan al interior de las localidades urbanas (INEGI, 2010).



El volumen de agua que escurre desde las zonas más altas de la ciudad corresponde a casi el total del volumen anual de lluvia que cae en algunas demarcaciones urbanas del valle; como las alcaldías Venustiano Carranza e Iztacalco.

En la Figura 2.3 se muestra un mapa con las corrientes superficiales y cuerpos de agua en la Ciudad de México, actualizados al año 2021. Algunas de las corrientes del poniente como el “Río de los remedios” y “Río Tlalnepantla” se vuelven canales en la zona más baja de la cuenca. Este mismo mapa también presenta las zonas sujetas a inundación aledañas a la ciudad de México; siendo la más importante de éstas, la ubicada en Texcoco, en las cercanías al “Lago Doctor Nabor Carrillo”.

Por último, el dominio de estudio se presenta de manera ampliada en la esquina inferior derecha del mapa de la Figura 2.3; el cual se determinó con base en las cuencas de aportación a la ciudad de México y su límite territorial.

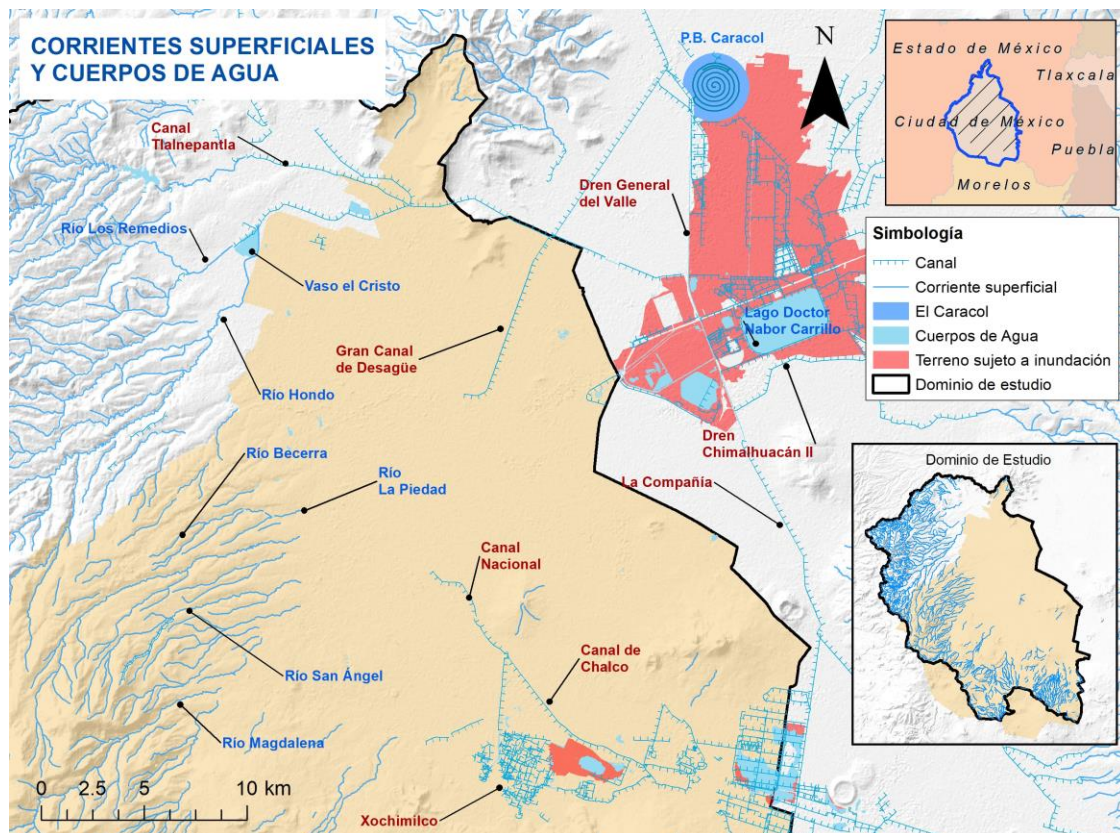


Figura 2.3. Mapa de corrientes superficiales y cuerpos de agua de la Ciudad de México.

Información vectorial obtenida de INEGI, (2021).

## 2.2. Historia de las inundaciones en Ciudad de México – Drenado del Lago

Para albergar a la creciente población de la ciudad; a lo largo de su historia se han llevado a cabo una serie de obras de infraestructura que, desde tiempos remotos, han estado vinculadas al sistema hidráulico de la cuenca. La Zona Metropolitana del Valle de México (ZMVM) cuenta con tres salidas artificiales denominadas: **Gran Canal de Drenaje** (Túneles de Tequixquiac), **Emisor del Poniente** (Tajo de Nochistongo) y **Emisor Central** (Figura 2.7). Construidos en diferentes épocas, cada uno de estos elementos de drenaje han sido diseñados pensando en resolver de forma definitiva el problema de desalojo y control de niveles de agua, principalmente en la ciudad de México y su Zona Metropolitana.

Donde ahora se asienta la ciudad de México, se encontraba un sistema de 5 lagos ubicados en la parte baja de una cuenca hidrológica; y que cubrían una superficie de 1500 km<sup>2</sup>. La Antigua Tenochtitlán; capital del imperio Mexica (Figura 2.4), fue fundada en el año 1325, en donde el aprovechamiento de los recursos hídricos permitió a los Mexicas establecer la cultura lacustre más avanzada de Mesoamérica.

La relación de Tenochtitlán con el agua cambió radicalmente con la llegada de los conquistadores españoles en 1521, quienes destruyeron la ciudad para erigir otra acorde con los patrones europeos (Once TV México, 2013). Esto dio inicio a la eliminación de la cultura lacustre y el comienzo del drenado del agua de la Cuenca de México, desapareciendo cerca de 1100 km<sup>2</sup> de agua a lo largo de 400 años.

En la capital novohispana; que comenzaba a construirse sobre las ruinas de la antigua Tenochtitlán, las inundaciones eran el gran problema que los españoles deseaban resolver a toda costa (Once TV México, 2013). Se rellenaron canales que daban paso libre a las aguas y comenzó la paulatina desecación de los lagos.

El 14 de noviembre del año 1552, Don Luis de Velasco el Viejo, vio con terror como aguas provenientes del norte invadían la capital novohispana, en donde la predicción de un ciclo de inundaciones por parte de los indígenas, produjo la combinación de las ingenierías prehispánica y novohispana para dar respuesta a las inundaciones; enfocándose

principalmente en la problemática de los ríos que abastecían al lago de Texcoco (Llanas y Fernández, 2017).

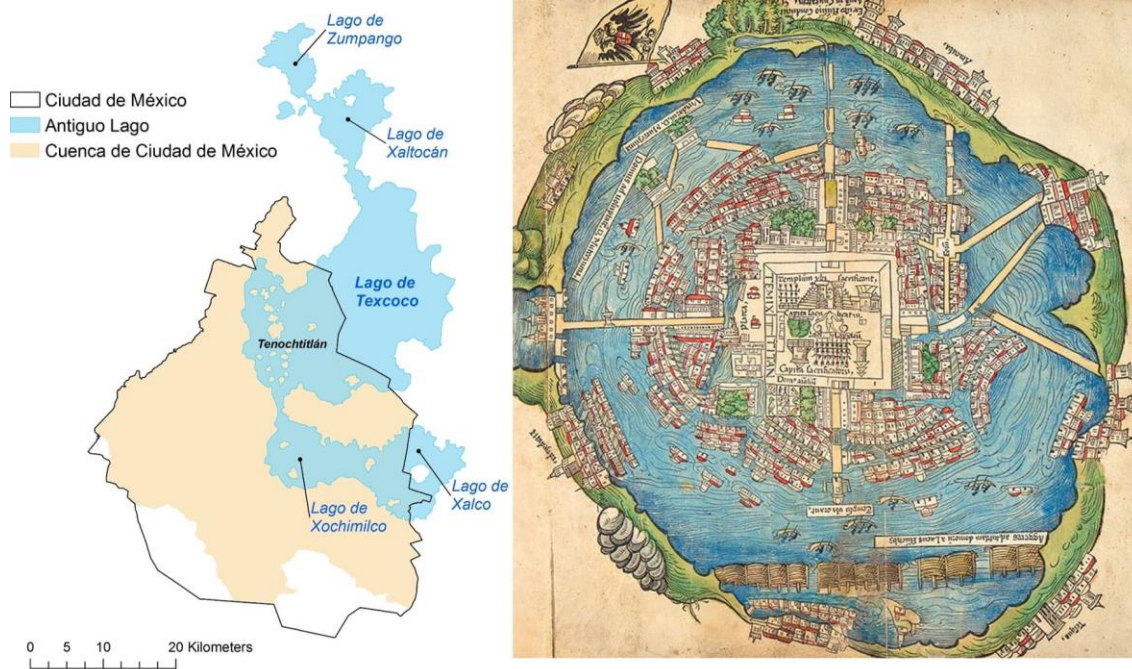


Figura 2.4. Lago de Texcoco y Mapa de Nuremberg, 1524.

El mapa muestra a la izquierda una representación del antiguo lago de Texcoco y a la derecha la Ciudad de Tenochtitlán. El centro está representado por el Templo Mayor, y lo que actualmente es el Centro Histórico de la Ciudad de México (Instituto de Investigaciones Históricas - UNAM, 2020).

A principios del siglo XVII se daría inicio al vaciado de la Cuenca de México. Las inundaciones de la ciudad ocurridas en la época colonial (1604 y 1607) originaron el inicio de las labores de construcción de los canales de Huehuetoca (diseñado por Enrico Martínez) y Tajo de Nochistongo (7 km de longitud) para la creación de la primera salida artificial de agua (inundaciones causadas por el río Cuautitlán y lago de Zumpango) al golfo de México, a través de los ríos Moctezuma y Pánuco.

A pesar de estas obras de drenaje, la ciudad continuó inundándose periódicamente. Por ejemplo, se registra la inundación de 1629, la cual invadió la zona urbana durante 5 años (Figura 2.5).

Posteriormente, en el siglo XIX, después de la independencia del dominio español en México, se desarrolló el proyecto del “Gran Canal de Desagüe”; el cual inició su

construcción en tiempos de Maximiliano y continuó bajo la administración de Porfirio Díaz (inaugurado el 17 de marzo de 1900). Este canal serviría para captar los escurrimientos de la Ciudad de México, Estado de México y los excedentes del Lago de Texcoco (Reinoso et al., 2012). En su momento esta obra ayudó suficientemente a evitar inundaciones; pese a lo cual, no bastó para la proyección y crecimiento demográfico del siglo XX.



Figura 2.5 Ciudad de México en la época colonial

Entre 1938 y 1940, los hundimientos en el centro de la ciudad rebasaron 50 cm anuales, y el drenaje construido a principios de siglo comenzó a presentar fracturas y dislocamientos.

Para 1940, la ciudad contaba con tres millones de habitantes, y las zonas urbanas se extendieron, por lo que el canal de desagüe ya no era suficiente para desalojar todas las aguas del norte y el oriente de la ciudad. Para contrarrestar estas limitaciones; entre 1937 y 1946, se abrió el segundo túnel de Tequixquiac (11 km de largo, 4 metros de diámetro y 100 metros de profundidad) para continuar con el vaciado de la cuenca; pero el problema del drenaje no se resolvió.

En 1925, el Gran Canal comenzó a hundirse debido a las perforaciones y explotación de los mantos acuíferos (Reinoso et al., 2012), invirtiendo su pendiente y provocando el

regreso del agua a la ciudad. Esto dio como resultado la inundación del centro de la ciudad en 1951 (Figura 2.6); en donde un torrencial aguacero descargó sobre el valle de México convirtiendo a la Ciudad en un lago inmenso (Once TV México, 2013).



Figura 2.6. Inundación de la ciudad de México en 1951. Centro Histórico.

Para regular los escurrimientos de la zona de lomerío al poniente de la ciudad, se construyeron entre 1929 y 1940 las presas de Tecamachalco, del Tornillo, Becerra, Tacubaya, Mixcoac, del Capulín y de Guadalupe (ver Figura 2.7).

A finales de los 50, en la entonces Dirección General de Obras Hidráulicas surgió la idea de construir un gran sistema de drenaje profundo que no estuviese afectado por hundimientos. La primera etapa de esta obra (Túnel Emisor Central) fue inaugurada en 1975; y actualmente está compuesto por nueve interceptores y un emisor central (salida principal de agua de la Ciudad de México, ver Figura 2.7); y diariamente desaloja agua residual y de lluvia al estado de Hidalgo (Transmonte, 2015). Esta obra tiene 50 km de longitud, 6.5 metros de diámetro y construido a 240 metros de profundidad. A pesar de que la obra se planteó originalmente para desalojar agua de lluvia, se decidió utilizarla también para aguas residuales, debido a la falta de capacidad de drenaje del Gran Canal.

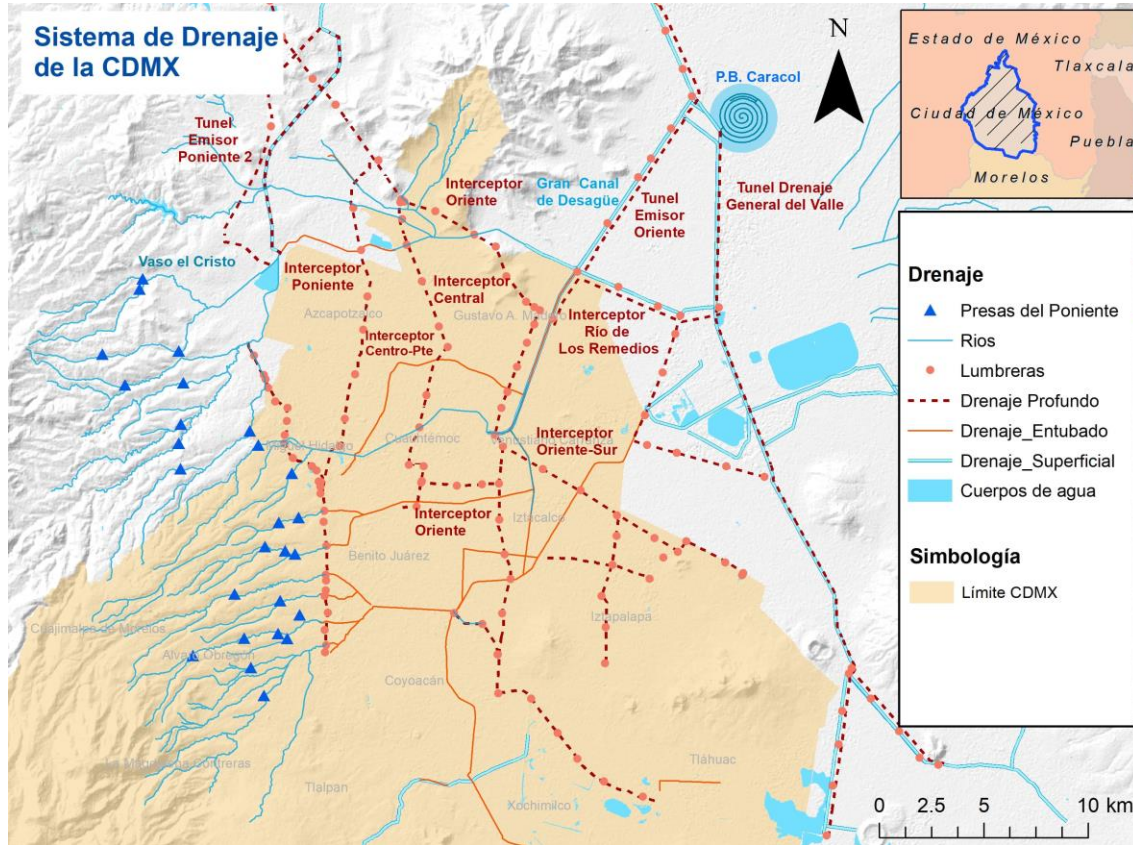


Figura 2.7. Sistema de drenaje de la Ciudad de México.

En la década de los años setenta; durante la construcción del sistema de drenaje profundo, se cambiaron tuberías y colectores de las colonias beneficiadas, aunque, el drenaje continúa siendo insuficiente en algunas zonas. Entonces, para aliviar las inundaciones ocasionadas por lluvia en aquellas zonas de la ciudad con drenaje ineficiente; en el año 2008, la Comisión Nacional del Agua (CONAGUA) inició la construcción del Túnel Emisor Oriente (TEO), el cual fue inaugurado en diciembre de 2019. Esta obra está planeada para funcionar de forma simultánea con el actual drenaje profundo durante la temporada de lluvias. No obstante, la construcción del TEO ha generado problemas sociales y ambientales. La población de Tula en el Estado de Hidalgo reclamó en 2017 (Camacho Servin, 2018) que el río Tula ya no soporta más descargas residuales que desde hace 50 años se envían allí. La obra del TEO implica llevar el triple de aguas negras de las que ya recibía el río; lo que puede ocasionar problemas sanitarios y de inundaciones en esa región.

Por último, existe un Plan Maestro de Drenaje de la Zona Metropolitana de la Ciudad de México; pero se elaboró en 1994 con proyección al año 2010, por lo que ya no cumple

con la situación actual de la Ciudad (Zamarrón, 2020). Un ejemplo de esto es que el Emisor Central ha operado fuera de sus variables de diseño y sin mantenimiento (Conagua, 2008).

### 2.3. Contexto actual de las inundaciones en Ciudad de México

A lo largo de su historia se han generado impactos en el Valle de México por la expulsión de las aguas y la sobre explotación del acuífero (ver Figura 2.9); problemas directamente derivados del crecimiento exacerbado de la Ciudad que exige un aumento de los servicios para los habitantes y la población flotante<sup>3</sup>.



Figura 2.8. Mapa Mental. Problemática de las inundaciones en CDMX.

En la actualidad, la Ciudad de México se ha expandido a un paso veloz, convirtiéndose en una de las mayores metrópolis del mundo, con una población estimada al 2018 de 21 millones 518 mil habitantes (Forbes, 2018). Los efectos de las inundaciones en

<sup>3</sup> La población flotante es la población que utiliza un territorio, pero cuyo lugar de residencia habitual es otro. La población flotante, sumada a la población residente efectiva, permitirá determinar la “carga de población” que realmente soporta cada territorio (Garroncho Rangel 2011, pag. 27).

la ciudad son exacerbados por el continuo incremento de la población y desarrollo urbano; y un sistema de drenaje que no es suficiente para drenar el volumen total de agua de lluvia.

Este crecimiento urbano tiene otras implicaciones ambientales dentro del valle. El recubrimiento asfáltico y el concreto de la ciudad han devorado las áreas verdes (Connolly, 1999), creando una capa impermeabilizante. Esto impide la infiltración natural a los mantos acuíferos y por consiguiente se aumenta la carga del sistema de drenaje en su funcionamiento para dar alivio al escurrimiento superficial (Reinoso et al., 2012). Estos factores han generado una alteración del ciclo hidrológico dentro de la cuenca; que, combinada con la modificación del uso de suelo y la deficiencia del drenaje, representa un riesgo presente y futuro para la población.

Otro factor importante que contribuye a las inundaciones es la red de caminos; los cuales transportan los flujos de inundación a través de las zonas urbanas (De Almeida et al., 2018). En adición, las inundaciones se ven agravadas por la acumulación de basura en las captaciones de agua pluvial o deficiencias en la capacidad de conducción de las corrientes (Reinoso et al., 2012).

Otro gran problema es la falta de ordenamiento territorial. La construcción de asentamientos urbanos irregulares en llanuras de inundación contribuye al estrangulamiento y bloqueo del flujo, aumentando los daños económicos y sociales. Esto ha ocasionado la construcción de grandes obras de drenaje para dar alivio a comunidades que no deberían haberse establecido sobre una llanura de inundación en primer lugar, generando gastos estratosféricos. Por ejemplo, se desarrollan fraccionamientos en zonas de alto riesgo, con falta de infraestructura básica de alcantarillado y red de agua potable, como sucede en la zona de cerro de la Estrella, sierra de Santa Catarina y sierra de Guadalupe. Inclusive, el sistema de presas del poniente ha sido invadido en sus alrededores por asentamientos populares que provocan con ello la reducción en la capacidad de las presas (Figura 2.10).

También se han construido fraccionamientos residenciales aguas abajo de las cortinas de las presas, que impiden que las obras de excedencias puedan descargar eficientemente hacia el cauce natural de los ríos (Reinoso et al., 2012).



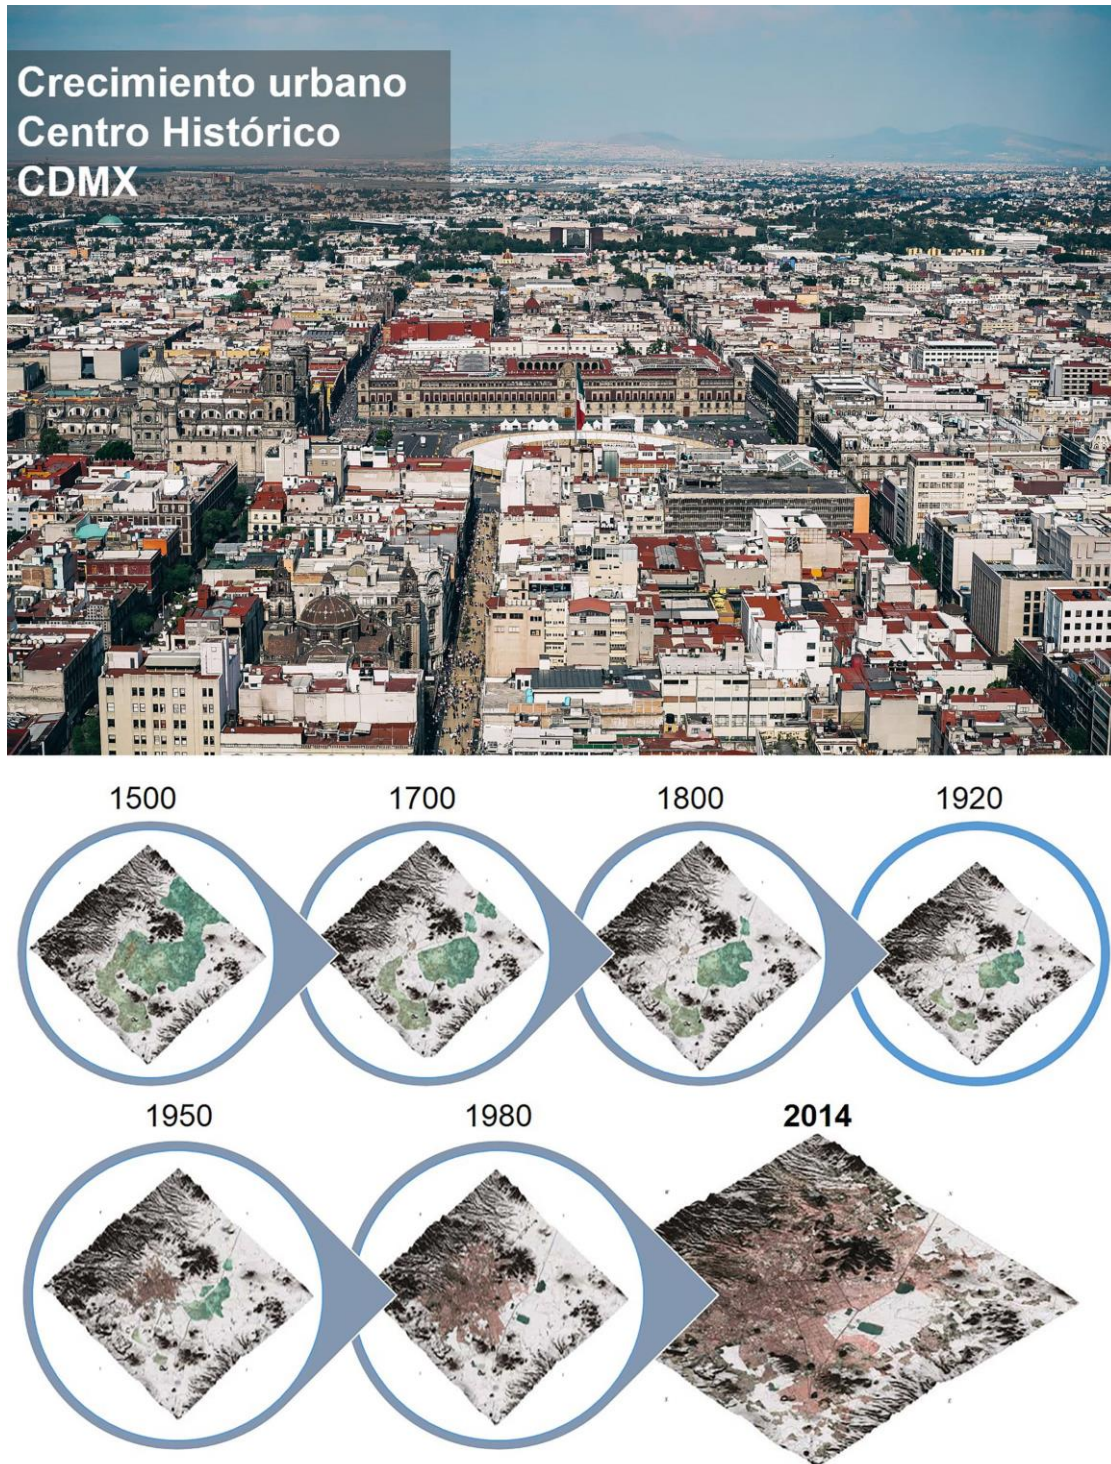


Figura 2.9. Crecimiento exacerbado de la Ciudad de México y drenado del lago.

Arriba: Crecimiento exacerbado de la ciudad. Fotografía aérea del centro Histórico. Abajo: Línea de tiempo del drenado del Lago del Valle de México (Salinas et al., 2016). El vaciado de lo que era el antiguo lago de Texcoco continúa, por lo que se ha reducido dramáticamente su superficie. Fuente: Salinas et al., (2016)



Figura 2.10. Presa Becerra A. Fecha: 11/08/2020

Las imágenes muestran la falta de mantenimiento en la Pesa Becerra A en la alcaldía Álvaro Obregón al poniente de la Ciudad. En época de lluvias, los desechos obstruyen compuertas y salidas de agua causando inundaciones. Fotografías tomadas por M. en I. Marcela Liliam Severiano Covarrubias

En tiempos recientes el gobierno de la ciudad ha estado sustituyendo el drenaje de concreto; desgastado por el paso de los años, por otro de mejor calidad. Estos daños al drenaje son ocasionados sobre todo por el hundimiento de la ciudad y el daño sufrido durante las construcciones del metro, los sismos, los acomodamientos del subsuelo, así como las construcciones de gran altura y peso. Adicionalmente, la capacidad del alcantarillado se ve reducida por el azolve de las tuberías, ocasionado por la deforestación de las cuencas o por obras que dejan tierra y material que acaba sobre las calles y dentro del drenaje, además de la basura que es acarreada por el escurrimiento del agua hacia las alcantarillas (Reinoso et al., 2012).

Más aún, el hundimiento de la ciudad de México continúa siendo una situación alarmante. La expulsión de las aguas; antes por gravedad, ahora tiene que hacerse por bombeo para elevar las aguas hasta el nivel del Gran Canal (Reinoso et al., 2012). Actualmente, en algunos sitios, el hundimiento es de un centímetro al año, pero en otros, como Xochimilco y Texcoco, es de 18 y 25 cm anuales, respectivamente (ver Cigna and Tapete, 2020).

### 2.3.1. Hundimientos

La ciudad enfrenta un severo desafío hídrico, a través de procesos en cascada y entremezclados: frecuentes inundaciones desde los cerros hacia el centro de la cuenca del Valle de México, olas de calor, escasez de agua debido a la creciente demanda para uso municipal, agrícola e industrial, y pérdida significativa de agua debido a fugas de tuberías. A su vez, la explotación del agua subterránea (que proporciona ~ 70% del agua potable) en exceso de la recarga natural induce el agotamiento del sistema acuífero y el hundimiento del suelo, con tasas excepcionalmente rápidas de ~ 40 cm / año (Galloway & Burbey, 2011). Esto causa grietas en la superficie, asentamientos desiguales, edificios inclinados y deformados, aparente levantamiento de estructuras profundamente cimentadas o apiladas y otras formas de daño a la infraestructura urbana, mayor exposición a inundaciones superficiales y modificación de la respuesta sísmica de la cuenca (Cigna & Tapete, 2020).

El asentamiento diferencial en las márgenes de las áreas en hundimiento, que a veces ocurre por encima de las discontinuidades en la geología del lecho rocoso y la estructura del sistema acuífero, son la causa principal del desarrollo de fallas superficiales, grietas y daños en la infraestructura urbana. En la Ciudad de México, esto se debe a las grandes tensiones de tracción que se producen en el suelo cuando se produce una compactación diferencial en las zonas de transición brusca entre suelos blandos y firmes (Cigna & Tapete, 2020).

En 2020, los mayores hundimientos en la Cuenca del Valle de México se extienden a través de Nezahualcóyotl y revelan la ocurrencia de hasta -3,0 cm / mes en dirección vertical. Esto es consistente con la tendencia a largo plazo de -35,0 cm / año observable en la Figura 2.11.

La amenaza producida por los hundimientos se puede determinar basándose no solo en la velocidad de desplazamiento anual o el asentamiento total (es decir, la magnitud de la subsidencia), sino también en el asentamiento diferencial entre dos puntos, que a su vez produce una distorsión angular,  $\beta$ :

$$\beta = \frac{\Delta z}{l} \quad (2.1)$$

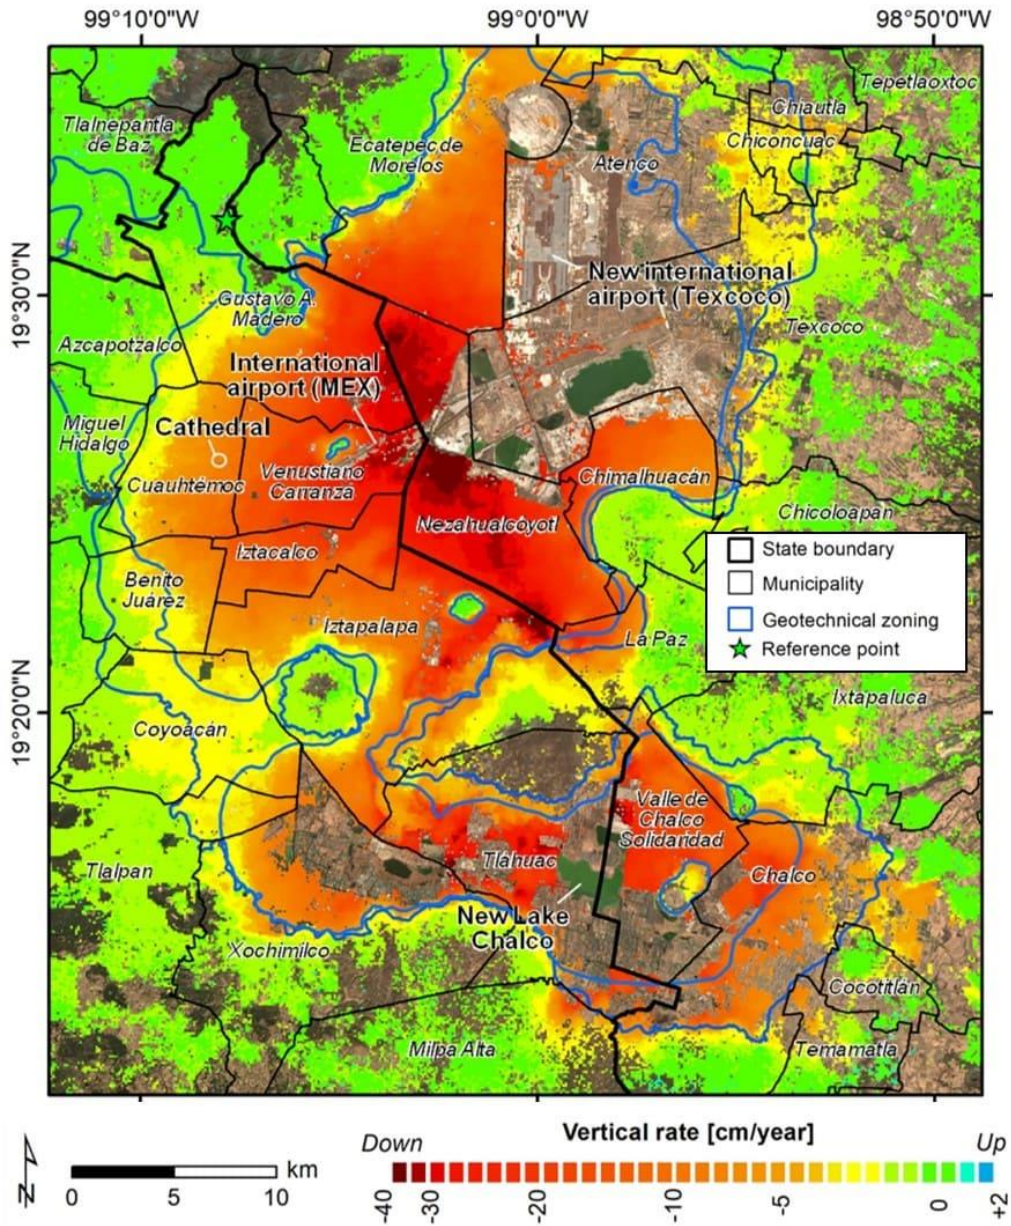


Figura 2.11 Vista detallada de la velocidad de desplazamiento vertical en la Ciudad de México en 2017-2019.

Fuente: Cigna & Tapete, (2020).

Los gradientes horizontales de subsidencia más pronunciados en 2017-2019; y más vulnerables a fallas superficiales se concentran principalmente en la transición entre sedimentos lacustres y unidades de roca dura (estructuras volcánicas), por ejemplo, en el sector sureste de Nezahualcóyotl y en Iztapalapa (Figura 2.12). En esta área, se estiman

asentamientos diferenciales de más de 25 cm en 2 años a distancias de 100 m (es decir, 0,25%), lo que indica distorsiones angulares  $\beta$  de más de  $1/400$ , es decir,  $0,14^\circ$ .

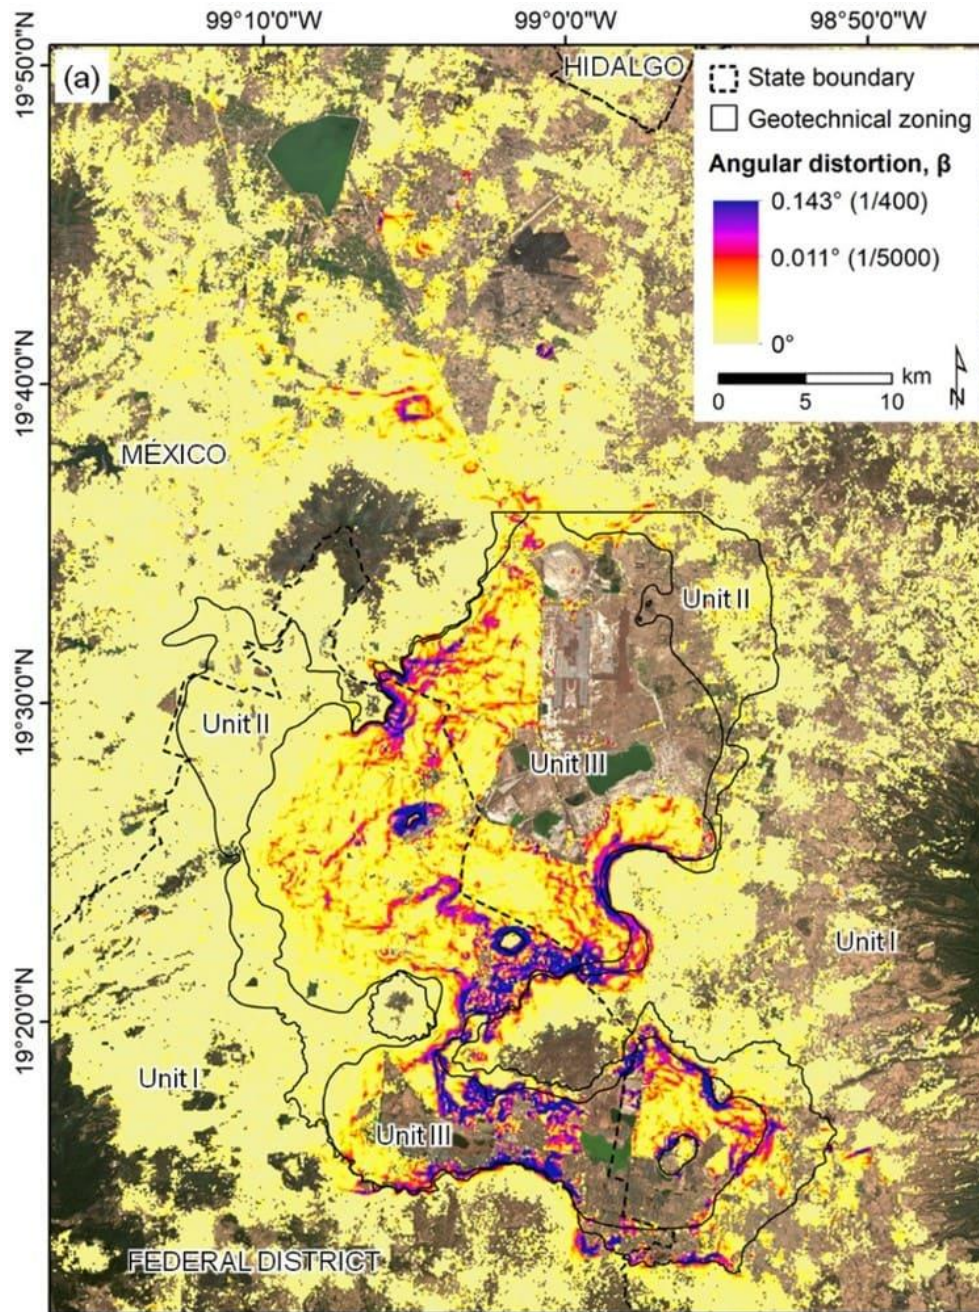


Figura 2.12 Distorsiones angulares  $\beta$ . Análisis del peligro de fallas superficiales inducidas por subsidencia en la Ciudad de México en 2017-2019.

Fuente: Cigna & Tapete, (2020).

Esta distorsión angular o asentamiento diferencial también puede afectar las redes de servicios públicos, como el agua potable, tuberías y colectores del sistema de drenaje combinado, que incluye tanto aguas grises de los hogares como aguas negras. Estos hundimientos diferenciales son el principal reto en cuanto al Sistema de Drenaje de la Ciudad.

El incremento de los hundimientos altera la morfología urbana, favoreciendo el desarrollo de depresiones topográficas, algunas de las cuales pueden alcanzar profundidades mayores a los cuerpos de agua existentes; y cuando el flujo de inundación excede la capacidad del sistema de drenaje, estas depresiones pueden incrementar el impacto de una inundación catastrófica. En orden descendente, Tláhuac, Venustiano Carranza, Iztapalapa y Gustavo A. Madero, son las principales alcaldías donde el incremento de depresiones topográficas y el potencial aumento a la exposición de inundaciones puede impactar gran parte de las Áreas Geoestadísticas Básicas Urbanas (Cigna & Tapete, 2020).

### **2.3.2. Eventos de inundación y afectaciones**

Las inundaciones que se producen en la Ciudad de México se generan por una capacidad inadecuada del drenaje y un gran número de barreras o impedimentos para el flujo (Plate, 2009), y durante la temporada de lluvias; que por lo general ocurre de mayo a noviembre, las inundaciones y encharcamientos son incidentes que se repiten año con año.

Para la Ciudad de México se considera inundación cuando la profundidad del agua rebasa los 20 cm. Esta es una altura suficiente para causar daños en casa habitación y generar problemas y obstrucciones en las vías de transporte (Reinoso et al., 2012).

Los escurrimientos superficiales que se presentan en las zonas de lomas y montañas (donde existen zonas con pendientes fuertes), como las lluvias torrenciales donde la precipitación es mayor que la capacidad del drenaje, son los principales factores que dan origen a las inundaciones en la Ciudad. La falla de tuberías de alcantarillado (que a menudo están obstruidas por basura) y los desbordamientos de aguas residuales también son un efecto en cascada común de inundaciones súbitas (Cigna & Tapete, 2020).

En el mapa de la Figura 2.13 se muestran los niveles de riesgo de inundaciones a nivel AGEB para la Ciudad de México. Las zonas que tienen un nivel bajo de vulnerabilidad son las correspondientes a la región montañosa, formada por rocas volcánicas (andesita, dacita, basalto). A pesar de ello, las lluvias ocurridas en las zonas altas producen escurrimientos de gran velocidad originando inundaciones súbitas en las zonas más bajas y más susceptibles a inundaciones (región de depósitos aluviales, antigua zona de lago).

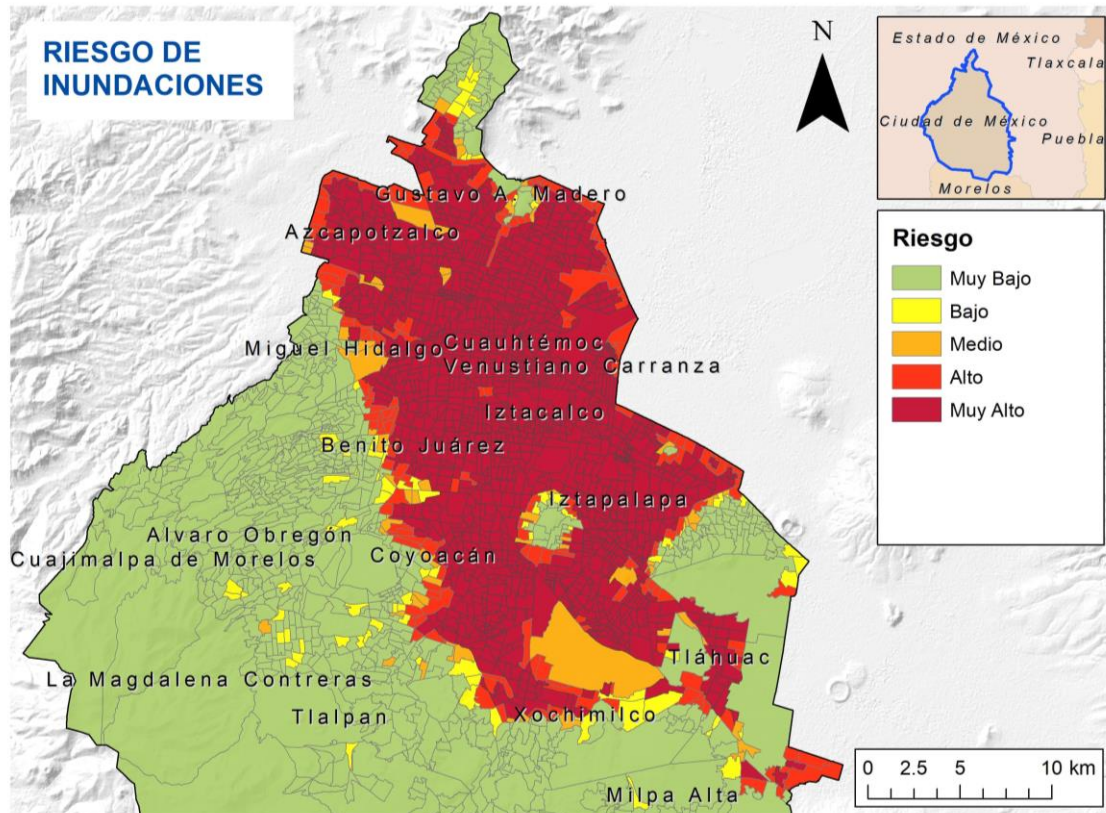


Figura 2.13. Mapa de riesgo de inundaciones asociadas eventos con periodo de retorno de 5 años.

La construcción de este mapa se realizó con base en los datos del “Atlas de riesgo de inundaciones a nivel AGEB”. Secretaría de Gestión Integral de Riesgos y Protección Civil (2019).

En el año 2017 se presentaron inundaciones y encharcamientos por la ocurrencia de fenómenos hidrometeorológicos en la ciudad, lo que derivó en 738 reportes de emergencia (Figura 2.14) atendidas por el Gobierno de la Ciudad de México. Estos encharcamientos producen interrupciones en las vías de comunicación generando daño a los automóviles y conflictos en los tiempos de traslado.

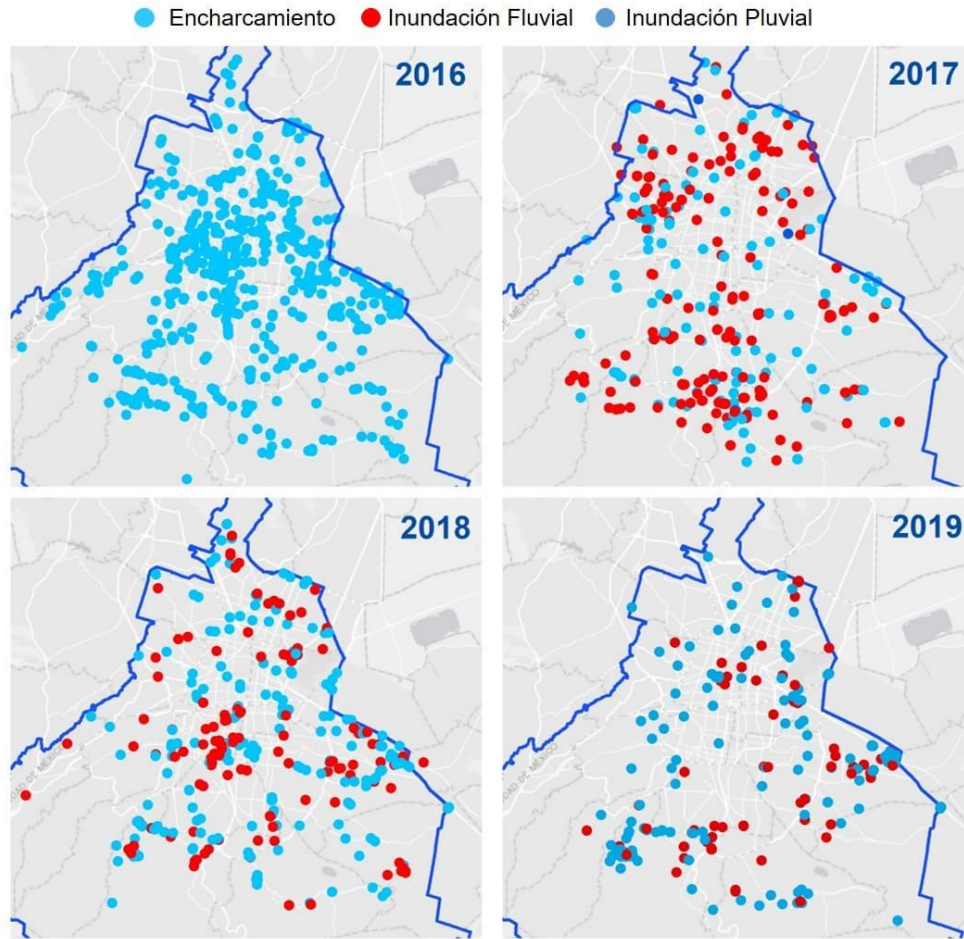


Figura 2.14 Mapa de Incidentes de encharcamientos e inundaciones en la CDMX para los años 2016 -2019.

Los puntos del mapa indican las ubicaciones donde se reportaron los incidentes. La construcción de estos mapas se realizó con base en datos de la Secretaría de Gestión Integral de Riesgos y Protección Civil, (2019).

En la zona de Sierra de las Cruces (ver Figura 2.1), ocurren frecuentes lluvias extremas, combinadas con escurrimientos rápidos debido a las altas pendientes.; y durante la temporada de lluvias, las demarcaciones de Tlalpan, Coyoacán, Miguel Hidalgo, Iztapalapa, Gustavo A. Madero y Nezahualcóyotl, son comúnmente afectadas por inundaciones (Cigna & Tapete, 2020). Esto es consistente con los mapas de la Figura 2.15; donde las zonas más altas de la cuenca alcanzan valores mayores a los 50 milímetros acumulados en 24 horas a partir de un periodo de retorno de 10 años.



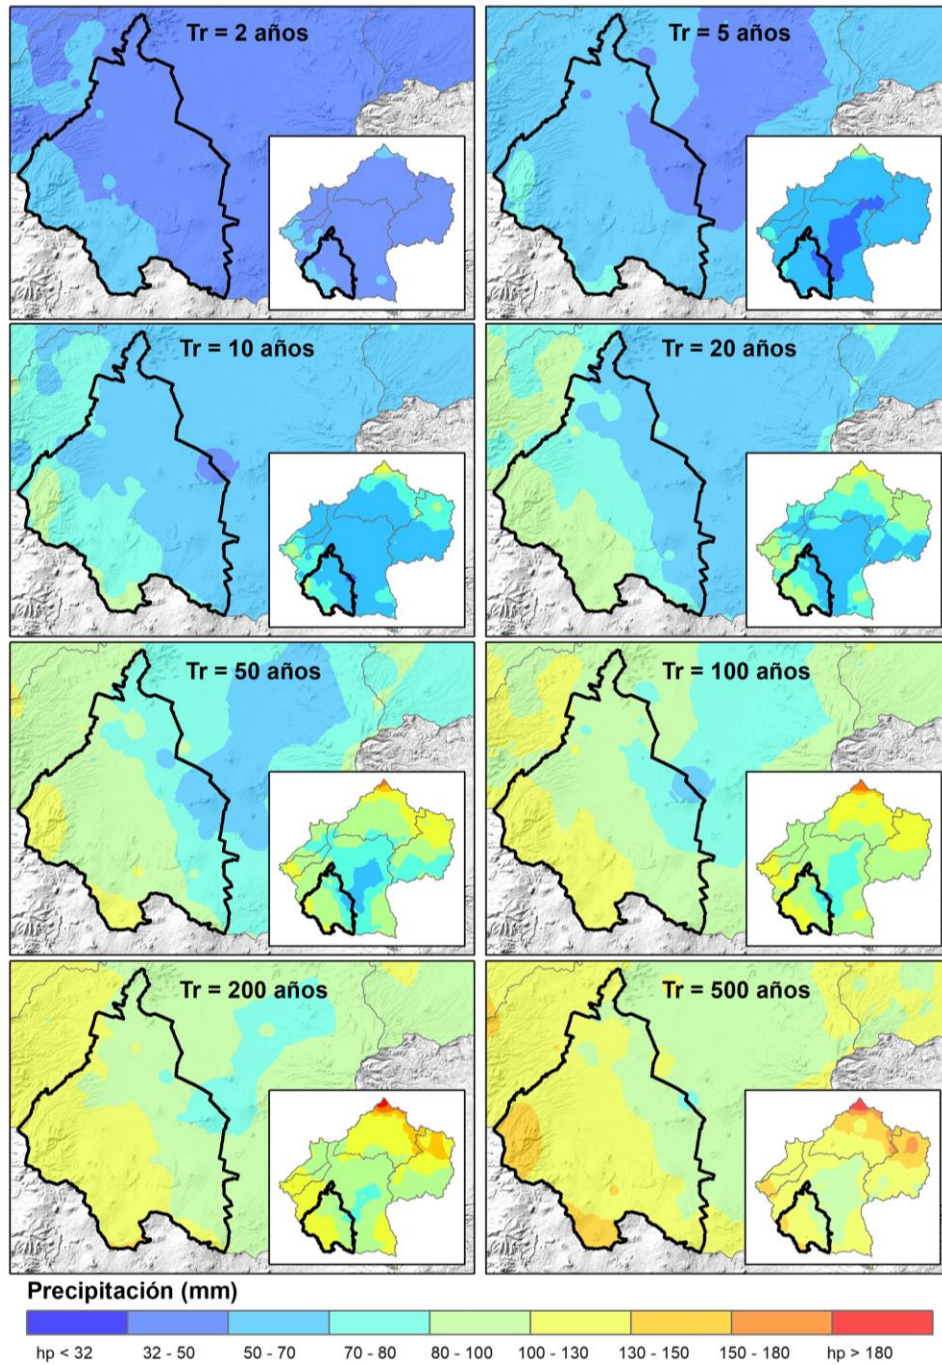


Figura 2.15. Mapas de lluvia para diferentes periodos de retorno en Ciudad de México y Cuenca del Valle de México.

Para la construcción de los mapas se utilizó información del trabajo desarrollado por Domínguez et al., (2018).

En la tabla siguiente se realiza una recopilación de eventos de inundación para el periodo 2017 – 2019; y que afectaron diversas zonas de la ciudad:

Tabla 2-1. Eventos de inundación en CDMX. Años 2017 y 2019

Evento	Fecha	Afectaciones	Referencia
1	29 / 05 / 2017	-Lluvia más intensa en los últimos 17 años -41 colonias de las delegaciones Tlalpan, Xochimilco, Coyoacán y Álvaro Obregón fueron las más afectadas.	EXPANSIÓN, (2017)
2	28 / 06 / 2017	-Inundación del metro. -Lluvia promedio de 5 mm. -7 500 000 m³ de agua acumulados. -Zona más afectada en Miguel Hidalgo con 54 mm. -Inundaciones en circuito Interior, Reforma, Constituyentes, Ejercito Nacional -120 viviendas afectadas en zona de Anáhuac.	(Aristegui, 2017)
3	31 / 08 / 2017	-Oriente de la ciudad afectado por lluvias fuertes. -Zona del aeropuerto inundada. -Inundación en metro Pantitlán. -Colapso de avenidas principales como Circuito Interior y Oceanía. -Desbordamiento de presa El Ángulo. -184 Encharcamientos en la ciudad. -Alerta roja en Venustiano Carranza, Gustavo A. Madero, Azcapotzalco, Cuajimalpa y Miguel Hidalgo. Socavón en las calles Humboldt y Cristóbal Colón.	EL PAÍS 2017
4	06 / 09 / 2017	-Alerta roja por inundación en Tlalpan, Coyoacán, Xochimilco y al menos una docena de cruces viales. -Alerta naranja en Tláhuac, Iztapalapa, Álvaro obregón, Cuajimalpa, Gustavo A. Madero y Magdalena Contreras. -Inundación en Viaducto Tlalpan a la altura de Insurgentes	(FINANCIERO, 2017; González, 2017)
5	05 / 08 / 2018	-Encharcamientos, una bajada de agua. Anegación en segundo piso del periférico a la altura de León Felipe y Barranca de Pilares. -Acumulación de agua de Periférico con Avenida Alencastre, Molinos e intersección con Constituyentes	(LA SILLA ROTA, 2018; NOTIMEX, 2018)

<b>Evento</b>	<b>Fecha</b>	<b>Afectaciones</b>	<b>Referencia</b>
6	20 / 08 / 2018	8 inundaciones, 11 encharcamientos, tres bajadas de agua y afectaciones en redes viales. Una de las colonias más afectadas fue Jesús del Monte en Cuajimalpa. Cuatro inundaciones en Tláhuac.	López 2018
7	27 / 08 / 2018	Alerta Naranja en las delegaciones Iztapalapa e Iztacalco, donde hubo nueve inundaciones y un deslizamiento de tierra; lo que ocasionó problemas viales y autos varados. Los puntos anegados fueron en Calzada Ignacio Zaragoza, Avenida Texcoco y varias colonias de Nezahualcóyotl.	Gómez Flores, 2018
8	22 / 09 / 2018	Alerta Naranja en delegaciones Cuauhtémoc y Venustiano Carranza. Inundaciones en: <ol style="list-style-type: none"> <li>1. Eje 1 Norte y Circuito Interior</li> <li>2. Av. 533 y Río Consulado, COL San Juan de Aragón</li> <li>3. Circuito Interior y Norte 25, Colonia Moctezuma</li> <li>4. Av. 661 y Av. 604, colonia Aragón Fovissste</li> <li>5. Circuito Interior y Tlacos, colonia Casas Alemán</li> </ol>	METRÓPOLI 2018
9	18 / 07 / 2019	Alerta amarilla en las delegaciones: -Álvaro obregón, Benito Juárez, Coyoacán, Cuajimalpa, Magdalena Contreras y Xochimilco	(Publimetro, 2019)
10	10 / 09 / 2019	-Alerta Naranja en las alcaldías Iztacalco, Iztapalapa y Venustiano Carranza. -Alerta amarilla en Azcapotzalco, Benito Juárez, Coyoacán, Cuauhtémoc, Gustavo A. Madero, Miguel Hidalgo, Tláhuac, Tlalpan y Xochimilco. -Inundación en Calzada Ignacio Zaragoza y República Federal en Iztapalapa.	(Chilango, 2019)

El problema de inundaciones en la Ciudad de México existe desde la época de la Antigua Tenochtitlán y las medidas que se han implementado para su control se han enfocado más en una planeación reactiva; como la construcción de grandes obras de drenaje, en lugar de implementar medidas de prevención, por lo que será necesario hacer consideración de esto en la planeación futura del Drenaje en la Ciudad.

Una de las propuestas más lógicas para el control de inundaciones en la ciudad es el ordenamiento territorial. Esta medida podría traer beneficios en cuanto a la mejora de servicios a la población; aunque por cuestiones sociales, es una solución poco factible.

Para evitar que el problema de las inundaciones siga en aumento, es necesario buscar metodologías alternas y de bajo costo como el pronóstico y la construcción de mapas de riesgo para la prevención de daños por inundación. Los problemas de infraestructura hídrica que enfrenta México precisan el empleo de nuevas metodologías en donde la ciencia y la ingeniería deben adaptarse a los futuros cambios ocasionados por el cambio climático (Pitt, 2008). En este sentido, México debe enfrentar cuatro desafíos en la creación de un sistema operacional de pronóstico (Adams & Pagano, 2016):

1) Aprovechar los datos disponibles; 2) Pronosticar con los modelos adecuados; 3) Utilizar los modelos hidrometeorológicos para emitir alertas efectivas y 4) Administrar un servicio operacional.



## Capítulo 3. Contexto de la investigación

*“Los pronósticos son casi siempre utilizados en la creencia de que contar con una predicción disponible es preferible a permanecer en completa ignorancia acerca de eventos futuros de interés”*

**Jolliffe and Stephenson, (2013)**

### 3.1. Predicción probabilista de inundaciones

La incertidumbre de los eventos futuros es la razón principal para pronosticar (Krzysztofowicz, 2001). Las sociedades requieren urgentemente información más confiable y precisa del clima; y el desarrollo de metodologías capaces de abarcar la incertidumbre en el proceso de toma de decisiones.

La lluvia es; por lo general, la fuente predominante de incertidumbre en el pronóstico de inundaciones. Existe una amplia variedad de técnicas para pronosticar inundaciones, y la mayoría de éstas utilizan a la precipitación como dato de entrada; ya sea de observaciones, o pronósticos obtenidos a partir de la Predicción Numérica del Clima (NWP<sup>4</sup>). Los modelos hidrológicos para la simulación del proceso lluvia – escurrimiento son los más comúnmente utilizados por investigaciones previas, sobre todo en la primera década del año 2000 (Wu et al., 2020). En consecuencia, la variable más comúnmente predicha es el desbordamiento de ríos.

---

<sup>4</sup> NWP: métodos numéricos de solución y pronóstico del clima que abordan la estabilidad numérica, la precisión, la velocidad computacional y la versatilidad para tratar con más variables de pronóstico y la interacción entre escalas resueltas y no resueltas. Los principales componentes de estos métodos son: la representación de la variabilidad climática espacial mediante la elección de la discretización espacial, el método de pasos de tiempo, las condiciones de frontera y las condiciones iniciales (Bauer et al., 2015).

A pesar de que los modelos hidrológicos continúan siendo una opción popular para la predicción de inundaciones, se han considerado otras opciones; como el uso de modelos hidrodinámicos y los modelos basados en datos.

Los modelos hidrodinámicos son modelos matemáticos que intentan replicar el movimiento de fluidos y, por lo general, se resuelven de forma numérica. Estos modelos simulan el movimiento del agua resolviendo ecuaciones basadas en las leyes de la física. Dependiendo de la representación espacial de la llanura de inundación, los modelos se pueden agrupar dimensionalmente en modelos 1D, 2D y 3D (ver Teng et al., 2017). De los tres modelos anteriores, los 2D son los más ampliamente utilizados para el mapeo de extensión y estimación de riesgo por inundaciones. En contraste, los modelos basados en datos (Machine-learning) o también llamados de “Caja Negra” (Mosavi et al., 2018), son métodos alternativos que utilizan la información disponible, y se han vuelto cada vez más populares en hidrología (Shen et al., 2018). Estos métodos dependen de las relaciones estadísticas de causa efecto entre las variables hidrológicas. Entre estos se incluyen los modelos estocásticos y redes neuronales artificiales (ANNs)<sup>5</sup>; los cuales requieren una gran calidad y extensión de información hidrológica histórica. Adicionalmente, estos modelos requieren un periodo largo de entrenamiento, y sus aplicaciones prácticas para el pronóstico de inundaciones están limitadas por la falta o ausencia de consideración de los cambios físicos en la cuenca (p. ej. uso de suelo). Además, los parámetros dependen de la extensión de la información disponible para llevar a cabo la calibración del modelo (Jain et al., 2018).

Por otro lado, en las últimas dos décadas, la Predicción numérica del Clima (NWP) ha evolucionado de un pronóstico determinista a una predicción probabilista basada en Sistemas de Predicción por Ensamblados (EPS)<sup>6</sup>; los cuales, a su vez, se han utilizado con mayor frecuencia con el propósito de predecir inundaciones en el mundo (Wu et al., 2020). En años recientes, el uso de ensambles ha evolucionado al mejorar su resolución espacial y temporal; y la estimación de diversos parámetros atmosféricos en virtud del crecimiento del

---

<sup>5</sup> Las redes neuronales artificiales se inspiran en la biología de las neuronas del cerebro y son sistemas masivos de cómputo para operaciones en paralelo y consisten en una gran cantidad de procesadores simples con muchas interconexiones (Mao, 1996).

<sup>6</sup> Los Sistemas de Predicción por Ensamblados (EPS) son herramientas para la predicción probabilista basada en Predicciones Numéricas del Clima (NWP). Representan el intento por estimar el rango de escenarios posibles en función de un conjunto de condiciones iniciales.

poder de cómputo. Esto ha ocasionado un incremento en el uso de EPS para la creación de Sistemas de Alerta Temprana para inundaciones fluviales, tanto a nivel global y local (p.ej. Emerton et al., 2016; Lee et al., 2018; Moore et al., 2005; Revilla-Romero et al., 2015; Rodríguez-Rincón et al., 2015; Verbunt et al., 2007), con el objetivo de generar una toma de decisiones más consciente y considerando la incertidumbre de los fenómenos meteorológicos.

Por ejemplo, existen servicios que operan a nivel continental y global, y que emiten pronósticos de temporada, como: “EFAS” (European Flood Alert System, Thielen et al., 2008) y “GloFAS” (Global Flood Awareness System, Alfieri et al., 2013). En el año 2003 la Comisión Europea comenzó el desarrollo del “Sistema de Alerta de Inundaciones Europeo”, (EFAS) el cual apunta a la simulación de los procesos hidrológicos en las cuencas y a proveer información armonizada de inundaciones a lo largo de Europa. EFAS ha demostrado que la predicción de inundaciones por ensambles para un Sistema de Alerta basado en umbrales de inundación, puede ser producido con una cantidad limitada de datos, al aplicar métodos probabilísticos. Por otro lado, el “Sistema Global de Concientización de Inundaciones” (GloFAS) produce pronósticos a nivel global (Figura 3.1) y fue establecido por el Centro de Investigación Conjunta (JRC) de la Comisión Europea y el Centro Europeo para la Predicción de Clima de Plazo Medio (ECMWF).

Los sistemas EFAS y GloFAS son un ejemplo de cómo los ensambles meteorológicos han sido utilizados para la predicción de inundaciones a resoluciones mayores a los 30 km; y para sistemas de alerta por el desbordamiento de ríos, en donde estos productos sirven para alimentar un modelo hidrológico para la estimación de avenidas (Office of Water Prediction, 2018).

Con el objetivo de generar estrategias de manejo de inundaciones en México, uno de los primeros esfuerzos por generar escenarios probabilistas de inundación fue desarrollado por Pedrozo-Acuña et al. (2015), en donde se recreó el evento causado por la Tormenta tropical Arlene (2011) en la cuenca del río Panuco. Este trabajo evaluó la incertidumbre hidrológica mediante la generación de 30 escenarios de escurrimiento



obtenidos a partir de un modelo hidrológico<sup>7</sup> distribuido (Domínguez Mora et al., 2008), y la puesta a punto de un modelo hidrodinámico bidimensional para la construcción de un mapa probabilista de inundación.



Figura 3.1 Amenaza de inundaciones con periodo de retorno de 100 años. Sistema GloFAS.

Pronóstico para el 12 de mayo de 2020.

Otro ejemplo de la implementación de un EPS en México, fue el documentado por Rodríguez-Rincón et al., (2015), en donde se utilizó un Modelo Numérico de Predicción del Clima (NWP) en combinación con un modelo hidrológico distribuido para la generación de un ensamble de escurrimientos, en el río Tonalá, Tabasco. En este estudio, los ensambles fueron considerados por medio de la alteración de los parámetros de multifísica del modelo climático “Weather Research and Forecasting” (WRF, Powers et al., 2017); en contraste con la estrategia de modificación de condiciones iniciales utilizada comúnmente en los servicios meteorológicos del mundo. Este trabajo permitió evaluar la incertidumbre asociada a la predicción del proceso lluvia-escurrimiento y cómo influye la acumulación de los errores de dicho proceso en la predicción de inundaciones.

<sup>7</sup> Modelo que permite estimar el caudal de un río en función de parámetros como el uso de suelo, infiltración, lluvia, evaporación, humedad del suelo, entre otros.

En 2020, Wu et al., estudiaron 70 trabajos de predicción de inundaciones basados en ensambles y encontraron que más de la mitad de las investigaciones se enfocaron en los siguientes análisis:

1. Utilización de ensambles de pronóstico como datos de entrada de un modelo de inundaciones, incluyendo su desarrollo.
2. Comparación de diferentes productos de pronóstico.
3. Análisis de viabilidad que examinan la idoneidad de EPS específicos para su uso en ubicaciones particulares de interés.

Los puntos anteriores indicaron una brecha existente en la aplicación de los EPS para resolver un problema práctico real. Además, la gran mayoría de los estudios de predicción probabilista de inundaciones se han realizado en el hemisferio norte (ver Figura 3.2); y enfocados en la predicción de inundaciones fluviales en zonas rurales o a nivel cuenca (p.ej., Gouweleeuw et al., 2005; Siccardi et al., 2005). Por ejemplo, los ensambles han sido utilizados para la predicción de avenidas en cuencas definidas como la del río Meuse, en Holanda; y la cuenca del río Odra en Polonia (Gouweleeuw et al., 2005); en donde se utilizó predicción determinista y basada en ensambles, derivada de productos EPS del ECMWF; la cual a su vez, sirvió para alimentar al modelo hidrológico distribuido LISFLOOD (Van Der Knijff et al., 2010). En esta investigación demostraron que las predicciones basadas en ensambles, al ser interpretadas por la probabilidad de excedencia, proveen información complementaria al pronóstico determinista; tanto en el caso de subestimación como sobre estimación del flujo medido.

Generalmente, los trabajos de investigación que han utilizado EPS se han enfocado en la predicción de eventos de inundación fluvial; pero en el caso de inundaciones urbanas existen otras consideraciones a tomar en cuenta; como la presencia de estructuras y drenaje. Dentro de algunos ejemplos de la implementación de los EPS en entornos urbanos se puede mencionar el trabajo realizado por Henonin et al., (2013); quienes hicieron una revisión de los modelos basados en la física para inundación pluvial. En este trabajo se analizaron las ventajas y desventajas de la predicción en tiempo real; y establecieron que usar modelos numéricos es una opción importante para el manejo de inundaciones en ciudades.

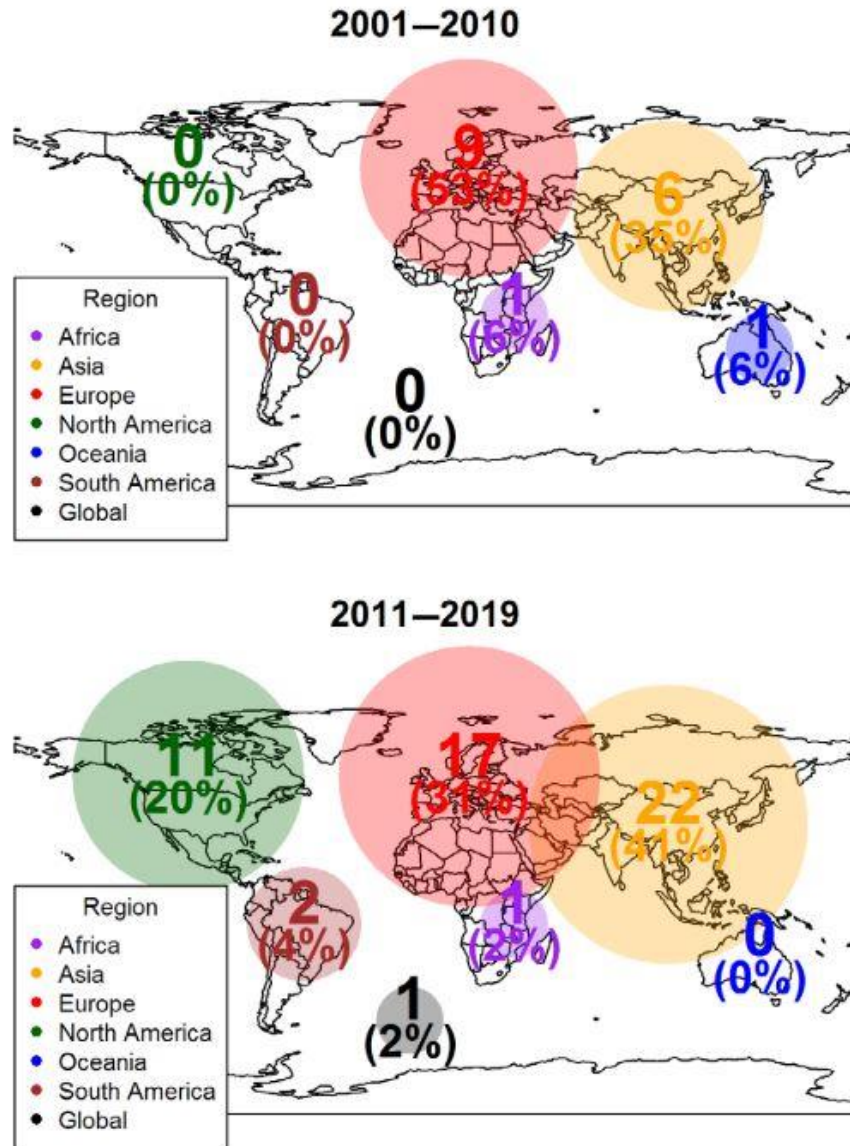


Figura 3.2. Mapa de ubicación de los casos de estudio investigados por Wu et al., (2020).

Los porcentajes en paréntesis representan el porcentaje de las investigaciones en cada región sobre el total de casos de estudio considerados en cada década (Total de casos igual a 70).

### 3.2. El pronóstico en Ciudad de México

En México, el Servicio Meteorológico Nacional (SMN, Gobierno de México, 2020) emite un pronóstico meteorológico extendido a 96 horas con cobertura nacional. Una gran desventaja para el análisis de eventos de inundación es que estos avisos o boletines meteorológicos no muestran datos de la evolución temporal de la lluvia en el horizonte de

tiempo. Por ejemplo, para la vigilancia del Huracán Genevieve del 19 de agosto de 2020 (Figura 3.3), el SMN muestra un pronóstico determinista de la lluvia acumulada para un horizonte de 90 horas utilizando la plataforma meteologix, (2021), la cual a su vez utiliza datos emitidos por el Centro Europeo de Predicción del Clima de Plazo Medio (ECMWF).

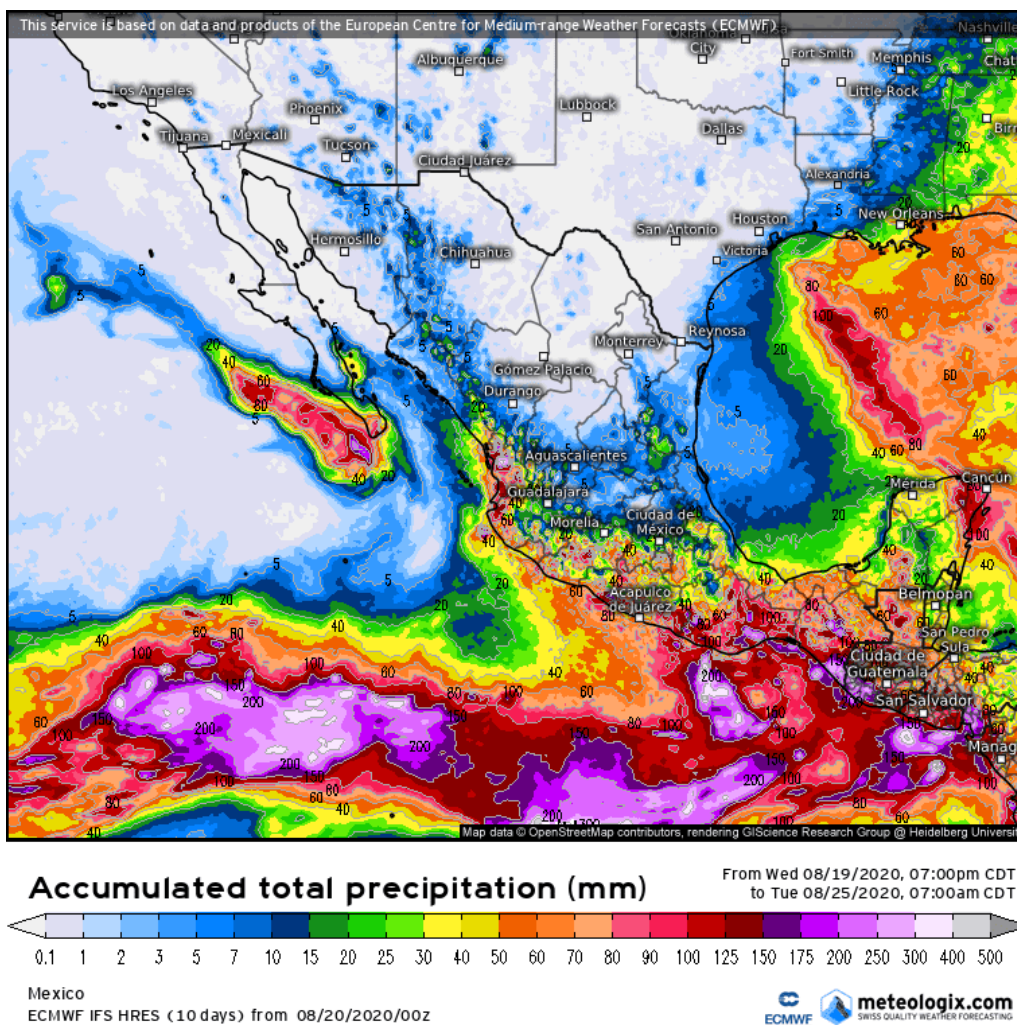


Figura 3.3. Pronóstico de acumulado total de precipitación de 5 días emitido por el Servicio Meteorológico Nacional. Seguimiento del Huracán Genevieve.

Predicción emitida por el Servicio Meteorológico Nacional basado en la plataforma meteologix.com.mx. Datos correspondientes al pronóstico determinista HRES (High Resolution Forecast) del ECMWF.

En el año 2000, el Centro Nacional de Prevención de Desastres (CENAPRED) creó el Sistema de Alerta Temprana para Ciclones Tropicales, SIAT-CT (Gobierno de México, 2021a) como herramienta de coordinación en el alertamiento a la población y en la acción




institucional, ante la amenaza ciclónica, que se sustenta en la interacción de los principales actores del Sistema Nacional de Protección Civil (SINAPROC). Y en años más recientes, el CENAPRED comenzó el proyecto de Atlas Nacional de Riesgo por Inundaciones (ANRI), que muestra las manchas de inundación asociadas a diferentes periodos de retorno para distintas ciudades del país.

Por otro lado, el SMN cuenta con un servicio de observación del tiempo mediante radares meteorológicos (Gobierno de México, 2021b); en donde el radar de Cerro Catedral emite la reflectividad de la lluvia para la Ciudad de México en decibeles (dBz). Por su parte, el Sistema de Aguas de la Ciudad de México (SACMEX, [sacmex.cdmx.gob.mx](http://sacmex.cdmx.gob.mx)) cuenta con un operativo de lluvias fundado en el año 2007, el cual tiene como objetivo dar atención a encharcamientos e inundaciones provocadas por las fuertes lluvias; y adicionalmente, tiene un Semáforo de Alerta de Lluvias por alcaldía con las categorías desde lluvia ligera hasta lluvia torrencial.

En adición, la Secretaría de Gestión Integral de Riesgos y Protección Civil cuenta con su propia clasificación de los Niveles de Alerta de lluvias para la CDMX, y que se describen en la Tabla 3-1.

Tabla 3-1. Clasificación de los niveles de alerta por fenómenos meteorológicos

Fuente: Secretaría de Gestión Integral de Riesgos y Protección Civil (2021)

Alerta	Criterios de Clasificación		Umbral de lluvia mm/24h
<b>Verde</b>	<b>Condiciones promedio en la CDMX</b>		< 15
<b>Amarillo</b>	Presencia de hidrometeoros ligeros que ocasionan daños si se asocian a otras circunstancias		15 - 29
<b>Naranja</b>	Fenómenos meteorológicos cuya intensidad puede producir daños en estructuras frágiles		30 - 49
<b>Rojo</b>	<b>Fenómenos meteorológicos cuya intensidad provoca daños</b>		50 - 70
<b>Púrpura</b>	<b>Fenómenos meteorológicos con intensidad pocas veces registrada, que ocasiona daños graves</b>		> 70

Un intento por estimar futuros escenarios y riesgo por inundación en la Ciudad de México, fue llevado a cabo por Reinoso et al. (2012) quienes construyeron mapas de inundación que muestran las zonas de afectación mediante el cálculo del volumen directo resultado de escenarios de falla del sistema de drenaje en la ciudad. A pesar de que esta metodología no permitió generar resultados probabilistas, sí abrió la puerta al uso de mapas para una mejor planeación en cuanto a ordenamiento territorial y protección civil.

Cabe mencionar que, las estrategias anteriores permiten llevar a cabo una planeación a largo plazo de los recursos hídricos y el drenaje; así como la implementación de acciones de emergencia y protección civil; sin embargo, solo constituyen una planeación reactiva, por lo que no son muy útiles en cuanto a la prevención de posibles y futuros eventos de inundación. En este sentido; para que un Sistema de Alerta sea efectivo, debe basarse en una planeación de emergencia con antelación a la ocurrencia un evento (Zschau & Andreas N. Küppers, 2003).

### **3.3. Desafíos y futuras oportunidades en el uso de Ensamblajes para pronóstico de inundaciones**

Wu et al., (2020) identificaron áreas de investigación y mejoras en el uso de Ensamblajes de Pronóstico para inundaciones; las cuales se enlistan a continuación y se desglosan en el mapa mental de la Figura 3.4:

1. Mejorar la calidad y disponibilidad de pronósticos,
2. Pronóstico para diferentes tipos de inundación,
3. Extender las variables de salida del pronóstico,
4. Extender y acortar la brecha en el horizonte de pronóstico,
5. Extender la generación y evaluación de los ensamblajes.

De acuerdo con los puntos anteriores, es necesario contar con estaciones de medición que permitan evaluar y calibrar los pronósticos. Por otro lado, las inundaciones compuestas (Leonard et al., 2014); las cuales son ocasionadas por dos o más eventos que generan inundaciones, como la ocurrencia de eventos consecutivos de lluvia, o la interacción de diferentes tipos de inundación, han recibido poca atención en los estudios previos. Por lo tanto, el estudio de este tipo de inundaciones es un desafío clave.



Figura 3.4. Mapa mental. Resumen de los desafíos y atención a brechas existentes en el pronóstico de inundaciones basado en Sistemas de Predicción por Ensamblés

Wu et al., (2020) establecieron que otro de los desafíos clave es proveer pronósticos de inundación que representen de forma apropiada la incertidumbre del pronóstico, para lo cual se requiere poder de cómputo suficiente para llevar a cabo múltiples simulaciones de modelos hidrológicos e hidráulicos.

Los estudios previos se han enfocado en la predicción dentro de un rango de tiempo corto a medio; aunque, pronosticar inundaciones con semanas o meses de antelación también puede proveer información crucial para la reducción del riesgo.

Los desafíos actuales deben extender el uso de los ensambles de pronóstico para sistemas operacionales, e incluirlos en la cadena para la toma de decisiones de emergencia y administración hídrica. Mientras la práctica de pronosticar inundaciones sea una actividad recurrente, la predicción debe enfocarse en producir pronósticos precisos y confiables, y mejorar los procesos de verificación (Wu et al., 2020).

Otra limitación relevante de investigaciones previas ha sido la utilización de EPS solo para inundaciones fluviales. Dichas metodologías no son aplicables en el caso de zonas urbanas, en donde las inundaciones se llevan a cabo por efectos pluviales en su mayoría.

En resumen, es importante que los trabajos actuales y futuros sobre pronóstico dirijan sus esfuerzos a casos de inundación a escala local, los cuales se relacionan con inundaciones urbanas o súbitas. Además, es necesario acortar la brecha del uso de modelos numéricos para simulación de múltiples escenarios en el menor tiempo posible; y así, poder emitir una alerta con la antelación adecuada. En este sentido, usar modelos 2D o modelos acoplados brinda una mayor información sobre la profundidad y extensión de la inundación.

Por último, se requiere ampliar el uso de los ensambles para aplicaciones de emergencia, tales como planes de evacuación y mitigación del riesgo para acciones humanitarias (Wu et al., 2020). La evaluación del riesgo por inundaciones debe emplear el mejor conocimiento disponible, al considerar la adaptación de las zonas urbanas a su ubicación geográfica, tomando en cuenta las condiciones climáticas y ambientales, y no basarse exclusivamente en criterios socio-económicos (Moore et al., 2005).





## Capítulo 4. Marco teórico

*“La historia de las ciencias nos demuestra que las teorías son perecederas. Con cada nueva verdad revelada, tenemos una mejor comprensión de la naturaleza y nuestras concepciones, y nuestros puntos de vista, se modifican”*

**Nikola Tesla**

Las metodologías para pronosticar un evento de inundación dependen en gran medida de la zona de estudio y la información disponible.

Los modelos de pronóstico más empleados son los deterministas. Estos involucran dos componentes principales: (i) mecanismos de generación del flujo (lluvia) y (ii) modelos de flujo (hidrológico o hidráulico). Estos modelos se caracterizan por estimar el flujo y tirante de un río mediante la integración de parámetros hidrometeorológicos junto con la descripción física de una cuenca. En ambos modelos, la lluvia es un parámetro crítico; y por lo general la información resultante es el escurrimiento y/o tirantes (Jain et al., 2018). Algunos tipos de cuencas permiten el uso de este tipo de sistemas de predicción; pero existen otro tipo de cuencas en donde la medición de lluvia y estimación del escurrimiento está limitada por el tiempo rápido de respuesta de la cuenca, inhabilitando una reacción oportuna para preparar a la población (Siccardi et al., 2005).

En este sentido, las nuevas metodologías de gestión de riesgo de inundaciones han dado lugar a la utilización de alternativas como el cambio de uso de suelo y el pronóstico; este último constituyendo una opción de bajo costo en comparación con las medidas estructurales.

## 4.1. Sistemas de Alerta contra Inundaciones pluviales

Los sistemas de monitoreo en tiempo real y predicción de inundaciones son herramientas que permiten a los tomadores de decisiones ejecutar la decisión más efectiva bajo incertidumbre al reducir la misma en la evolución de eventos futuros (E. Todini et al., 2005); y se han vuelto cada vez más necesarios, especialmente en zonas urbanas (Bates & De Roo, 2000).

Un sistema de pronóstico y alerta de inundaciones debe alertar al público y a las autoridades correspondientes de una inundación inminente; su objetivo es la emisión del pronóstico a usuarios y agencias con un horizonte de tiempo<sup>8</sup> adecuado y con la mayor confiabilidad posible (Jain et al., 2018). Para que estos sistemas sean funcionales y operacionales, deben ser lo suficientemente precisos dentro de los horizontes de tiempo fijados; así como proveer una cuantificación de la incertidumbre (Ezio Todini, 2004). Además, los pronósticos deben estar disponibles en tiempo casi real, para que puedan ser útiles para predecir un evento.

Dentro de los factores que impactan al horizonte de tiempo se mencionan las condiciones topográficas e hidrometeorológicas de la cuenca y la disponibilidad de información. Adicionalmente, la emisión y frecuencia de los datos de pronóstico; así como su colección y procesamiento, son otros factores que influyen (Jain et al., 2018).

Los principales componentes de los sistemas de pronóstico son: (i) Recopilación de información (meteorológica, hidrológica) y transmisión; (ii) Pronóstico; y (iii) Emisión de la información a los usuarios y agencias. Incluso, el desarrollo de un sistema operacional de pronóstico es una tarea compleja, y existen distintos factores que influyen en su creación; como la disponibilidad de las predicciones y el poder de cómputo (ver Figura 4.1).

El mejor acercamiento para producir un pronóstico probabilista de inundaciones, requiere una metodología que considere las incertidumbres en cascada a través del modelamiento de inundaciones e inevitablemente estará conformada de métodos estadísticos e informales (simplificación de modelos) como partes de dicha cascada. Por

---

<sup>8</sup> Horizonte de tiempo: Periodo entre la hora de emisión del pronóstico y el inicio de su periodo de validez.

ejemplo, al considerar solo la topografía para identificar áreas susceptibles a inundaciones pluviales, se ignora cualquier papel que pueda desempeñar el drenaje subterráneo (o superficial) para aliviar (o no) las posibles inundaciones. A pesar de ello, como lo demostró la inundación de junio de 2007 en Hull (Coulthard & Frostick, 2010), los sistemas de drenaje casi siempre se ven abrumados durante las inundaciones pluviales, por lo que su consideración en una primera etapa es de importancia secundaria. Durante una inundación pluvial, se podría suponer que los sistemas de drenaje han alcanzado su capacidad y, por lo tanto, merecen consideración en una etapa más detallada y de refinamiento del Sistema de Alerta (Falconer et al., 2009).



Figura 4.1. Factores que influyen en un sistema de pronóstico de inundaciones

Fuente de la información: Cloke & Pappenberger (2009)

De acuerdo con las recomendaciones del Proyecto “Flooding from Other Sources” (HA4a; Hankin et al., 2008) existe un orden de prioridad para la prestación de un Servicio de Alerta (ver Tabla 4-1); en donde la creación de un Sistema de Alerta contra Inundaciones Pluviales encabeza la lista con nivel de prioridad A (Sistema de Alerta requerido con urgencia). En general, las inundaciones pluviales son resultado por acción de la lluvia,

ocasionando escurrimiento superficial y encharcamientos antes de que estos sean captados por cuerpos de agua, sistema de drenaje o alcantarillas, o no puedan ingresar a la red de drenaje porque alcanzó su máxima capacidad. Este tipo de inundaciones a menudo son causadas por lluvias intensas de corta duración, aunque pueden ser causadas por lluvias "moderadas" más prolongadas, en ocasiones con lluvia de alta intensidad local. A menudo se asocian con tormentas eléctricas de verano o tormentas convectivas similares, que tienen un área típica de 50 a 100 km<sup>2</sup> y una vida útil típica de alrededor de 1 hora (Falconer et al., 2009).

Tabla 4-1. Orden de prioridad para la creación de un Sistema de Alerta de Inundaciones

Prioridad	Concepto
<b>A</b> <b>Sistema de alerta requerido con urgencia</b>	Inundaciones pluviales
	Exceso de capacidad de alcantarillado urbano y capacidad de drenaje de aguas superficiales;
	Respuesta de las aguas subterráneas a las lluvias extremas prolongadas, los altos niveles de los ríos en las riberas.
<b>B</b> <b>Sistema de alerta menos urgente</b>	Bloqueo o falla de infraestructura urbana
	Rotura de presas
	Tsunami
	Brecha de canal
<b>C</b> <b>Sistema de alerta no urgente pero a tener cuenta</b>	Cursos de agua y alcantarillas pequeños y "perdidos".
	Antiguas rutas de cursos de agua
	Flujo de lodo / escombros
	Falla de la infraestructura de suministro de agua;
	Falla de la infraestructura del sistema de drenaje

Por último, es importante no confundir "inundaciones pluviales" con "inundaciones de aguas superficiales", que es el término generalmente adoptado para describir las inundaciones combinadas en áreas urbanas durante lluvias intensas. Como tal, incluye inundaciones pluviales, inundaciones de alcantarillado, inundaciones de pequeños canales abiertos y cursos de agua urbanos con alcantarillas y flujos terrestres de manantiales de agua subterránea. Las inundaciones pluviales se distinguen de las "inundaciones súbitas", que también pueden estar asociadas con lluvias de alta intensidad, pero generalmente surgen de un curso de agua definido (Falconer et al., 2009).

## 4.2. Sistemas de Predicción por Ensamblés (EPS)

Los Sistemas de Predicción por Ensamblés (EPS) son herramientas para la predicción probabilista basada en Predicciones Numéricas del Clima (NWP). Estos sistemas simulan posibles incertidumbres al añadir pequeñas perturbaciones a las condiciones iniciales de análisis; para así producir diferentes pronósticos para un mismo evento (Persson, 2015).

Estos Sistemas de Predicción por Ensamblés representan el intento por estimar el rango de escenarios posibles en función de un conjunto de condiciones iniciales. Cada miembro de dicho ensamble constituye un pronóstico determinista individual; entonces, este ensamble de pronósticos deterministas se considera como una estimación de la distribución de una variable "x"; la cual, si hablamos de un campo de pronósticos meteorológicos<sup>9</sup>, varía para cada punto dentro de una cuadrícula y en cada paso de tiempo del horizonte de pronóstico (Wilson et al., 1999). A estos productos se les conoce como "Ensamblés de Pronóstico".

Un ensamble de pronóstico (Figura 4.2) produce un rango de posibles escenarios en lugar de un simple valor de predicción; en donde la adición o sustracción de una pequeña perturbación en las condiciones iniciales de un parámetro, emite miembros de igual probabilidad y ligeramente diferentes al miembro original. Las condiciones iniciales

---

<sup>9</sup> Información de pronóstico que corresponde a arreglos espaciales de variables atmosféricas

perturbadas permiten explorar el entendimiento del rango de incertidumbre con respecto de las observaciones y el modelo (Owens, R G, Hewson, 2018a).

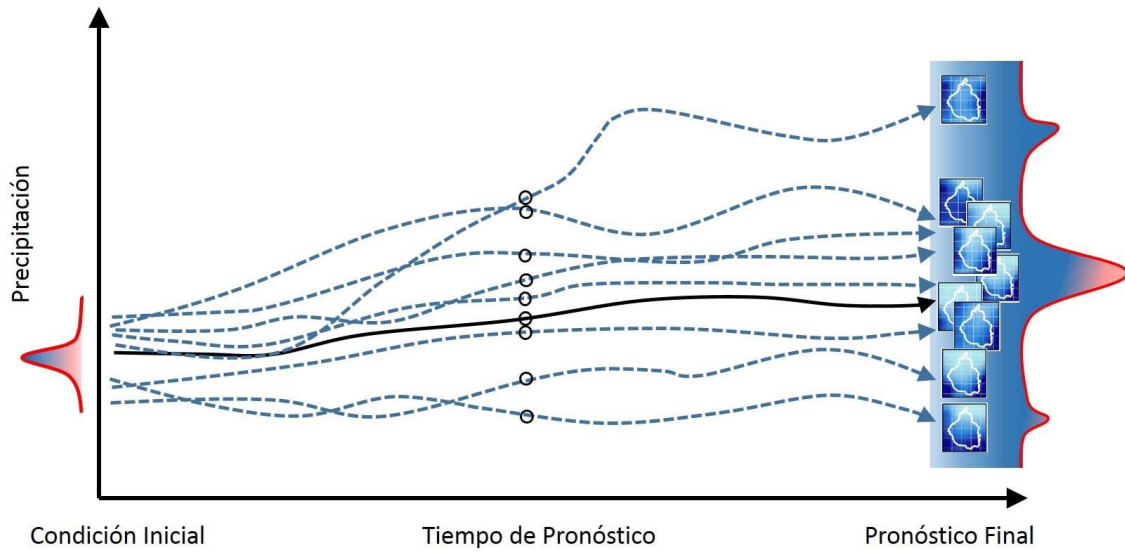


Figura 4.2. Esquema del concepto de ensambles de pronóstico.

Fuente: Imagen elaborada por el autor

Las líneas representan la evolución de 9 estados iniciales de la atmosfera a través del horizonte de pronóstico. Para el tiempo final del horizonte se presenta una mayor dispersión en los resultados (siendo un indicativo de la incertidumbre). Estos nueve ensambles únicos constituyen una distribución de probabilidad de los posibles estados futuros de la atmósfera (Owens, R G, Hewson, 2018a).

#### 4.2.1. ECMWF

Uno de los centros que desarrollan pronósticos basados en ensambles desde el año 1992 es el Centro Europeo para la Predicción del Clima de Plazo Medio (ECMWF, Anon 2018). El ECMWF fue fundado en 1975 y es un instituto de investigación con un servicio de operación de 24 horas, el cual produce pronósticos de clima. Dentro de sus actividades de pronóstico, se incluye la producción de ensambles meteorológicos y análisis que describen los posibles escenarios y su probabilidad de ocurrencia a nivel global (Figura 4.3). Los horizontes de pronóstico cubiertos van desde un plazo medio, mensual y temporal, hasta un año adelante (ECMWF, 2018).

Las variables de pronóstico primarias emitidas por el modelo atmosférico del ECMWF son: temperatura, viento y humedad específica; las cuales son convertidas en otros parámetros atmosféricos (ej. precipitación, Persson, 2015) y discretizados en forma espacial (cuadrícula, grid point space) y temporal.

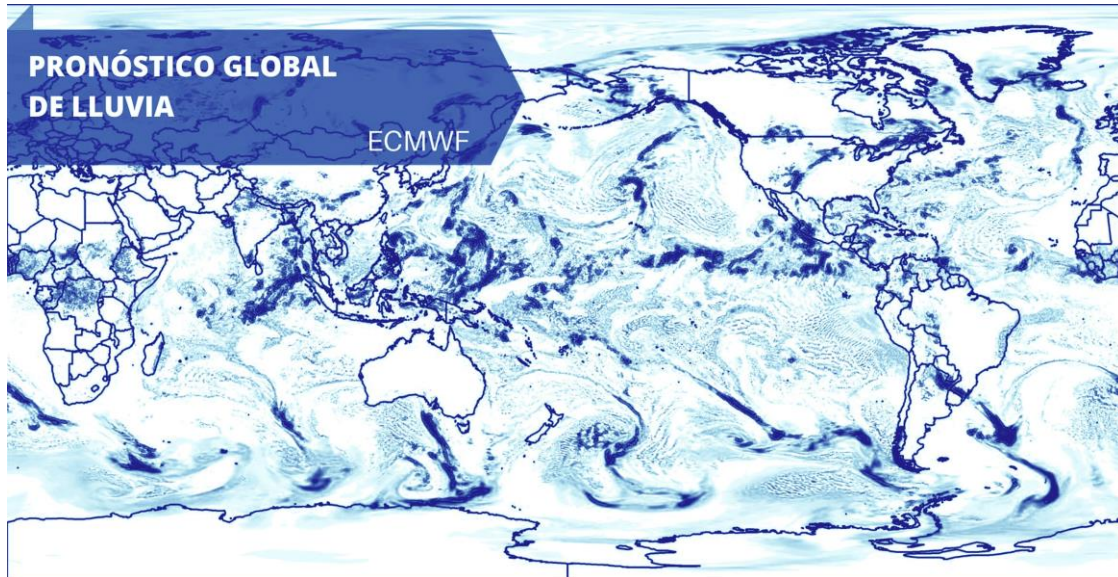


Figura 4.3. Ejemplo de pronóstico emitido por el ECMWF a escala global.

Tasa de Precipitación Total (Precipitación Convectiva + Precipitación estratiforme). ECMWF 09/11/2018 00:00 UTC. Información meteorológica en formato GRIB. Fuente: Imagen elaborada por el autor.

Las perturbaciones iniciales son construidas utilizando la técnica “singular vector” (SV) y las perturbaciones son generadas a partir de ensambles de asimilación de datos (ensemble of data assimilations, EDA; Owens, R G, Hewson, 2018). La técnica “SV” intenta identificar las regiones dinámicamente más inestables de la atmósfera calculando dónde las pequeñas incertidumbres iniciales afectarían un pronóstico de 48 horas más rápidamente (Persson, 2015). Una vez que los diferentes conjuntos de vectores son separados en los hemisferios norte y sur y sobre los trópicos (30°N y 30°S), son combinados de forma lineal y añadidos a “EDA” para producir 25 perturbaciones globales (estos ensambles de asimilación corresponden a conjuntos independientes de datos asimilados; y son generados mediante la perturbación aleatoria de las observaciones, la temperatura superficial del mar, hielo marino y humedad del suelo). Posteriormente, se revierten los



signos de estos 25 vectores para producir otras 25 perturbaciones en espejo; dando un total de 50 campos de perturbación global. Por lo tanto, los miembros consecutivos presentan perturbaciones anti simétricas por pares. Esta anti simetría puede desaparecer después de un día o dos como se ejemplifica en la Figura 4.4.

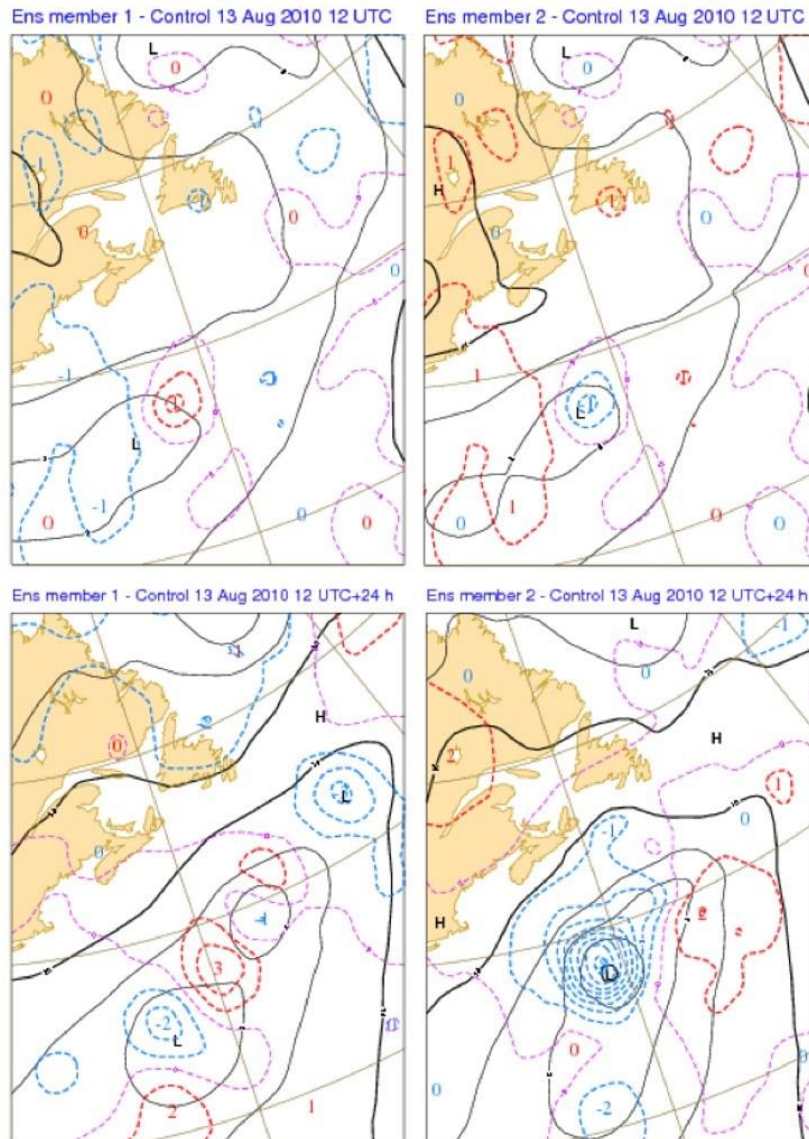


Figura 4.4. Simetría de pronósticos emitidos por el ECMWF.

1000hpa análisis perturbados y pronósticos de los miembros 1 y 2. 12 UTC 13-08-2010. Las perturbaciones positivas y negativas se indican en rojo y azul respectivamente. En el tiempo inicial (mapas superiores) las perturbaciones son un par anti simétrico, mostrando debilidad o aumento de un sistema de baja presión al noroeste del atlántico. 24 horas después (mapas inferiores), el miembro 1 muestra dos sistemas ciclónicos; mientras tanto, el miembro 2 muestra un aumento del sistema de baja presión. Mapas obtenidos de (Owens, R G, Hewson, 2018a).

### 4.2.2. Ventajas y desventajas de los EPS

¿Deberían los pronósticos ser siempre probabilistas en lugar de deterministas? Esta es una pregunta que existe desde el siglo pasado (Krzysztofowicz, 2001) y que aún en tiempos actuales sigue siendo un debate. Por ejemplo, en el año 2005, diversas agencias meteorológicas en los Estados Unidos (U.S.A) se rehusaban a emitir sus pronósticos en términos probabilistas y la principal razón de ello era que desconocían o no estaban familiarizados con la existencia de productos y metodologías para emitir ese tipo de pronósticos (Rayner et al., 2005).

Por lo general, la información dada a los usuarios de los sistemas operacionales de pronóstico de inundaciones es determinista. Es común que los sistemas deterministas estén basados en datos observados para la simulación del proceso lluvia-escurrimiento; y carecen de un horizonte de tiempo adecuado para implementar medidas de protección civil (Ferraris et al., 2002). En cambio, un pronóstico de inundación basado en probabilidades permite considerar la incertidumbre en la toma de decisiones, en lugar de una solución única.

Un pronóstico determinista puede crear la ilusión de certidumbre en la mente de un usuario, lo cual puede llevar fácilmente a una acción no óptima; en contraste, los pronósticos probabilistas; o basados en ensambles, ofrecen los beneficios potenciales descritos en la Figura 4.5.

Por otro lado, las estaciones climatológicas y los radares meteorológicos son las fuentes principales de medición de lluvia; aunque, en el caso de los radares, los horizontes de tiempo en los que se desempeñan mejor están en un rango de hasta 6 horas. Por estas razones, dichas fuentes de información por sí solas, son incapaces de establecer una alerta temprana que impida inundaciones (Moore et al., 2005). A diferencia de estos sistemas, los Modelos de Predicción Numérica del Clima (NWP) son una herramienta esencial para establecer horizontes de pronóstico mayores al tiempo de concentración de las cuencas (Cloke & Pappenberger, 2009).

Un sistema basado en ensambles es más adecuado para la detección de eventos extremos, ubicados en las colas de la distribución de la lluvia. Por ejemplo, en 2007, Collier señaló que los ensambles son una herramienta útil para limitar los errores derivados de las

fuentes de incertidumbre en la predicción de inundaciones súbitas. Además, el uso de los ensambles tiene sus ventajas sobre todo en cuencas no aforadas y en combinación con otros parámetros que describen las relaciones físicas y espaciales dentro de las cuencas.

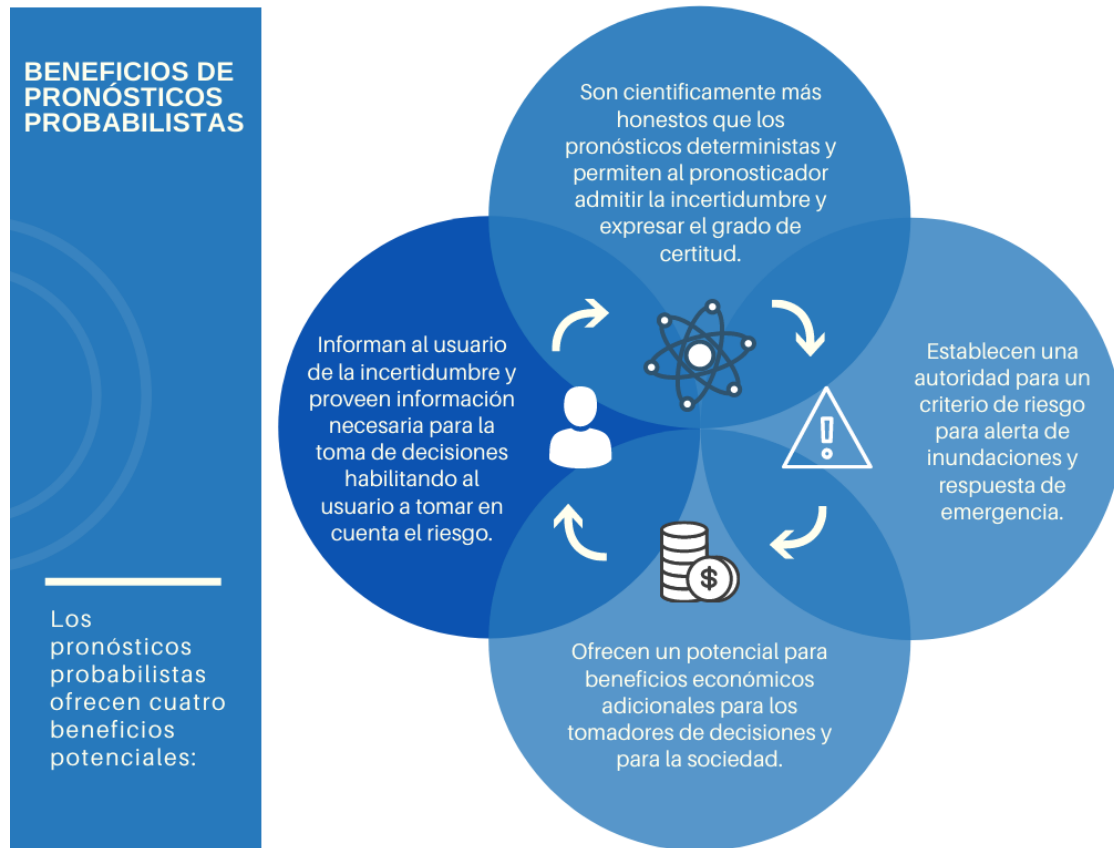


Figura 4.5. Beneficios potenciales de los pronósticos probabilistas.

Un inconveniente de la predicción probabilista es la gran cantidad de escenarios que se deben modelar o simular para obtener un resultado basado en probabilidades. Verbunt et al., (2007) señalaron que utilizar un ensamble de 51 miembros para el pronóstico operacional es una tarea difícil. En este sentido es común que se empleen técnicas como el *clustering*<sup>10</sup> (p.ej. Atger 2001) para reducir el número de escenarios.

<sup>10</sup> El clustering consiste en agrupar ítems en grupos con características similares y se utiliza para determinar patrones climáticos, agrupar artículos por temas o para segmentar clientes, etc.

Por los costos computacionales que implica la cadena de predicción, es recomendable o incluso necesario implementar metodologías para reducir el ensamble al seleccionar miembros representativos. Por ejemplo Atger, (2001) descubrió que existe un pequeño impacto en el desempeño del pronóstico si el número de miembros de los ensambles del ECMWF se reduce de 50 a 21, para predicción de lluvia con horizonte de tiempo de 4 días. Inclusive, Jaun *et al.*, (2008), establecieron que un sistema probabilista de inundaciones puede ser desarrollado usando un pequeño ensamble de 10 miembros. Otro ejemplo es el de Ferraris *et al.* (2002) y Siccardi *et al.* (2005); quienes han colaborado en la implementación de una cadena de pronóstico para la predicción de inundaciones en Italia. Esta cadena está conformada de información meteorológica del ECMWF, reducción de escala de precipitación y un modelo hidrológico; en donde se agruparon los ensambles para la generación de miembros representativos o clústeres. En estos trabajos concluyeron que un pronóstico determinista no es útil en la incorporación de la incertidumbre a lo largo de la cadena de pronóstico; y aunque los ensambles tampoco tienen un desempeño perfecto, sí constituyen una distribución de probabilidad predictiva del evento.

A pesar de la efectividad que brinda la Predicción Numérica del Clima para generar escenarios climáticos, el proceso para el modelado, producción y selección de dichos escenarios a una resolución adecuada, es un proceso muy complejo que requiere tiempo; el cual sumado a los tiempos de modelado hidrológico e hidráulico, puede impactar significativamente en la emisión del pronóstico, y por consiguiente en los tiempos de acción y respuesta ante los eventos extremos; sobre todo en zonas donde las cuencas tienen una respuesta rápida a la precipitación.

### 4.2.3. Calibración

El objetivo de la calibración es mejorar el desempeño del pronóstico crudo, incrementando su confiabilidad. El post-procesamiento de los productos de pronóstico usualmente consiste en una corrección de escalas temporal y espacial; y, en segundo lugar, una corrección aplicada por sub-dispersión o sesgo (Cloke & Pappenberger, 2009). Si bien, este tipo de correcciones se aplican en la mejora de los pronósticos **ex post** (pronóstico de eventos que ya han ocurrido).

Hablando de los pronósticos del ECMWF, la mejora del pronóstico probabilista puede llevarse cabo mediante la combinación adecuada de los productos HRES (High Resolution Forecast) y ENS (Ensemble Forecast). Esta metodología junto con recomendaciones del ECMWF establecen que el pronóstico puede ser mejorado mediante una calibración por ponderación (Richardson et al., 2015). Esta calibración consiste en asignar pesos de participación de probabilidad para los pronósticos determinista y probabilista, de tal modo que mejore su confiabilidad. Las recomendaciones establecen que el pronóstico determinista HRES se desempeña mejor en las primeras horas del pronóstico, mostrando un nivel de participación de hasta el 60% en las primeras 24 horas del horizonte de tiempo. Evidentemente, entre mayor sea el horizonte de tiempo, la participación (peso) de los ensambles será mayor debido a la incertidumbre.

#### **4.2.4. Fuentes de incertidumbre**

Existen tres fuentes de incertidumbre en la predicción de inundaciones basada en ensambles (Krzysztofowicz, 2001): *operacional*, *hidrológica* y *meteorológica*.

Si excluimos la incertidumbre operacional (error humano), la incertidumbre puede ser evaluada con la combinación de la incertidumbre hidrológica y meteorológica (E. Todini et al., 2005). Generalmente, la incertidumbre meteorológica se refiere a la precipitación; la cual puede estimarse con pronósticos meteorológicos; usualmente generados con modelos de Predicción Numérica de clima (NWP). Sin embargo, ningún NWP puede estimar pronósticos perfectos, pues la incertidumbre es inherente a cada resultado de pronóstico (Owens, R G, Hewson, 2018b). Por otro lado, la incertidumbre hidrológica se refiere a las imperfecciones del modelo hidrológico, el valor de los parámetros, y otras entradas que se suponen como determinísticas.

Una de las mayores fuentes de incertidumbre de los modelos NWP es la resolución de los datos (tamaño del pixel). Existen tormentas causantes de inundaciones que se presentan a escalas menores a los 10 km<sup>2</sup>; las cuales no son captadas por los productos de percepción remota (Jain et al., 2018). En consecuencia, los modelos numéricos globales deben mejorar su resolución y complejidad (Bauer et al., 2015).

El pre procesamiento de los ensambles meteorológicos puede ayudar a la mejora de los pronósticos. Por ejemplo, utilizar técnicas como Grand-Ensemble<sup>11</sup> (Pappenberger et al., 2008); para el pronóstico a escala global, es una herramienta que permite alertar de posibles desastres. Los mayores beneficios de este tipo de sistemas se ven reflejados ante la falta de información para la gestión de inundaciones o cuando se requieran medidas de prevención (Cloke & Pappenberger, 2009).

Por último, el uso de EPS para el pronóstico de inundaciones requiere emplear metodologías para analizar su confiabilidad (ver Capítulo 4.3). En este sentido, los métodos de “verificación de pronósticos” (ver Jolliffe and Stephenson, 2013) son herramientas útiles para analizar el desempeño y evaluar su incertidumbre. No obstante, no existen datos suficientes de inundaciones o existe baja frecuencia de las mismas, lo que limita la verificación de este tipo de eventos (Jain et al., 2018).

### 4.3. Verificación de pronósticos

Un aspecto importante de un sistema de predicción del clima es su habilidad para pronosticar de forma precisa los eventos extremos de lluvia (Atger, 2001); los cuales son de sumo interés en el estudio y predicción de “inundaciones de aguas superficiales” (Falconer et al., 2009); por consiguiente, es crítico entender y caracterizar la calidad de los pronósticos (Sharma et al., 2017).

La práctica común para el pronóstico a partir de ensambles se basa en su generación a partir de diferentes variables meteorológicas, diferentes condiciones iniciales, múltiples modelos hidrológicos o múltiples conjuntos de parámetros, o una combinación de lo anterior (Cloke & Pappenberger, 2009); por lo que un buen ensamble de pronósticos debe reunir las siguientes tres cualidades:

1. La distribución de probabilidad debe ser precisa,

---

<sup>11</sup> Método que consiste en la construcción de un ensamble de pronósticos mediante la combinación de productos emitidos por distintos centros meteorológicos o generados a partir de distintas metodologías, con el objetivo de contar con un ensamble de pronóstico compuesto por el mayor número de miembros posible.

2. Los pronósticos deben corresponder bien para eventos de diferentes magnitudes,
3. La probabilidad de los pronósticos debe ser consistente con las frecuencias observadas.

¿Qué medidas de desempeño usar y como evaluar la calidad de un pronóstico? Para resolver esta pregunta se examinan diferentes atributos; tales como la confiabilidad, resolución, discriminación y nitidez de una predicción (Murphy, 1993); y dentro de la comunidad científica atmosférica, a este proceso se le conoce como “*Verificación de pronósticos*”.

La verificación de pronósticos es el proceso de evaluación de la calidad de las predicciones y es una etapa crucial en el pronóstico de inundaciones.

Existe una gran variedad de procedimientos de verificación, y todos estos involucran la relación entre los pronósticos y las observaciones de un evento dado (Wilks, 2006). Un proceso común en la verificación es comparar la magnitud y ubicación de la precipitación y tirantes de inundación mediante la aplicación de numerosas métricas de desempeño (p.ej. Buizza 1996; Buizza et al. 2000; Hamill, Hagedorn, and Whitaker 2008; Jain et al. 2018; Jolliffe and Stephenson 2013); las cuales influyen en la interpretación de la calidad del pronóstico. La verificación se ha utilizado para analizar el desempeño de los ensambles meteorológicos considerando las temporadas de invierno y verano e incluso para estudiar la calidad del pronóstico a través del horizonte de tiempo de un evento. Por ejemplo, Buizza et al., (2000) verificaron el pronóstico de la lluvia acumulada cada 12 horas para Europa en 1997 y encontraron que para umbrales de 5 y 10 milímetros de lluvia, el pronóstico solo es confiable hasta un horizonte de tiempo de 4 días en invierno y hasta 3 días en verano.

En general la mayoría de los estudios de verificación se han realizado en Europa y los Estados Unidos de América (Wu et al., 2020); y dichos trabajos concuerdan en que, un pronóstico probabilista basado en ensambles siempre se desempeña mejor que un pronóstico único para cualquier horizonte de tiempo.

Las razones por las cuales verificar un pronóstico pueden clasificarse en tres: *administrativas, científicas y económicas*

Tabla 4-2. Razones para verificar un pronóstico

<b>Administrativo</b>	Desde el punto de vista administrativo, es necesario contar con un valor numérico que mida qué tan bien se desempeña el pronóstico, de otro modo no hay objetividad en su calidad.
<b>Científico</b>	El punto de vista científico tiene que ver con el entendimiento y; por lo tanto, mejora del sistema de pronóstico.
<b>Económico</b>	El uso económico se relaciona con los usuarios de los pronósticos; en donde los esquemas deben comunicar los resultados a los usuarios de la manera más simple posible. Esto aumenta la complejidad debido a los diferentes intereses del usuario.

También es necesario diferenciar el pronóstico de eventos pasados y de eventos futuros. Para esto, es común utilizar el término *hindcast* (a veces *backcast*) para cualquier predicción que no es una predicción genuina de un evento futuro. Por el contrario, los términos *ex ante* y *ex post* son usados en el valor económico de un pronóstico. *Ex ante* (antes de que el evento ocurra) se refiere a una predicción del futuro, mientras que *ex post* (predicción de un evento pasado) se refiere a predicciones de periodos históricos en donde los datos para verificación están disponibles (Jolliffe & Stephenson, 2013).

De acuerdo con Murphy (1993) existen 3 tipos de bondad de un pronóstico: a) Consistencia; b) Calidad y c) Valor, y que se describen en la Tabla 4-3. Por otro lado, los atributos que determinan la calidad de un pronóstico pueden agruparse en 9 y se describen en la Tabla 4-4.

Tabla 4-3. Tipos de bondad de un pronóstico

<b>Tipo de bondad</b>	<b>Descripción</b>	<b>Métodos de verificación</b>
<b>Consistencia</b>	Grado de correspondencia entre el pronóstico y el juicio del pronosticador. El pronóstico debe proveer la mejor y más apropiada información disponible a los usuarios potenciales y reflejar un grado de incertidumbre (estar expresado en términos probabilísticos).	Brier Score Ranked Probability Score Reliability Curve



Tipo de bondad	Descripción	Métodos de verificación
<b>Calidad</b>	Es el grado de correspondencia entre los pronósticos y las observaciones. La calidad se enfoca en la medición de la precisión, desempeño, confiabilidad y resolución del pronóstico.	Error Medio Absoluto (MAE) Error Medio Cuadrático (MSE) Enfoque orientado a distribuciones  Es medido en valor monetario.
<b>Valor</b>	Grado en que el pronóstico ayuda en la toma de decisiones. Relacionado con el valor económico del pronóstico.	Enfoques: ex post  ex ante (re-calibración del pronóstico)

Tabla 4-4. Atributos escalares de calidad de un pronóstico

Atributo	Descripción
<b>BIAS</b>	Correspondencia entre la media del pronóstico y la media de la observación.
<b>Asociación</b>	Es la fuerza de la relación lineal entre pares individuales de pronósticos y observaciones .
<b>Precisión</b>	Nivel de correspondencia entre pares individuales de pronósticos y observaciones.
<b>Desempeño</b>	Precisión relativa de los pronósticos en relación a un pronóstico de referencia.
<b>Confiabilidad</b>	Correspondencia entre la media condicional de las observaciones y el pronóstico condicional, promediado para todos los pronósticos.
<b>Resolución</b>	Diferencia entre la media condicional de las observaciones y la media no condicionada de las observaciones, promediada para todos los pronósticos.
<b>Nítidez</b>	Habilidad del pronóstico de predecir valores extremos.
<b>Discriminación</b>	Habilidad del pronóstico de discriminar entre observaciones .
<b>Incertidumbre</b>	Variabilidad de las observaciones.

(Murphy, 1993)

Existen distintos métodos para la verificación de pronósticos; y su aplicación depende del tipo de pronóstico realizado, ya sea probabilista o no probabilista; así como las características de la zona de estudio; si es local (puntual) o si se desea verificar un pronóstico de campos atmosféricos (variable en el espacio).

Al utilizar conjuntos grandes de información climática, se pueden presentar datos faltantes. Esto se puede enfrentar simplemente ignorando estos valores en el proceso de verificación, o estimarlos a partir de la información disponible.

En la tabla siguiente se mencionan los métodos de verificación más utilizados y si son aplicables para pronósticos probabilistas o no probabilistas.

Tabla 4-5. Métodos de verificación de pronósticos

Método de verificación	¿Aplicable a pronóstico?	
	No Probabilista	Probabilista
Eyeball	sí	sí
Dicotómico (Matriz de confusión)	sí	sí
Error Medio	sí	no
BIAS	sí	no
Error medio cuadrático	sí	no
Diagrama de confiabilidad	no	sí
Brier Score	no	sí
Brier Skill Score	no	sí
Diagrama de discriminación	no	sí
Relative Operating Characteristic	no	sí
Ranked Probability Score	no	sí

Los métodos presentados en esta tabla se pueden consultar en Brooks et al. (2015) y Jolliffe and Stephenson (2013)

#### 4.3.1. Método categórico o basado en umbrales

Un problema muy común en la verificación de pronósticos es la evaluación de pronósticos probabilistas para eventos dicotómicos (Wilks, 2001).

Un pronóstico puede ser evaluado utilizando un método basado en umbrales; eventos si/no, en donde la decisión se vuelve dicotómica. Para este tipo de eventos, el método más utilizado es el de construcción de tablas de contingencia o matriz de confusión (p.ej. Belitskaya, 2017; R. Buizza et al., 2000; Kuhn & Johnson, 2013) para la aplicación de distintas métricas de error en la identificación de falsas alarmas (FAR), o probabilidad de detección de un evento (POD), las cuales permiten medir la calidad del pronóstico a partir de los atributos descritos en la Tabla 4-4. Este método consiste en la aplicación de distintos índices para la medición de atributos escalares y de desempeño en la caracterización del pronóstico.

Hay dos formas en que un pronóstico sea correcto (ya sea un acierto o un negativo correcto) y dos maneras de que sea incorrecto (ya sea una falsa alarma o un error o evento no observado).

Tabla 4-6. Estructura de tabla de contingencia

(Wilks, 2006)

		OBSERVADO		TOTAL
		SI	NO	
PRONOSTICADO	SI	$a$	$b$	$a + b$
	NO	$c$	$d$	$c + d$
		$a + c$	$b + d$	$n = a + b + c + d$

En donde:

- $a$  es un evento observado y pronosticado (aciertos, TP=True Positive TP).
- $b$  es un evento no observado pero pronosticado (falsa alarma, FP=False Positive)
- $c$  es un evento observado, pero no pronosticado (errores, FN=False Negative)
- $d$  es un evento no observado y no pronosticado (negativo correcto, TN=True Negative)

En la tabla siguiente se resumen las distintas métricas de verificación para pronósticos no probabilistas aplicados en la utilización de tablas de contingencia.

Tabla 4-7. Métricas para método dicotómico de verificación.

	<b>Medida</b>	<b>Descripción</b>	<b>Definición</b>	<b>Atributo escalar</b>	<b>Rango</b>	<b>Valor perfecto</b>
Básicas Descriptivas	BIAS	Sesgo	$bias = \frac{a + b}{a + c}$	Sesgo	0 a $\infty$	
	H	Tasa de aciertos (POD, probability of detection)	$H = a / (a + c)$	Discriminación	0 a 1	1
Medidas de Desempeño	F	Tasa de Falsa Alarma (probabilidad de falsa alarma, POFD)	$F = b / (b + d)$	Discriminación	0 a 1	0
	FAR	Proporción de Falsa Alarma	$FAR = b / (a + b)$	Confiabilidad, Resolución	0 a 1	0
	PC	Porcentaje Correcto	$PC = (a + d) / n$	Precisión	0 a 1	1
	HSS	Heidke Skill Score	$HS = \frac{2(ad - bc)}{(a + c)(c + d) + (a + b)(b + d)}$	Desempeño	-1 a 1	1
	CSI	Critical suces index (Total de amenazas, TS)	$CSI = \frac{a}{a + b + c}$	Precisión	0 a 1	1

La tasa de aciertos (H) o Probability of Detection (POD) proporciona una medida de la capacidad de discriminación de pronósticos e indica la fracción de eventos observados y pronosticados correctamente con un valor perfecto igual a uno. La Tasa de Falsas Alarmas o también llamada Probability of False Detection (POFD), es la relación de falsas alarmas con respecto al número total de no ocurrencias del evento, con un valor perfecto igual a 0. La Proporción de Falsa Alarma o False Alarm Ratio (FAR) da una medida de la confiabilidad y resolución del pronóstico. FAR representa la fracción de pronósticos que resultan ser erróneos. FAR tiene una orientación negativa con mejores valores cercanos a cero. Porcentaje Correcto o Proportion Correct (PC) proporciona una medida de la precisión del pronóstico, cuyo valor perfecto es igual a 1. Heidke Skill Score (HSS) indica la precisión

del pronóstico en relación con la probabilidad aleatoria, con valores perfectos de HSS = 1. El Total de amenazas (Threat Score, TS) o Critical Success Index (CSI) mide la correspondencia entre los eventos predichos y los eventos ocurridos, con valores perfectos más cercanos a 1.

Derivado de la Matriz de confusión o Tabla de Contingencia se puede calcular la probabilidad condicional o condicionada. La probabilidad condicional define la probabilidad de que un evento en particular sea verdad o no en función de ciertas restricciones del evento.

De la tabla de contingencia anterior se pueden derivar 4 probabilidades condicionadas:

- Probabilidad de que un evento observado sea pronosticado:

$$P[\text{Observado}|\text{Pronosticado}] = \frac{\text{eventos observados y pronosticados}}{\text{total de eventos sí pronosticados}} = \frac{a}{a + b}$$

- Probabilidad de que un evento no observado sea pronosticado:

$$P[\text{No observado}|\text{Pronosticado}] = \frac{\text{eventos no observados y pronosticados}}{\text{total de eventos sí pronosticados}} = \frac{b}{a + b}$$

- Probabilidad de que un evento observado no sea pronosticado:

$$P[\text{Observado}|\text{No pronosticado}] = \frac{\text{eventos observados y no pronosticados}}{\text{total de eventos no pronosticados}} = \frac{c}{c + d}$$

- Probabilidad de que un evento no observado no sea pronosticado:

$$P[\text{No observado}|\text{No pronosticado}] = \frac{\text{eventos no observados y no pronosticados}}{\text{total de eventos no pronosticados}} = \frac{d}{c + d}$$

A partir de las probabilidades condicionadas anteriores se puede calcular la tasa de probabilidades (odds ratio, OR). Este es un método muy común de medir la habilidad de predicción de un predictor binario (ver ecuación (4.1), y se estima como el cociente de los casos de éxito sobre los de fracaso en el evento estudiado (Kuhn & Johnson, 2013).

$$P_{aciertos} = P[Observado|Pronosticado]$$

$$P_{errores} = P[Observado| No pronosticado]$$

$$Odds_{observado,pronosticado} = \frac{P_{aciertos}}{1 - P_{aciertos}}$$

$$Odds_{observado,no pronosticado} = \frac{P_{errores}}{1 - P_{errores}}$$

$$OR = \frac{Odds_{observado,pronosticado}}{Odds_{observado,no pronosticado}} \quad (4.1)$$

Si el valor de la tasa de probabilidades  $OR$  es superior a 1, significa que es más probable el éxito que el fracaso. Por otro lado, si el valor de  $OR$  es igual a 1 significa que tanto el éxito como el fracaso son equiprobables con probabilidad igual a 50%.

Cuando existen dos clases (si/no), la *sensibilidad* (*sensitivity*) del modelo se considera como la tasa de aciertos, ya que mide la precisión del pronóstico.

$$Sensibilidad = \frac{aciertos}{aciertos + errores} = \frac{a}{a + c} \quad (4.2)$$

Por el contrario, la tasa de falsos positivos o de falsa alarma se expresa como:

$$\begin{aligned} 1 - Especificidad &= 1 - \frac{negativos correctos}{negativos correctos + falsas alarmas} \\ &= 1 - \frac{d}{d + b} \end{aligned} \quad (4.3)$$

### 4.3.2. Verificación de Ensamblados de Pronóstico

Un ensamble de pronóstico probabilista puede ser considerado bueno si el evento observado se presenta estadísticamente como otro miembro más del ensamble; siendo una buena representación de la incertidumbre; en donde las frecuencias relativas de cada

miembro deberían estimar la probabilidad actual de un evento. Una condición necesaria para la consistencia del ensamble es un grado adecuado de dispersión; entonces, si la distribución del ensamble es apropiada, el valor observado tendrá la misma probabilidad de ocurrencia en cualquier percentil<sup>12</sup> de la distribución representada por el ensamble (Wilks, 2006). Por ejemplo, Verbunt et al. (2007) analizaron la dispersión dada por los ensambles del ECMWF en la cuenca del río Rhine, y encontraron que los ensambles representan una pauta más confiable de pronóstico que el método determinista.

Con respecto a la verificación probabilista de variables discretas como la precipitación, existen métodos que sí toman en cuenta la incertidumbre y brindan medidas escalares de la precisión y desempeño de los pronósticos.

Dentro de la verificación de pronósticos probabilistas existen los pronósticos probabilistas de eventos binarios. Los ejemplos de este tipo incluyen la ocurrencia o no de un evento binario en particular; por ejemplo, la posibilidad de lluvia sobre un área y periodo dado sea mayor a 50 milímetros; y esta se define por la función de distribución acumulativa. Para este tipo de pronósticos, el método más utilizado para evaluar el atributo “confiabilidad” de un pronóstico es el *Diagrama de Confiabilidad* (Reliability Curve, Bröcker and Smith 2007). Un pronóstico es confiable si el evento ocurrió en verdad con una frecuencia relativa observada consistente con el valor del pronóstico (Bröcker & Smith, 2007). El diagrama de confiabilidad se obtiene al graficar la frecuencia relativa del evento contra su probabilidad de ocurrencia; y es un método gráfico (Figura 4.6a) para evaluar la confiabilidad, resolución y precisión de un pronóstico probabilista (Wilson, 2006).

Por otro lado, las curvas ROC (Relative Operating Characteristic) se han utilizado cada vez más en los últimos años para evaluar pronósticos de probabilidad para predicciones binarias (sí/no). ROC es un gráfico de la Tasa de Aciertos (POD) frente a la Proporción de Falsas Alarmas (POFD) utilizando umbrales de probabilidad crecientes (Figura 4.6b); y permite medir la capacidad del pronóstico para discriminar eventos observados y no observados. La forma de la gráfica de la Curva ROC está determinada por la capacidad

---

<sup>12</sup> Medida estadística para comparación de datos. Establece la posición de un valor con respecto a los demás.

intrínseca de discriminación del sistema de pronóstico; y no brinda ninguna información de la confiabilidad (Jolliffe & Stephenson, 2013).

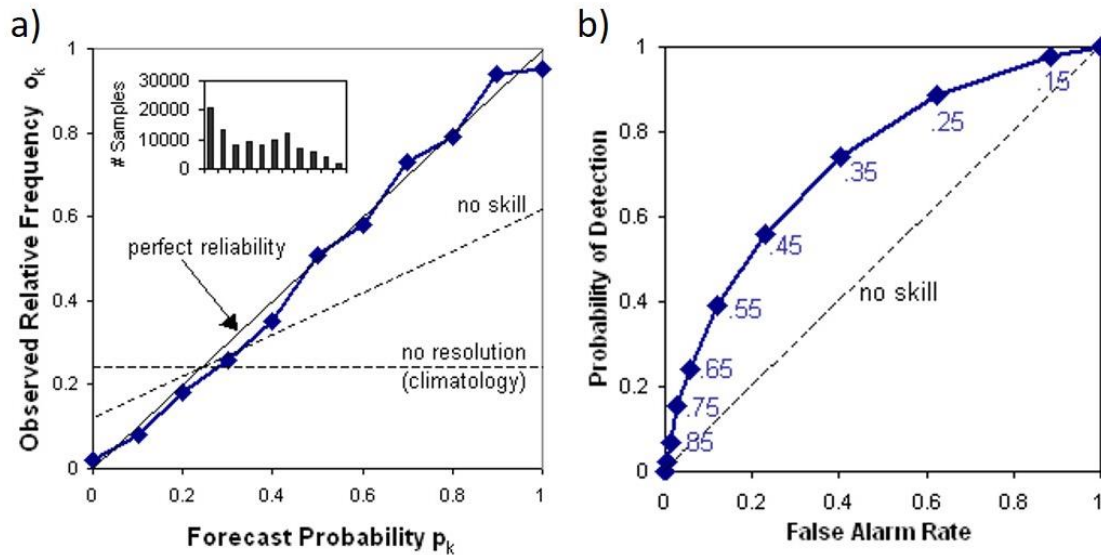


Figura 4.6. Ejemplo de Diagrama de Confiabilidad y curva ROC.

Fuente: Brooks et al., (2015)

Otro método es el de “Brier Score (BS)” o error medio cuadrático de los pronósticos de probabilidad. Por ejemplo, Roulin (2006) evaluó el desempeño de los ensambles de pronóstico del ECMWF en comparación con la probabilidad de flujo extremo en dos cuencas de Bélgica. En este trabajo se compararon 6 años de datos históricos de pronóstico con resultados obtenidos con métodos determinísticos mediante la métrica Brier Skill Score (BSS; Wilson, 2006); en donde la predicción por ensambles presentó un mejor desempeño en comparación con métodos deterministas; y los mayores beneficios al usuario estuvieron en función de la elección de umbrales de probabilidad apropiados para la toma de decisiones. Por ejemplo, Atger, (2001) utilizó los umbrales de 5, 10 y 50 milímetros para verificar pronósticos de lluvia acumulada cada 12 horas en Francia.

Antes de convertir los ensambles en información probabilista puede ser recomendable explorar sus propiedades estadísticas básicas. Por ejemplo; en una primera fase, el pronóstico puede centrarse en la media de los ensambles (Ensemble Mean, EMEAN).



Por otro lado, si el valor observado es estadísticamente indistinguible de los miembros del ensamble, entonces el error medio del ensamble debe igualar la desviación estándar (dispersión del ensamble). Adicionalmente, en un buen ensamble de pronóstico, el error medio debe ser igual o menor al error del pronóstico de control (Jolliffe & Stephenson, 2013).

Un punto relevante de los estudios previos sobre verificación de pronósticos es, utilizar umbrales de probabilidad de excedencia para los sistemas de alerta. Es importante que la definición de dichos umbrales sea establecida con el cuidado necesario con la finalidad de evitar posibles falsas alarmas o eventos no pronosticados, que inevitablemente tendrían repercusiones sociales y económicas (Siccardi et al., 2005).

En la siguiente lista se resumen las consideraciones más importantes o aspectos a tener en cuenta para establecer una pauta de la calidad de los pronósticos probabilistas:

- El pronóstico determinista debe parecer un miembro más del ensamble.
- Los pronósticos deben corresponder bien para eventos de diferentes magnitudes.
- Si la media de los ensambles se desempeña mejor que el pronóstico determinista, es un buen indicativo del Sistema de Pronóstico.
- Los ensambles deben tener un grado adecuado de dispersión de tal modo que se constituya una distribución de probabilidad de la ocurrencia de un evento dado.
- Los eventos observados deben estar dentro de la distribución de probabilidad dada por los ensambles.

### **4.3.3. Verificación de campos atmosféricos**

Por lo general los procesos de verificación aplicados en variables discretas se llevan a cabo para eventos específicos; pero cuando se desea verificar un pronóstico de campos atmosféricos; el proceso de verificación se vuelve más complejo. En un campo atmosférico, tanto las observaciones como los valores de pronóstico están en función del tiempo y el espacio, y existen distintos métodos para la aplicación de métricas e índices de verificación.

Para conocer la calidad y desempeño de un pronóstico en el espacio, se deben aplicar métodos de verificación de campos atmosféricos. La verificación de campos atmosféricos

es sumamente compleja, ya que, en estos casos la evaluación de la calidad del pronóstico opera dentro de una cuadrícula (grid point). El procedimiento más simple es ignorar la diferencia entre las dimensiones espacial y temporal, y solo tratar al conjunto de pronósticos y observaciones como un ensamble combinado en tiempo y espacio. La desventaja de esto es la pérdida de información a nivel espacial (Jolliffe & Stephenson, 2013). Otro método es partir la información en subconjuntos de pronósticos y observaciones a diferentes tiempos para una misma locación o viceversa, lo que brinda información de la variabilidad espacial o temporal del desempeño del pronóstico.

La verificación de campos atmosféricos genera la necesidad de empatar la información del pronóstico con observaciones irregularmente ubicadas en el espacio. Para poder comparar observaciones y pronósticos existen dos formas, ya sea utilizando la información original de las estaciones e interpolando desde la malla regular, o interpolando la información observada sobre la malla regular para comparar con los pronósticos (Jolliffe & Stephenson, 2013).

Un método simple y preliminar de verificación de campos atmosféricos es el de “Eyeball” (Brooks et al., 2015); que consiste en una comparación visual lado a lado de las observaciones y el pronóstico; si embargo, este método no es cuantitativo y está sujeto a interpretación.

Por otro lado, el Error Medio Cuadrático (MSE) es uno de los métodos de promediado espacial más comunes para medir la precisión de pronósticos de campos atmosféricos. Esta métrica opera dentro de una cuadrícula o mediante puntos de los campos de pronóstico y observación a partir del promedio espacial del cuadrado de sus diferencias (Wilks, 2006). Una de las desventajas de este método es la pérdida de información en las escalas espacial y temporal en el desempeño del pronóstico.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2 \quad (4.4)$$

Para una mejor interpretación del MSE, es común expresarlo como su raíz cuadrada RMSE (Root Mean Squared Error); ya que de esta forma se conservan las unidades originales de la variable de pronóstico.

## 4.4. Probabilidad de los Ensamblés

La forma más sencilla de estimar las probabilidades de los ensambles es mediante la Función de Distribución Acumulada (Cumulative Distribution Function, CDF); donde la probabilidad se define como el total de los pronósticos que predijeron a dicho evento, dividido por el número total de pronósticos o miembros del ensamble (Atger, 2001; R. Buizza et al., 2000; Hamill & Colucci, 1998). No obstante, esta metodología difícilmente devuelve probabilidades bien calibradas y por lo tanto no reflejan la verdadera ocurrencia del evento en cuestión.

Algunos trabajos de investigación han ajustado los miembros del ensamble a una distribución gamma de 2 parámetros (p.ej Hamill and Colucci, 1998; Wilson et al., 1999). Wilson et al., (1999) encontraron que el ajuste de la distribución gamma era confiable para un ensamble de hasta 33 miembros. En este sentido, y en años recientes, se han implementado modelos predictivos<sup>13</sup> para la estimación y calibración de las probabilidades de ensambles de pronóstico (p.ej. Gweon and Yu, 2019; Niculescu-Mizil and Caruana, 2005); en donde algoritmos como la “*Regresión Logística*”, han demostrado ser útiles para predecir probabilidades bien calibradas con base en datos históricos (p.ej., Browniee, 2018; Hamill et al., 2008).

### 4.4.1. Modelos Predictivos

La utilización de un enfoque probabilista en donde existe un número  $n$  de variables predictoras<sup>14</sup>; que en el caso de un ensamble meteorológico  $n$  es igual al número de miembros, involucra la aplicación de un modelo predictivo para la estimación de las probabilidades asociadas al evento observado en cuestión.

---

<sup>13</sup> Proceso de creación de una herramienta matemática para generar una predicción.

<sup>14</sup> Variables independientes que sirven como datos de entrada para la construcción del modelo predictivo

Los modelos predictivos consisten en un conjunto de algoritmos estadísticos que al aplicarse a datos históricos devuelven una función matemática para resolver un problema en concreto; que en este caso es predecir un valor en términos de probabilidad con valores entre 0 y 1, con el objetivo de utilizar las probabilidades estimadas para pronosticar la ocurrencia de un evento dado. Estos algoritmos se dividen en algoritmos supervisados y no supervisados.

Los algoritmos supervisados son métodos en donde los datos históricos cuentan con información de los datos de salida o de resultado de la variable que se desea predecir, y ejemplos de algunos de estos algoritmos son la Regresión Logística y los Árboles de decisión. En contraste, los algoritmos no supervisados no necesitan contar con datos históricos para la construcción de un modelo predictivo, como el “*clustering*” y las redes neuronales.

El modelo predictivo construido a partir de los datos históricos, podrá ser capaz de estimar probabilidades de eventos futuros; y para la modelización es muy común dividir a los datos históricos en dos conjuntos: entrenamiento (Training set<sup>15</sup>) y prueba (Test set<sup>16</sup>). El conjunto de entrenamiento son los datos con los que se construye el modelo, en donde se calculan los parámetros y se construyen las ecuaciones del modelo. Mientras que el conjunto de prueba se utiliza para comprobar la eficacia del modelo. Las ecuaciones y parámetros obtenidos en la etapa de entrenamiento se utilizan para calcular los valores de salida aplicados al conjunto de prueba.

La partición de los datos es muy importante en la generación del modelo. Por lo general se utiliza un porcentaje de 80% de los datos para entrenamiento y 20% para prueba; y lo más recomendable es que la partición de la información se lleve a cabo de forma aleatoria. Esto impide que se generen desviaciones o sesgos debido a la procedencia de la información o por la variable de tiempo.

Por último, al estimar las probabilidades de un ensamble se desea que estas reflejen la frecuencia verdadera del evento de interés (Kuhn & Johnson, 2013). En otras palabras, la

---

<sup>15</sup> Conjunto de datos usados para desarrollar el modelo predictivo.

<sup>16</sup> Conjunto de datos para evaluar el desempeño del modelo predictivo.

probabilidad de clase<sup>17</sup> pronosticada debe estar bien calibrada. Una forma para evaluar las probabilidades es mediante una curva de calibración o Diagrama de Confiabilidad.

## 4.5. Modelación de inundaciones

La amenaza de una inundación depende de la extensión, tirante y velocidad del flujo. Dichos factores, combinados con el entorno físico, social y económico, incrementan la susceptibilidad de las comunidades.

En la historia de la humanidad, ha existido una búsqueda constante para entender, evaluar y predecir inundaciones y sus impactos. Para servir a este propósito, se desarrollaron los “modelos de inundación” (Teng et al., 2017). Estos modelos numéricos juegan un rol importante en el pronóstico, sobre todo en relación con las inundaciones. Los modelos disponibles para el pronóstico de inundaciones van desde los modelos lluvia - escurrimiento, 1D y 2D.

Los modelos 1D, son computacionalmente menos costosos que los 2D, pero tienen limitaciones en la simulación de los flujos de inundación y su representación sobre la topografía (Teng et al., 2017); mientras que los modelos 2D, resuelven las ecuaciones de Saint-Venant en 2 dimensiones y pueden usarse para reproducir de forma adecuada la topografía superficial; pero a un costo computacional alto. Los modelos 2D son capaces de resolver procesos hidráulicos producidos por efectos de la topografía compleja, los cuales no pueden resolverse de forma unidimensional (Horritt & Bates, 2001).

Aunque también existen los modelos hidrodinámicos en tercera dimensión, estos son demasiado complejos y requieren una alta capacidad de memoria y tiempo de cálculo, por lo que son innecesarios para la modelación de inundaciones.

Los avances recientes en el modelado hidrodinámico junto con la computación (por ejemplo, computación paralela, código de fuente abierta) han conducido a grandes mejoras en la simulación de inundaciones (Wu et al., 2020).

---

<sup>17</sup> Variable dependiente, objetivo o clase se refiere al evento o cantidad que se predice.

Cuando se modela una inundación pluvial, el parámetro más importante es la información de elevación, ya que una buena representación de la topografía permite reproducir adecuadamente los flujos de inundación.

Con el objetivo de reducir la incertidumbre en la modelación, se ha optado por utilizar la mejor información de elevación disponible (p.ej., LiDAR) y rugosidad del suelo; en combinación con esquemas de cálculo complejos, para reproducir de forma adecuada la llanura de inundación (p.ej., Mejia Estrada et al., 2013; Rodríguez-Rincón et al., 2015).

La última variable de interés en la predicción de inundaciones es la incertidumbre del nivel superficial y extensión de la mancha de inundación (E. Todini et al., 2005). En este sentido, el uso de imágenes satelitales (p. ej Landsat y RapidEye) se ha convertido en una herramienta útil para validar los resultados de pronóstico dados por un modelo hidrodinámico 2D (p.ej., Di Baldassarre et al., 2010b; Rincón, 2016).

#### **4.5.1. Modelos simplificados 2D**

Cuando se desea realizar un pronóstico probabilista de inundaciones, el objetivo no es llegar al resultado real del evento; sino estimar el resultado mediante umbrales de probabilidad para la toma de decisiones; por lo que es recomendable utilizar modelos simplificados que permitan llevar a cabo un mayor número de simulaciones en un menor tiempo (Di Baldassarre, 2012).

Los modelos simplificados y de elemento finito 2D alcanzan resultados muy similares; pero los primeros ofrecen las mayores ventajas en cuanto a la simplicidad del armado del modelo y su calibración; lo que los hace ideales para pronosticar inundaciones. En comparación con modelos que utilizan un esquema de cálculo de elemento finito, los modelos basados en información ráster<sup>18</sup> presentan las ventajas siguientes:

1. El modelo se puede construir con mayor velocidad y simplicidad.

---

<sup>18</sup> En su forma más simple, un ráster consta de una matriz de celdas (o píxeles) organizadas en filas y columnas (o una cuadrícula) en la que cada celda contiene un valor que representa información, como la temperatura. Los rásteres son fotografías aéreas digitales, imágenes de satélite, imágenes digitales o incluso mapas escaneados (ESRI, 2022).

2. Al utilizar información ráster los resultados de la mancha de inundación tienen la misma resolución en todo el dominio de cálculo, lo cual no sucede en los modelos de elemento finito; que por lo general utilizan una malla de cálculo con distintas resoluciones para llevar a cabo los cálculos.

En la modelación hidrodinámica, los tiempos de cálculo dependen de la extensión, resolución del dominio y esquema de cálculo del modelo. Los modelos de inundación 2D basados en la física; resuelven las ecuaciones de aguas someras (Shallow Water Equations<sup>19</sup>, SWEs, Bresch, 2009), lo que requiere recursos computacionales altos. Muchos de estos modelos se han desarrollado con el objetivo de obtener un mejor desempeño, manteniendo la precisión, y reduciendo la complejidad de las ecuaciones. Adicionalmente, muchos de estos modelos se han beneficiado del cómputo en paralelo, a razón del avance en las técnicas y fácil acceso a hardware compatible para este tipo de cómputo. Por ejemplo, el modelo LISFLOOD-FP utiliza la librería OpenMP20 (Neal et al., 2009) para tomar ventaja de los múltiples procesadores (multi-core CPU's).

Aunque el tiempo de cálculo de la simulación está directamente relacionada a la resolución espacial del DEM, la complejidad del modelo también ejerce un gran impacto. Resolver las SWEs; incluso en su forma simplificada, es una tarea computacionalmente intensa debido a la complejidad matemática; por lo que, en años recientes, los estudios se han enfocado en desarrollar modelos 2D simplificados mediante la técnica Autómata Celular (Cellular Automata, CA).

La técnica Autómata Celular (CA) permite modelar procesos físicos complejos usando operaciones simples (Wolfram, 1984), lo que a su vez reduce la carga computacional en comparación con modelos basados en la física. El ejemplo más famoso de vida artificial o de Autómata Celular es el “Juego de la Vida” de Conway (De La Torre & Martín, 1997).

La técnica CA se compone de 5 características: (1) Un conjunto de celdas que representan el dominio de cálculo, (2) cada una de las cuales tiene un estado, (3) una

---

<sup>19</sup> Las ecuaciones de aguas someras, por lo general, modelan el flujo de superficie libre para un fluido bajo la influencia de la gravedad, en el caso en que se supone que la escala vertical es mucho más pequeña que la escala horizontal. Se pueden derivar de las ecuaciones de profundidad promediada incompresible de Navier-Stokes y expresan la conservación de la masa y el momento.

<sup>20</sup> Open multi- processing Application Programming Interface, API

distribución de celdas vecinas, (4) un paso de tiempo y (5) un conjunto de reglas de transición. Estas reglas se componen de operaciones simples que gobiernan la evolución de cada estado de las celdas. Como el cómputo del nuevo estado de una celda solo depende del estado de sus celdas vecinas en el paso de tiempo anterior, el algoritmo se desempeña bien para el cálculo de procesos en paralelo (Michele Guidolin et al., 2016).

#### **4.5.2. Modelos Digitales de Elevaciones**

Los modelos de elevación son información esencial y necesaria para los gestores de inundaciones (Abdullah et al., 2012), en donde la simulación de los procesos hidrológicos depende en gran medida de la información topográfica. Dicha información debe replicar las características y procesos del relieve, con una buena representación de las pendientes y zonas planas de una región (Jarihani et al., 2015).

El pronóstico probabilista de inundaciones en zonas urbanas requiere información con una resolución espacial adecuada; así como un modelo digital de elevaciones (DEM) capaz de representar de la forma más precisa posible los efectos y daños ocasionados por los flujos en calles y avenidas; así como la presencia de edificios.

La precisión de los modelos hidrodinámicos 2D depende directamente de la precisión y resolución de los modelos digitales de elevación (Leitão & de Sousa, 2018); los cuales constituyen al parámetro más importante en la modelación de inundaciones. Se ha demostrado que la información topográfica influye de manera significativa en los resultados de una modelación de inundación (Horritt & Bates, 2001) y que inclusive la resolución y escala utilizados para la modelación tienen un mayor impacto en comparación con otros parámetros y esquemas de cálculo de los modelos 2D. Una resolución espacial más alta representa mejor los campos topográficos (montañas, costas, islas) y los efectos que tienen en el clima local; sin embargo, a un costo computacional altísimo.

Actualmente, existe una variedad de productos de elevación (Tabla 4-8), con diferentes características de resolución y escala (Burgos et al., 2016). Entre estos se pueden mencionar los siguientes: Shuttle Radar Topography Mission (SRTM), ASTER GDEM (Global Digital Elevation Model), JAXA's ALOS 3D World (Japan Aerospace Exploration



Agency's); y por último la información de alta resolución LiDAR (Light Detection and Ranging).

Tabla 4-8. Modelos Digitales de elevaciones y resoluciones.

<b>Producto</b>	<b>Resolución en metros</b>
SRTM	90, 30
ASTER GDEM	30
ALOS	30
LiDAR (México)	1.5, 5

El modelo SRTM (Shuttle Radar Topography Mission) contiene datos de elevación en una escala casi global para generar la base de datos topográfica digital de alta resolución más completa de la Tierra. SRTM consistía en un sistema de radar especialmente modificado que voló a bordo del Transbordador Espacial Endeavour durante una misión de 11 días en febrero del año 2000. SRTM es un proyecto internacional encabezado por la Agencia Nacional de Inteligencia Geoespacial (NGA) y la Administración Nacional de Aeronáutica y del Espacio (POT). Este modelo tiene una resolución de 30 metros y el tipo de pixel es de variable entera (ver Figura 4.7a).

El modelo de superficie digital global ALOS (AW3D30, ver Figura 4.7b) es un conjunto de datos global generado a partir de imágenes recolectadas utilizando el Instrumento Pancromático de Detección Remota para Mapeo Estéreo (PRISM) a bordo del Satélite de Observación Terrestre Avanzado (ALOS) de 2006 a 2011. La Agencia de Exploración Aeroespacial de Japón (JAXA) publica el conjunto de datos del modelo de superficie digital global (DSM) con una resolución horizontal de 30 metros (1 segundo de arco) y tipo de pixel entero (JAXA, 2021).

El modelo SRTM corresponde a elevación de terreno; por lo que las elevaciones correspondientes a edificios, arboles, calles y estructuras urbanas no son visibles; mientras que el modelo AW3D sí es información de elevación superficial. Ambos modelos tienen ventajas y desventajas, por ejemplo, SRTM es un modelo suavizado que tiene mayores aplicaciones para la identificación de escurrimientos; aunque, al realizar simulaciones en

entornos urbanos, es necesario que el modelo sea capaz de representar las calles y avenidas; ya que estas ayudan a transportar los flujos de inundación en las zonas urbanas; a pesar de ello, elementos como árboles, automóviles y otras estructuras generan ruido y pueden producir errores en los resultados de una simulación hidrodinámica.

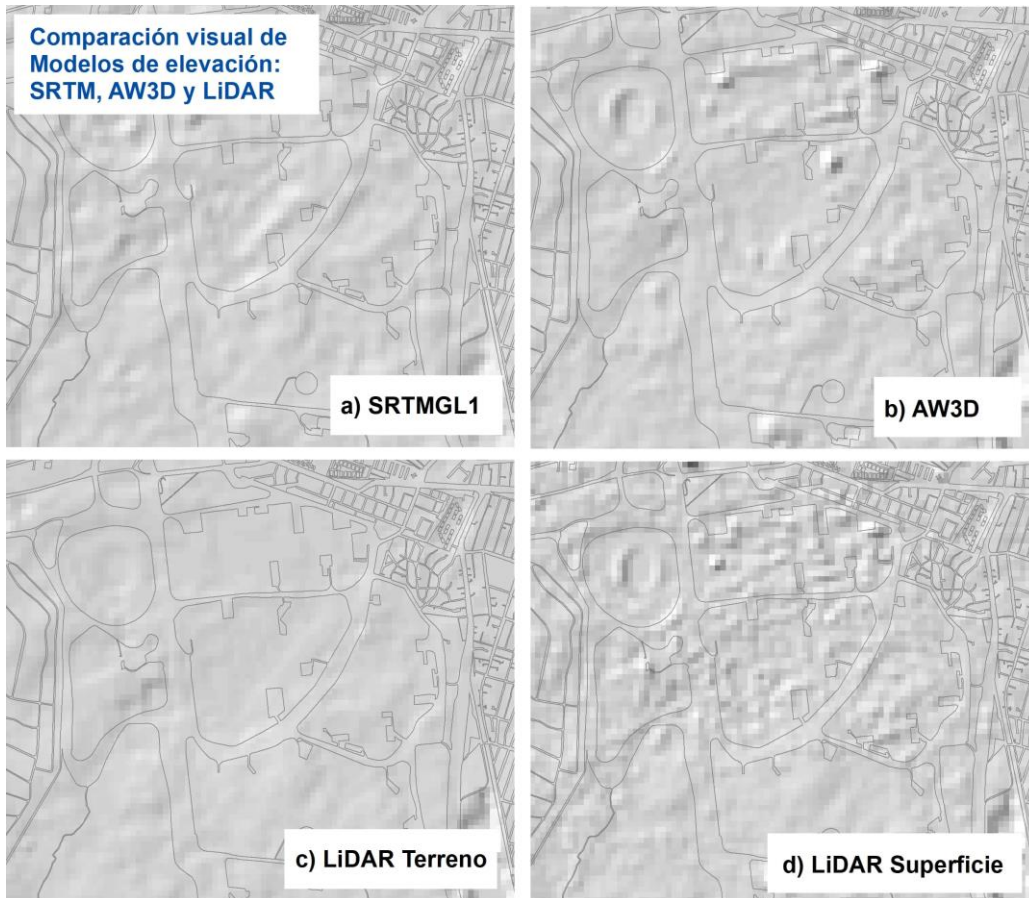


Figura 4.7. Comparación visual de los modelos de elevación: SRTM, AW3D, LiDAR de Terreno y superficie. Resolución de 30 x 30 metros.

Los mapas muestran la información de elevación para la zona de Ciudad Universitaria (UNAM) en la CDMX. La información LiDAR se interpoló a una resolución de 30 metros para ser comparable con los otros productos. Los productos se presentan de forma cruda sin ajustes o correcciones.

Por su parte el LIDAR aerotransportado, es un sensor activo que consta de un telémetro emisor de luz láser y de un espejo que desvía el haz perpendicularmente a la trayectoria del avión. Este desplazamiento lateral combinado con la trayectoria del avión permite realizar un barrido del terreno, en donde el sensor va generando y emitiendo una

serie de pulsos de luz láser, los cuales al pegar con los objetos o el terreno reflejan o devuelven parte de la energía del pulso emitido al sensor. Con esto, la medida de la distancia entre el sensor y el objeto iluminado por el láser es determinada a través del intervalo de tiempo entre la emisión y la reflexión o retorno del pulso.

La información LiDAR de mayor resolución disponible al 2022 para CDMX tiene una resolución de 1.5 metros con pixel de tipo flotante y está disponible en dos modalidades: LiDAR de terreno (Figura 4.7c) y LiDAR de superficie (Figura 4.7d).

El uso de información de elevaciones se ha vuelto primordial para la modelación de inundaciones, aunque, estos datos pueden contener información no relevante, como árboles, puentes e infraestructura; la cual necesita limpiarse para obtener mejores resultados. Por ejemplo, para los modelos de elevación GDEM (Global Digital Elevation Map) y SRTM (Shuttle Radar Topography Mission) se recomienda realizar una corrección por vegetación (Vegetation smoothing filtering); porque, generalmente presentan valores un poco más altos a la superficie real (Jarihani et al., 2015).

Una de las correcciones más comunes por elevación es el rellenado de los huecos o inconsistencias dentro de los modelos (fill dem). Estas inconsistencias, ocasionadas por la presencia de vegetación o estructuras (puentes), pueden interrumpir las redes de flujo, resultando en escenarios falsos en simulaciones hidrodinámicas.

En algunas ocasiones, las redes de flujo no están bien representadas dentro del modelo de elevación; por lo que es necesario realizar un dragado digital del cauce en el DEM. Este proceso, denominado “Stream Burning” ha sido utilizado en el mejoramiento de modelos de elevación en la creación de sistemas de alerta (Adams & Pagano, 2016).

En el año 2015, Jarihani y otros hicieron un estudio sobre el pre procesamiento de modelos digitales de elevación para su uso en modelos de inundación. En este trabajo abarcan conceptos como “sink filling” y “DEM reconditioning”, para el mejoramiento de las redes de flujo. Dentro de otras correcciones a los modelos de elevación, en el trabajo de Jarihani, se incluye una corrección por vegetación (vegetation smoothed DEMs). Este consiste en suavizar las zonas del DEM donde se presenta mayor ruido. Para la corrección por vegetación utilizaron el software llamado ANUDEM. Además de las técnicas

mencionadas anteriormente, existen otras para el reacondicionamiento hidrológico de un modelo digital de elevaciones. Una de las limitaciones es que la mayoría de los métodos antes descritos se aplican a cuencas naturales en la modelación de redes de flujo; las cuales no están siempre presentes en un entorno urbano; sobre todo cuando las inundaciones se dan por efectos pluviales.

### **4.5.3. Mapas probabilistas de inundación**

Entre los diferentes productos emitidos por un sistema de pronóstico, los datos más útiles son las elevaciones de ríos, manchas de inundación y tiempo de pico de las descargas, dados con un horizonte de tiempo suficiente para iniciar las labores apropiadas de respuesta por parte de las autoridades (Jain et al., 2018).

La evaluación del riesgo por inundaciones debe emplear el mejor conocimiento disponible, al considerar la adaptación de las zonas urbanas a su ubicación geográfica, tomando en cuenta las condiciones climáticas y ambientales, y no basarse exclusivamente en criterios socio-económicos (Moore et al., 2005). De acuerdo con esto, los mapas de amenaza desempeñan una función importante en las acciones necesarias para mitigar una inundación (Alfonso et al., 2015); y usualmente también se utilizan para representar el riesgo y vulnerabilidad de las inundaciones. Estos mapas pueden ser resultado de métodos deterministas o probabilistas.

Habitualmente, los mapas deterministas se basan en la optimización de parámetros particulares a un evento; y no toman en cuenta la incertidumbre asociada en el proceso de modelación. Esto conduce a un mal manejo de la amenaza; sobre todo cuando la intención del mapa es la planeación y toma de decisiones (Di Baldassarre et al., 2010a). En oposición, los mapas probabilistas basados en ensambles consisten en la construcción de modelos de inundación y un análisis de sensibilidad que permite considerar la incertidumbre (ver Figura 4.8). Este enfoque probabilista no requiere necesariamente el uso de un modelo hidráulico basado en la física; ya que se considera que el sistema no es una representación exacta del comportamiento del río o llanura de inundación (Di Baldassarre et al., 2010a).

Por otro lado, la baja frecuencia de eventos de inundación complica la tarea de validar los resultados dados por la modelación hidrodinámica. Para contrarrestar esto, la

información de percepción remota se ha vuelto una herramienta esencial e invaluable (Horritt & Bates, 2001), ya que permite tener un marco de referencia para calibración y evaluación del desempeño de un modelo numérico.

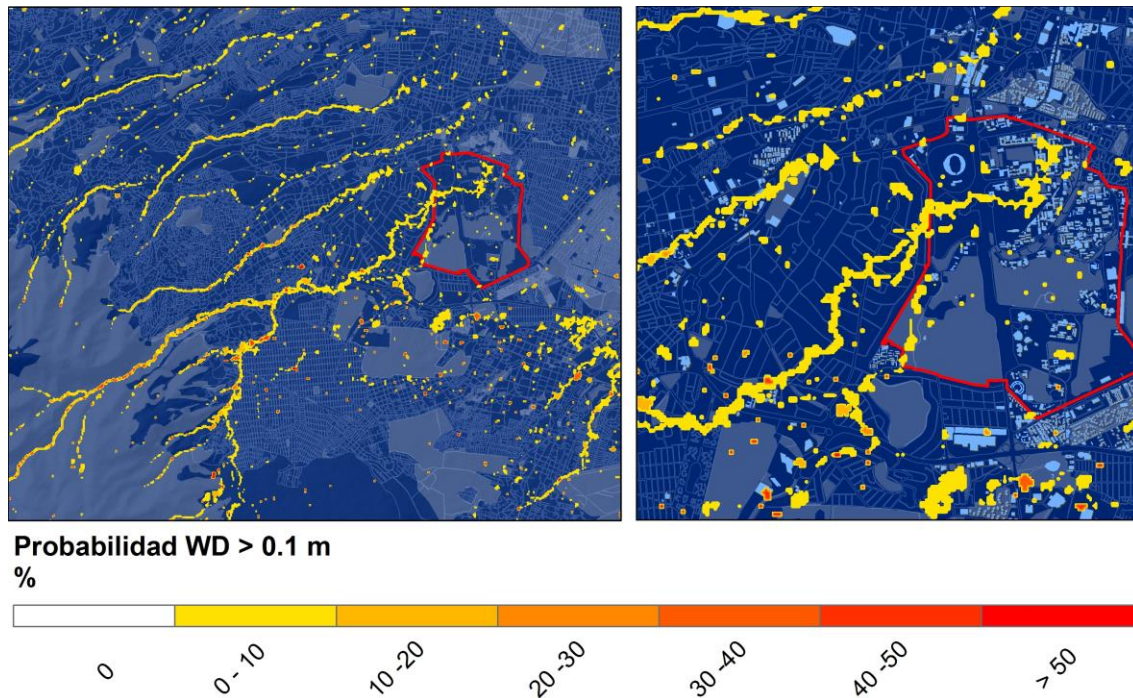


Figura 4.8. Ejemplo de mapa probabilista de inundaciones. Probabilidad de exceder una profundidad mayor a 10 cm. Zona sur CDMX. Evento del 27 de mayo de 2017.

Para esta prueba se simularon los 50 miembros correspondientes al evento y considerando lluvia espacialmente variada en el dominio de cálculo. El mapa muestra una probabilidad baja ( $P < 30\%$ ) de que los escurrimientos tengan un tirante mayor 10 cm. La imagen demuestra que los escurrimientos ocurren principalmente sobre avenidas generando encharcamientos.

Evaluar los resultados obtenidos con el modelo de inundaciones es una tarea desafiante, debido a la falta de registros de inundaciones (Molinari et al., 2019). A menudo, la validación no es posible y en ausencia de un proceso de validación, evaluar la incertidumbre es crucial. Además de las probabilidades, los tomadores de decisiones requieren conocer otros parámetros como el tirante, velocidad y extensión de la mancha de inundación. En este sentido, hay muy poca información disponible o nula, ya que las inundaciones son fenómenos de baja frecuencia y no se recopila información después de un evento de inundación. Sin embargo, se han originado nuevas oportunidades con el uso de

los smartphones y las redes sociales; las cuales pueden ser utilizadas para obtener información de variables que usualmente no son registradas.

Aun así, se recomienda validar los modelos de inundación debido a que son afectados por muchas fuentes de incertidumbre: en particular la topografía y el coeficiente de rugosidad, contribuyen significativamente a la incertidumbre de los resultados del modelo hidrodinámico. A falta de datos, se puede usar el sentido común como un criterio.

Por último, para lidiar con el problema de validación, los estudios recientes promueven el uso de un enfoque probabilista para la modelación de inundaciones, debido a dos razones: 1) No se puede negar la incertidumbre en los procesos hidrológicos/hidráulicos; 2) un enfoque probabilista ofrece una manera de evaluar la incertidumbre y de comunicarla a los tomadores de decisiones (Molinari et al., 2019).

## **4.6. Comunicación del riesgo e incertidumbre del pronóstico**

La comunicación efectiva entre los pronosticadores y el público en general es una variable crítica que puede limitar el impacto de posibles eventos de inundación. Esta comunicación denota un intercambio de información entre individuos, grupos e instituciones; y para que sea efectiva, la población objetivo debe 1) estar expuesta a la información, 2) prestar atención a ella, y 3) entenderla. En otras palabras, la diferencia entre una comunicación efectiva y no efectiva depende de la exposición, atención y comprensión, las cuales son condiciones necesarias para un comportamiento de acción preventiva (Ripberger et al., 2014). Las personas son más propensas a entender los mensajes acerca de eventos climáticos extremos, si estos incluyen información acerca de la naturaleza, locación, guía, tiempo y fuente de la amenaza o riesgo (Sorensen, 2000). Por otra parte, incluir información más compleja; como la probabilidad de ocurrencia de un evento particular, también puede influenciar la posibilidad de que las personas entiendan el riesgo (Morss et al., 2008).

El crecimiento del uso de ensambles de pronóstico ha avivado el interés para la generación de pronósticos del clima, considerando su incertidumbre; sobre todo porque los pronósticos del clima son imperfectos. La comunicación de esta incertidumbre es muy importante porque evita caer en pronósticos falsos y permite a los pronosticadores impartir

su conocimiento acerca de la incertidumbre; y de esta manera, ayudar a tomar una decisión más informada. No obstante, trabajos previos han encontrado que el público en general no sabe cómo interpretar correctamente el término “Probabilidad de Lluvia”. Esto toma sentido cuando los pronosticadores y los medios a veces utilizan distintas definiciones acerca de lo que significa probabilidad de lluvia; y por estas razones, muchas personas se han basado en su experiencia para formar su propia interpretación de lo que significa la “Probabilidad de Lluvia” (Morss et al., 2008). Esto significa que, al comunicar la incertidumbre o el riesgo al público, no importa tanto que entiendan la definición técnica con precisión, sino que puedan interpretar el pronóstico lo suficientemente bien para tomar una decisión que sea benéfica.

Las personas están más dispuestas a recibir información de pronóstico de clima bajo incertidumbre (p.ej. temperatura entre 25° - 30° para mañana) en comparación con un escenario determinista (p. ej. temperatura de 27° para mañana); y en general prefieren que está incertidumbre esté comunicada en términos de porcentaje (aunque no comprendan la interpretación meteorológica). Existe una fuerte evidencia de que la comunicación del riesgo debería incluir siempre una “traducción” numérica para cualquier expresión de probabilidad verbal utilizada, y esa traducción debe aparecer directamente en o al lado de la expresión verbal misma. Por ejemplo, la expresión verbal "es posible que haya tormentas eléctricas severas esta noche" se reformularía de manera más efectiva como "es posible que haya tormentas eléctricas severas (20% de probabilidad) esta noche" (Ripberger et al., 2022). Adicionalmente, las evidencias de trabajos previos sugieren que a las personas les gusta recibir una explicación de la situación meteorológica o la fuente de incertidumbre del pronóstico, como parte de la incertidumbre de los pronósticos meteorológicos (Morss et al., 2008; Ripberger et al., 2022); ya que los resultados dependen del tipo de explicación proporcionada.

En cuanto al pronóstico de inundaciones, el público ha tenido reacciones mezcladas ante el uso de mapas de inundación, si bien la habilidad de revisar si la extensión de la inundación en el área puede afectar sus vecindarios es de mucho valor, la paleta de colores utilizada para representar la variación de los tirantes puede prestarse a confusión. Esto

quiere decir que el color es una variable importante para dar sentido a la información proporcionada a los usuarios de los servicios de pronóstico (Carr et al., 2016).

Para finalizar, es importante mencionar que la motivación de la población para tomar acción depende de saber cuál es el pronóstico para su localidad específica (información geográfica específica), y si se pueden ver afectados.





# Capítulo 5. Metodología

*“Los eventos extremos de lluvia son de baja frecuencia, pero de alto impacto económico y social”.*

**León and Neri, (2010)**

## 5.1. Arquitectura del sistema de pronóstico

La metodología llevada a cabo en este trabajo se planteó con el objetivo de cumplir con la arquitectura de un sistema estándar de pronóstico de inundaciones (ver Figura 5.1) propuesta por Henonin et al., (2013). Dicha arquitectura hace una analogía entre el sistema de pronóstico y los componentes principales de una casa:

**Cimientos:** Un buen sistema de pronóstico depende de los datos de entrada, por lo que la calidad de la información de lluvia es primordial.

**Paredes:** Así como las paredes de una casa, las cuales dan soporte al techo, la recopilación de datos conforma el corazón del sistema. Esta recopilación de datos incluye su procesamiento, así como su distribución a otras partes del sistema, como el modelamiento y creación de herramientas de decisión. También es importante mencionar que el tiempo de descarga y recopilación de datos es muy importante, ya que debe ser adecuado para un pronóstico en tiempo real.

**Puertas y ventanas:** Las herramientas de modelado y toma de decisiones permiten realizar un mejor análisis de eventos pasados y futuros. Estas herramientas añaden un valor extra a los datos crudos y brindan información clave para técnicos y tomadores de decisiones.

**Proceso de emergencia:** Una casa con buenos cimientos; buenas paredes; y puertas y ventanas apropiadas, no puede proteger contra lluvia sin un techo. El proceso de emergencia debe ajustarse al contexto local, de tal manera que la tecnología y alerta de inundaciones se adapte a los usuarios finales.

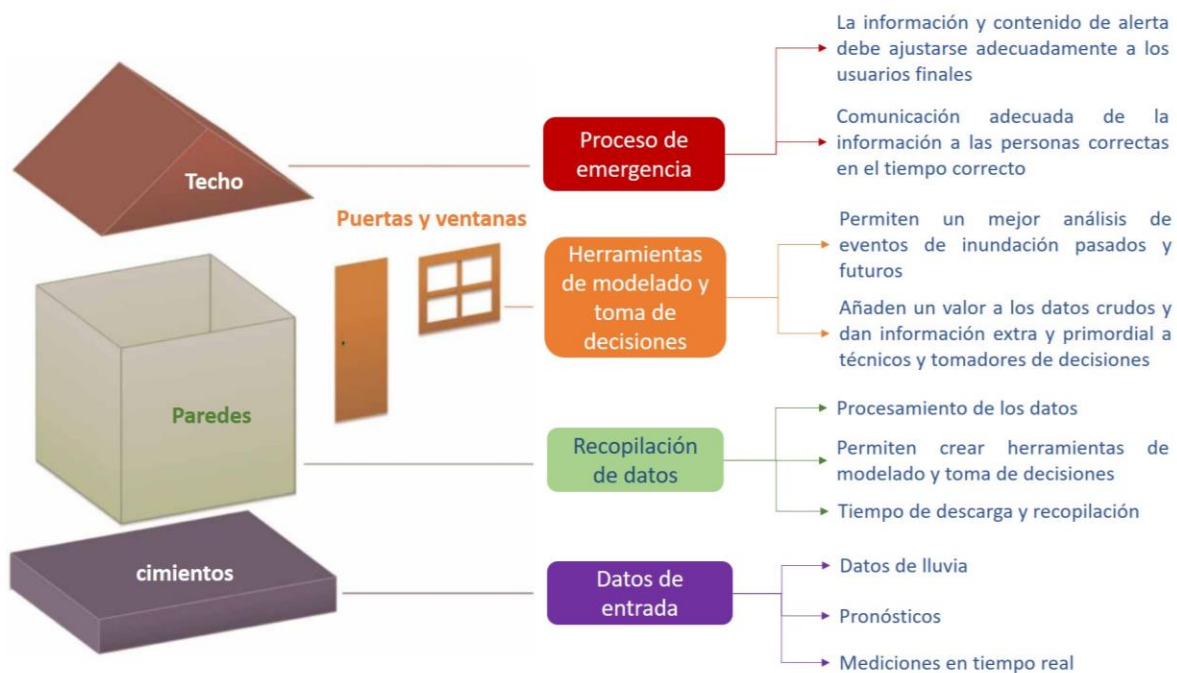


Figura 5.1. Arquitectura de casa para un sistema de pronóstico de Inundaciones.

Fuente: Henonin et al. (2013).

Las inundaciones en ciudad de México son principalmente de origen pluvial, por lo que contar con información de lluvia de calidad y confiable es lo más importante. Por estas razones, para los cimientos del sistema se utilizaron datos emitidos por el Sistema de Predicción por Ensamblados del ECMWF; el cual se describe en los Capítulos 4.2.1 y 5.2.1.

Para las paredes, se recopiló información de lluvia observada y de pronóstico, con el objetivo de investigar el potencial de los Ensamblados como herramienta para la predicción

de inundaciones urbanas. Los datos observados permitieron abordar las siguientes preguntas de investigación: 1) qué tan bien se corresponden los pronósticos con la precipitación observada en el Valle de México; 2) cuál es la precisión y confiabilidad de los pronósticos y 3) si su resolución es suficiente para predecir inundaciones en la ciudad. Para contestar estas preguntas, se realizó una verificación de pronósticos para dos zonas de estudio: (Zona 1) Cuenca del Valle de México (MVB) y (Zona 2) Ciudad de México (CDMX).

- **Zona 1:** Para esta zona, los pronósticos se verificaron contra la lluvia acumulada en 24 h, emitida por el sistema CLICOM ([clicom-mex.cicese.mx](http://clicom-mex.cicese.mx)), durante 2007 - 2014. Las razones de este análisis fueron dos: Primero, estudiar el desempeño del pronóstico a nivel cuenca y adicionalmente, contar con más puntos de referencia (píxeles) para la medición de la precisión de los pronósticos. En segundo lugar, la CDMX se encuentra dentro de esta cuenca, por lo que se puede establecer que los resultados obtenidos también son válidos para la ciudad de México. En adición a lo anterior, este análisis estadístico y espacial permitió conocer el comportamiento de las predicciones en relación a diferentes rangos de lluvia, tanto de baja intensidad como eventos extremos; y en la utilización de datos deterministas y probabilistas de lluvia acumulada en 24 horas.
- **Zona 2:** Para esta zona, los pronósticos se verificaron contra datos observados en tiempo real emitidos por el Observatorio Hidrológico del Instituto de Ingeniería de la UNAM (OH-IIUNAM, <https://oh-iiunam.mx/>), durante la temporada de lluvias (MJJASON, mayo-noviembre) de 2017–2019.

La verificación se realizó en términos de los siguientes atributos escalares: **precisión, confiabilidad, resolución, discriminación y desempeño**. Las probabilidades dadas por los ensambles se estimaron mediante un modelo predictivo para la posterior aplicación de métodos de verificación probabilistas.

Como herramienta de toma de decisiones, se utilizó Machine Learning<sup>21</sup> para la construcción de un modelo predictivo de regresión logística. La construcción del modelo se

---

<sup>21</sup> Machine learning: usar herramientas que toman nuestra información actual, filtran los datos en busca de patrones que sean relevantes para nuestro problema y devuelven respuestas. El proceso de desarrollo de este tipo de herramientas ha evolucionado a lo largo de varios campos, como la química, la informática, la física

alimentó de información histórica pronosticada y observada con el fin de obtener los parámetros de la regresión que permitieran predecir la probabilidad de ocurrencia de un evento mayor a diez milímetros de lluvia acumulada en 24 horas en la CDMX (alerta amarilla, Secretaría de Gestión Integral de Riesgos y Protección Civil, 2021).

Por último, para el proceso de emergencia y comunicación de alerta a usuarios finales y público en general, se contempló la generación de mapas probabilistas de inundación derivados de simulaciones realizadas con un modelo Automata Celular.

Se muestran en mayor detalle las etapas y datos requeridos para esta metodología en el esquema de la Figura 5.2. Más adelante se describen los datos y modelos utilizados para cada una de las etapas de esta investigación.

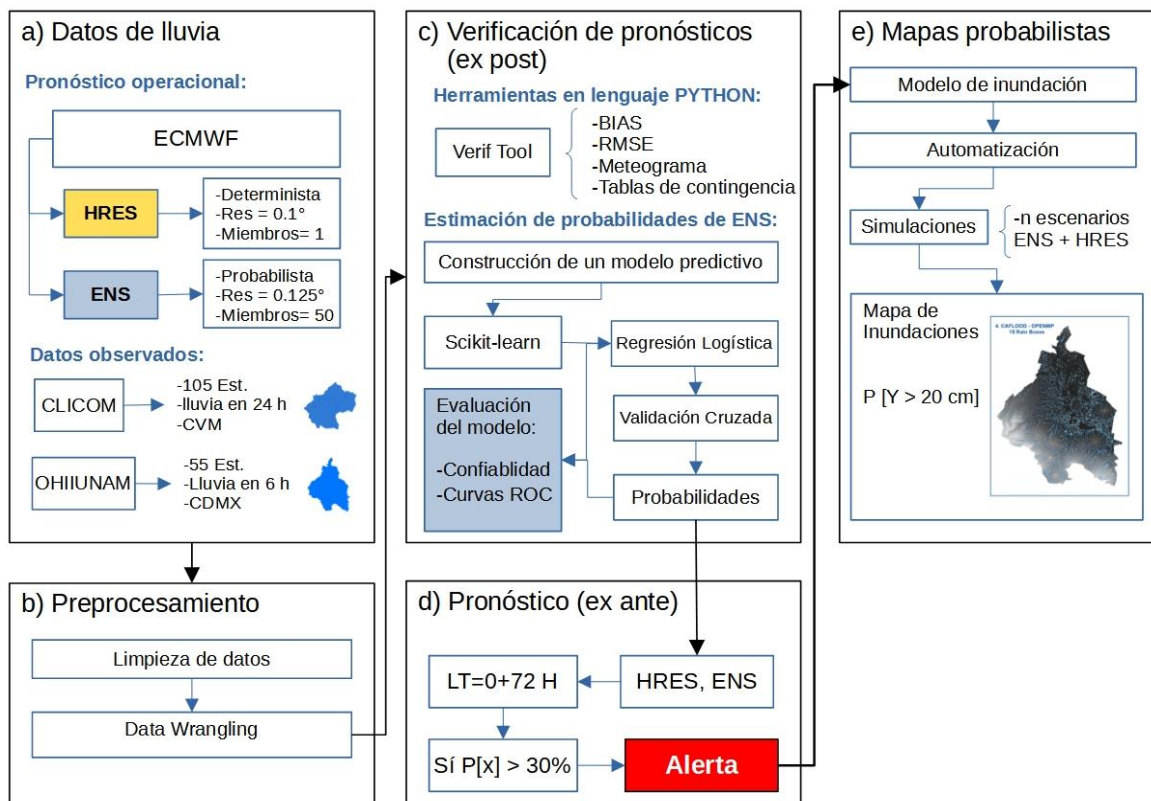


Figura 5.2. Diagrama de flujo de la metodología.

y la estadística, y se ha denominado "aprendizaje automático", "inteligencia artificial", "reconocimiento de patrones", "data mining" y "análisis predictivo".

## 5.2. Datos de Entrada

### 5.2.1. Datos de pronóstico

Se recopiló información operacional del Sistema de Predicción por Ensamblés; emitida por el modelo atmosférico global del Sistema Integrado de Pronóstico (IFS, Integrated Forecasting System) del ECMWF.

El modelo atmosférico del ECMWF (Figura 5.3) es ejecutado a escala global; y es usado para pronósticos de plazo medio, extendido y de temporada. Este modelo corre a varias resoluciones e incluye los pronósticos de alta resolución, ensambles y pronósticos de rango extendido y de temporada (extended-range).

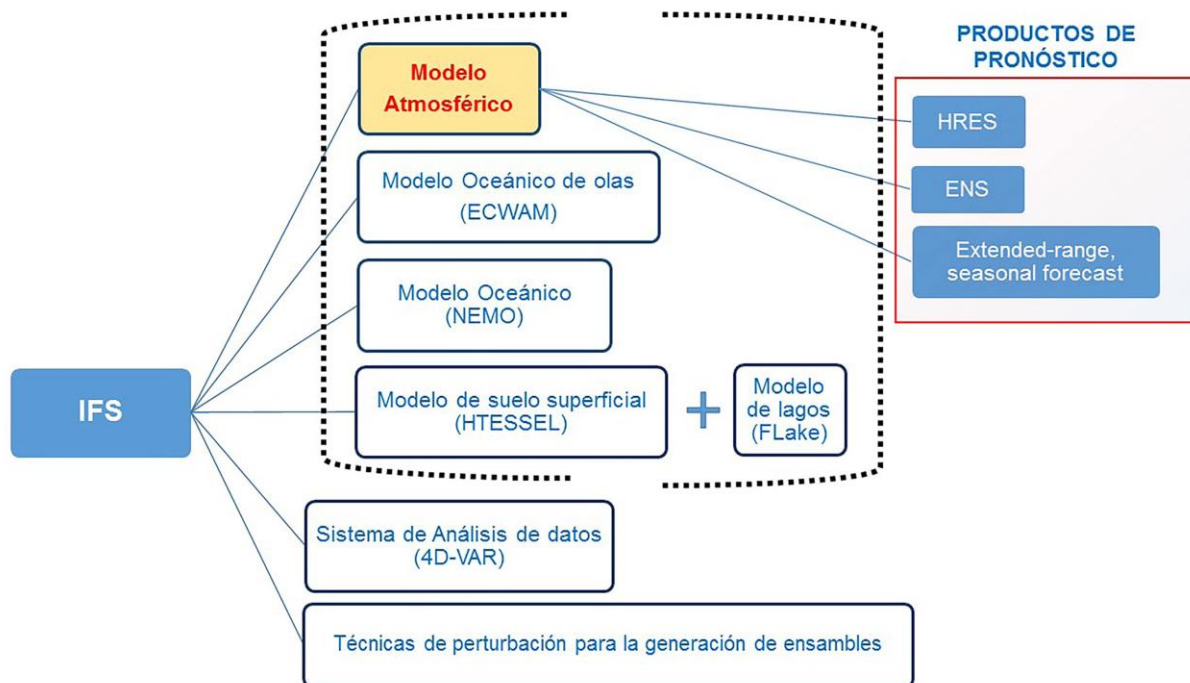


Figura 5.3. Componentes del Sistema Integrado de Pronóstico (IFS) del ECMWF

El modelo atmosférico está acoplado con los modelos ECWAM, NEMO, HTESSEL y FLake; debido a intercambios de energía entre el océano y la atmósfera; así como la orografía y humedad del suelo que juegan un papel importante en la evolución atmosférica.

Los productos utilizados en este trabajo corresponden al pronóstico probabilista o basado en ensambles, **ENS** (Ensemble Forecast) y al pronóstico determinista de alta

resolución, **HRES** (High Resolution Forecast). El parámetro utilizado fue la precipitación total (**tp**<sup>22</sup>, 228.18) a nivel de superficie (**sf**), para las 12:00 UTC<sup>23</sup> (tiempo base) y un horizonte de tiempo de 90 horas ( $t = 0 + 90$  h). La selección del horizonte de tiempo de 90 horas se estableció de acuerdo con las recomendaciones de Emerton et al., (2016), basadas en el tipo de producto de pronóstico, su resolución espacial y temporal, y la extensión del área estudiada.

El producto ENS (Ensamble de pronósticos) provee un estimado de la confiabilidad de un pronóstico único. ENS ofrece productos de alta frecuencia (productos horarios) hasta el paso de tiempo 90 y emitidos cuatro veces al día (Tabla 5-1 y Tabla 5-2). ENS consiste en un pronóstico de control (CF) más 50 miembros (Figura 5.4) con condiciones iniciales perturbadas (Persson, 2015).

En contraste, HRES es una predicción única emitida 4 veces al día, y constituye al modelo con mejor resolución ( $0.1^\circ$ ) del ECMWF. HRES provee una descripción más detallada del clima futuro en comparación con el pronóstico de control (CF, Control Forecast) o con cualquier miembro individual del ensamble; sin embargo, no permite tener un estimado de la incertidumbre ni medición de la confianza; por lo que considerar a esta predicción como un miembro más del ensamble puede ser de gran valor. En comparación con el modelo ENS, HRES tiene una mejor resolución, mejor detalle de la orografía y una mejor discriminación de los procesos costa-océano.

El acceso y descarga de la información del ECMWF se lleva a cabo a través de su sistema **MARS** (Meteorological Archival Retrieval System); que es el sistema de almacenamiento de archivos meteorológicos del ECMWF. Este sistema permite a individuos y organizaciones la obtención de una gran cantidad de datos meteorológicos. Los archivos están almacenados en los formatos estándar de acuerdo con la Organización Meteorológica Mundial (World Meteorological Organization, WMO), llamados **GRIB** (para campos atmosféricos) y **BUFR** (para observaciones meteorológicas). Todos los parámetros están disponibles en un formato de cuadrícula (latitud-longitud).

<sup>22</sup> El parámetro “tp” consiste en la suma de la precipitación convectiva (CP, Convective Precipitation) y la precipitación a gran escala (LSP, Large Scale Precipitation).

<sup>23</sup> El tiempo universal coordinado o UTC es el principal estándar de tiempo por el cual el mundo regula los relojes y el tiempo.

Para leer y procesar la información de los productos HRES y ENS (en formato GRIB) se utilizó una interface de Python llamada **cfrib** (Amici, 2018, <https://github.com/ecmwf/cfrib>), que permite leer los archivos GRIB, utilizando el paquete de Python **xarray** (<https://github.com/pydata/xarray>).

Tabla 5-1. Descripción de productos atmosféricos HRES y ENS del ECMWF

<b>Producto</b>	<b>Número de pronósticos</b>	<b>Resolución</b>	<b>Frecuencia de emisión al día</b>	<b>Tipo de pronóstico</b>
<b>HRES</b>	1	0.1 °	4	No Probabilista
Ensamble	50	0.125°	4	Probabilista
<b>ENS</b>				
Pronóstico de Control (CF)	1	0.1°	4	No Probabilista

Tabla 5-2. Horarios de emisión de productos del modelo atmosférico

(ECMWFc, 2018)

<b>CORRIDAS (TIEMPO BASE)</b>	<b>FRECUENCIA (horas)</b>	<b>ITINERARIO DE EMISIÓN (Europa)</b>
	0 - 90 (cada hora)	5:45 -6:12
00 UTC	93 - 144 (cada 3 horas)	6:12 - 6:27
	150 - 240 (cada 6 horas)	6:27 - 6:55
06 UTC	0 -90 (cada hora)	11:45 - 12:12
	0 - 90 (cada hora)	17:45 - 18:12
12 UTC	93 - 144 (cada 3 horas)	18:12 - 18:27
	150 - 240 (cada 6 horas)	18:27 - 18:55
18 UTC	0 -90 (cada hora)	23:45 - 00:12






Figura 5.4. 50 miembros perturbados del ensamble de pronóstico (ejemplo).

12 UTC del 30 de agosto de 2018 y paso de tiempo  $t = 12h$ . Resolución de 0.125 grados. Total Precipitation. ECMWF. La imagen muestra los 50 diferentes escenarios de pronóstico de lluvia para la Ciudad de México. Fuente: Imagen elaborada por el autor

El archivo GRIB tiene una estructura de hipercubo; el cual contiene múltiples campos agrupados juntos. Estas estructuras permiten agrupar todos los ensambles de un pronóstico para una fecha y un parámetro dados (Figura 5.5).

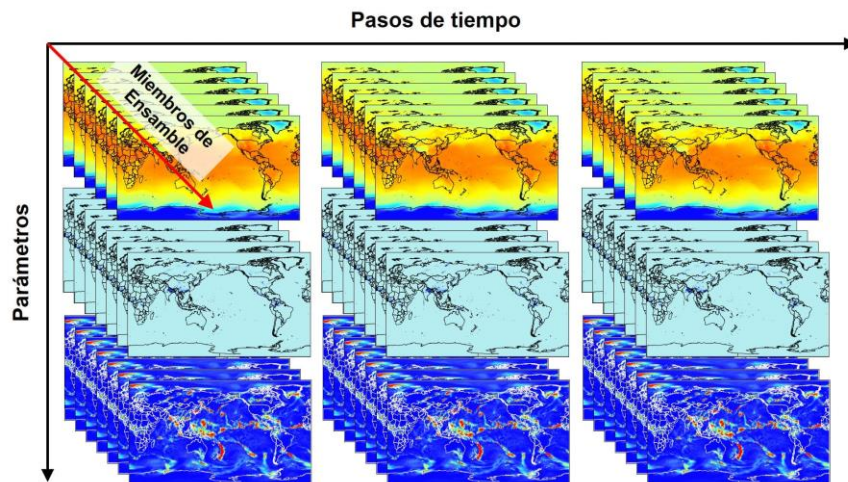


Figura 5.5. Estructura de hipercubo del formato GRIB.

Fuente: imagen elaborada por el autor

El sistema MARS está organizado en una estructura de árbol, en la que los archivos se seleccionan por categoría, para después elegir la fecha del evento que se desea obtener; y, por último, en el caso de pronósticos, la hora UTC del pronóstico deseado (Tabla 5-2).

Actualmente, la API en línea (**ECMWF WEBAPI**) del sistema MARS permite a los usuarios la descarga de hasta 20 peticiones en un día. Para descargar un conjunto mayor de información o en lote (batch) es necesario realizar la petición en lenguaje Python (Simarro, 2020). En el apartado de anexos (capítulo 9.1) se muestra un ejemplo de código en Python para la petición de descarga de información de pronóstico del sistema MARS.

### **5.2.2. Datos observados**

#### **Zona de estudio 1**

Para la Cuenca del Valle de México se seleccionó información de 103 estaciones climatológicas (Figura 5.6) con datos diarios (acumulados de 24 horas), pertenecientes a los estados de México, Tlaxcala, Hidalgo y la CDMX (Distrito Federal). Las estaciones fueron procesadas y seleccionadas con base en el periodo de análisis establecido (2007-2014) y considerando una buena cobertura y distribución espacial dentro de la cuenca (ver Tabla 9-1 en el apartado de ANEXOS).

#### **Zona de estudio 2**

Para verificar los pronósticos dentro del polígono que define a la Ciudad de México, se utilizó información observada en tiempo real emitida por el Observatorio Hidrológico del Instituto de Ingeniería de la UNAM (OH-IIUNAM); para la temporada de lluvias (MJJASON) de 2017-2019.

A mediados del año 2015, el Instituto de Ingeniería puso en marcha el programa del observatorio hidrológico para medir de forma más precisa la precipitación en la ciudad de México. Para el año 2017, el sistema estaba compuesto por 10 estaciones de medición; y en mayo de 2019 el número de estaciones aumentó a 55 (Figura 5.7 y Tabla 9-2).

En la Figura 5.7 se muestra la distribución de las estaciones del OH-IIUNAM, junto con la malla del ECMWF. Las estaciones individuales del OH-IIUNAM trabajan de forma independiente y están compuestas por un disdrómetro para medir la precipitación a escala

temporal de 1 minuto. Este sistema está basado en dispositivos de bajo costo para la adquisición de los datos; para ser transferidos a un servidor central y así estar disponibles a través de una plataforma web (<https://www.oh-iiunam.mx/>).

### ZONA DE ESTUDIO 1 CUADRICULA HRES, ENS y CLICOM

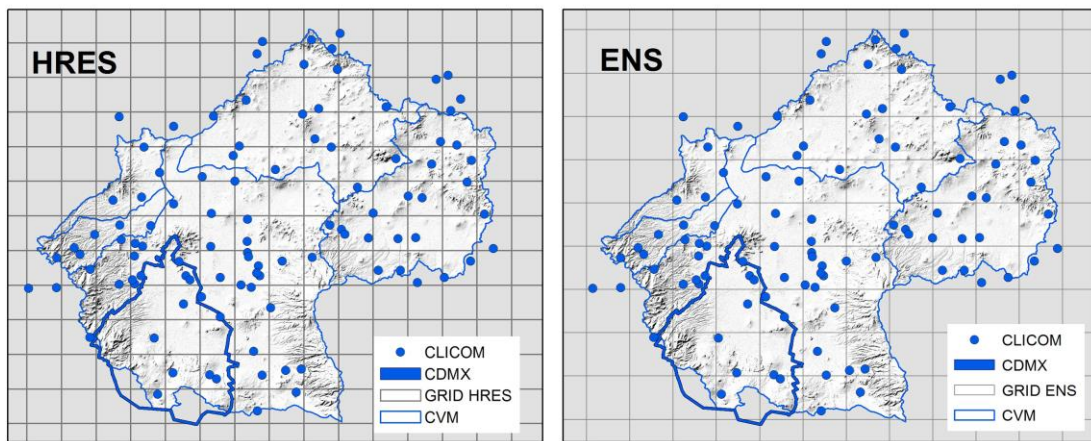


Figura 5.6. Mapa de localización de las estaciones climatológicas en la CVM.

Estaciones utilizadas para verificación histórica de la información de pronóstico. Sistema CLICOM. Izquierda: Zona de estudio con la cuadrícula del producto HRES ( $0.1^\circ$ ). Derecha: Zona de estudio con la cuadrícula del producto ENS ( $0.125^\circ$ ).

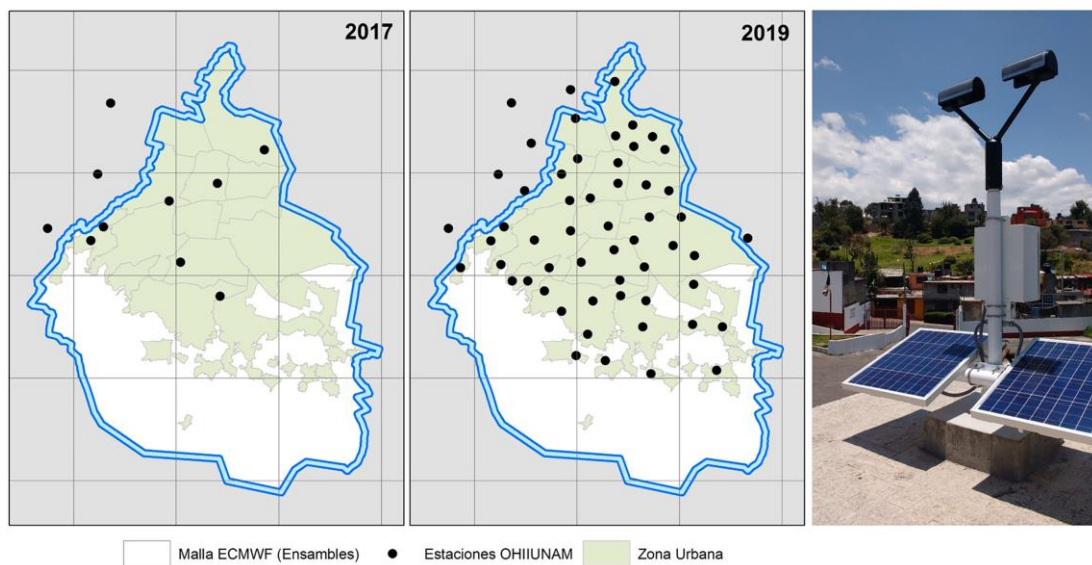


Figura 5.7. Distribución de estaciones de medición para los años 2017 - 2019 del OH-IIUNAM.

Imagen derecha: Disdrómetro de la estación Acopilco.

La tabla siguiente muestra un resumen de los conjuntos de datos de lluvia utilizados en este trabajo:

Tabla 5-3. Resumen de los productos utilizados en este trabajo

Zona de estudio	Datos	Resolución	Número de miembros	Horizonte de tiempo (h)	Paso de tiempo (h)	Periodo de análisis
1	CVM	HRES	1	24	24	2007 - 14
		ENS	50			
		CLICOM	-	-	-	
2	CDMX	HRES	1	0 -90	1, 6	2017-19 (MJJASON)
		CF	1			
		ENS	50			
		OH-IIUNAM	-	-	-	

### 5.3. Marco de trabajo para verificación de pronósticos

La precipitación generada en la ciudad de México es en mayor parte de tipo convectiva; en virtud de lo cual, es importante evaluar el comportamiento del pronóstico tanto en la escala temporal como en la espacial. En consecuencia, antes de utilizar los productos de pronóstico del ECMWF para la predicción probabilista de inundaciones, fue necesario verificar la calidad del producto y su desempeño contra datos observados de precipitación (ver Capítulo 4.3).

Para evaluar la calidad de los productos HRES y ENS se utilizó una variedad de métodos de verificación probabilistas y no probabilistas, en términos de los atributos escalares: **precisión, confiabilidad, resolución, discriminación y desempeño** (ver Murphy, 1993). Para obtener un valor numérico de los atributos anteriores se aplicaron los métodos siguientes: Eyeball, BIAS, Error Medio Cuadrático (RMSE), dispersión, diagrama de confiabilidad, Brier Score y curvas ROC (Característica Operativa del Receptor). La teoría respectiva a cada uno de los métodos anteriores se describe en los subcapítulos siguientes.

La verificación de los pronósticos se realizó de forma **ex post** y **at face value**<sup>24</sup>; y la estimación de las probabilidades se realizó a partir de un modelo predictivo de Regresión Logística.

La información pronosticada y observada se procesó utilizando lenguaje de programación Python. Las métricas de verificación se calcularon utilizando las celdas del producto HRES; así que, para comparar los pronósticos contra los datos observados, tanto el producto ENS y la información puntual de la lluvia observada, fueron interpolados linealmente a una resolución de  $0.1^\circ$  para ser coherentes con la cuadrícula del producto HRES.

Para el cálculo de los métodos de verificación: BIAS, RMSE, meteograma de la lluvia promedio en CDMX y mapa de impacto, se utilizó la herramienta “Verif” en su versión 1.1.0 (Nipen et al., 2019). Esta herramienta permite aplicar la mayoría de las métricas descritas por Brooks et al., (2015) para locaciones puntuales y produce gráficas para los distintos métodos de verificación. Verif trabaja a partir de un archivo de datos con pronósticos y observaciones ordenados de acuerdo a un formato específico (**data-based input**, ver Tabla 5-4). El archivo de datos debe incluir información sobre fechas, horizontes de tiempo y coordenadas geográficas de las estaciones, de modo que se puedan calcular estadísticas para diferentes dimensiones del pronóstico (por ejemplo, ventana de tiempo, pasos de tiempo, fecha y ubicación).

Para cada evento, se calculan las probabilidades acumuladas, las cuales se refieren a la probabilidad de que una variable sea menor o igual a un valor específico. A esto también se le conoce como la función de distribución acumulativa, o por sus siglas en inglés **CDF** (Cumulative Distribution Function). Para calcular la CDF, “Verif” ordena los miembros del ensamble de mayor a menor valor, asignando un valor de 1 y de  $1/m + 1$  a los miembros mayor y menor respectivamente; siendo  $m$  el número de miembros del ensamble.

Por otro lado, para la aplicación de las distintas métricas de verificación y la implementación de un modelo predictivo, es aconsejable analizar previamente los datos de entrada para garantizar que la información no tenga datos faltantes; esté homologada en un

---

<sup>24</sup> Producto de pronóstico sin pre-procesamiento (sin calibración previa).

formato específico y bien estructurado. Para cumplir con lo anterior dicho, se llevó a cabo una limpieza de datos (data cleaning), que consistió en la lectura de los distintos ficheros que contienen la información observada y de pronóstico. Posteriormente se examinó la información de los datos y un resumen de los estadísticos básicos para identificar valores faltantes, así como la generación de variables dummy<sup>25</sup> para la categorización de los eventos. El objetivo fue reestructurar los ficheros y los datos de pronóstico en una tabla o estructura de datos, que en el caso de lenguaje Python se puede representar por un **Data Frame** (ver, Pandas, 2022).

El formato de arreglo recomendado de los datos para el análisis se muestra en la tabla siguiente. Este formato da un orden lógico a los datos y facilita las operaciones de las métricas de verificación.

Tabla 5-4 Formato recomendado por el autor y utilizado por la herramienta "Verif" para el arreglo de los datos (ejemplo)

date	leadtime	id	lat	lon	obs	fcst	$e_0$	$e_1$	$e_2$	...	$e_n$
20170501	6	1	19.5	-99.3	0	0.03	0.02	0.10	0.11	...	0.09
20170501	12	1	19.5	-99.3	0	0.4	0.18	0.71	0.03	...	0.74
20170501	18	1	19.5	-99.3	0	0.04	1.56	0.19	0.01	...	0.003
20170501	24	1	19.5	-99.3	0	0	0	0	0	...	0
20170501	30	1	19.5	-99.3	0	0.06	0.18	0.09	0	...	0.16
20170501	36	1	19.5	-99.3	0.06	0.8	5.6	3.86	0.08	...	0.22
20170501	6	2	19.5	-99.2	0	0	0.01	0	0	...	0.00
20170501	12	2	19.5	-99.2	0	0.13	0.03	0.153	0.57	...	1.87
20170501	18	2	19.5	-99.2	3.89	1.3	0.098	0.27	1.48	...	4.2
20170501	24	2	19.5	-99.2	0	0.004	0	0.12	0.003	...	1.03

<sup>25</sup> Para categorizar un evento los datos se codifican en una variable más sencilla llamada variable dummy que usualmente adopta los valores de cero/uno.

date	leadtime	id	lat	lon	obs	fcst	$e_0$	$e_1$	$e_2$	...	$e_n$
20170501	30	2	19.5	-99.2	0	0.014	0.004	0.001	0	...	0
20170501	36	2	19.5	-99.2	0	0.006	0.238	0.002	0.001	...	0.005

- date: fecha inicial del pronóstico en formato AAAAMMDD
- leadtime: horizonte de tiempo en horas
- location: identificación de la estación (estación de medición o pixel)
- lat: Latitud en coordenadas geográficas
- lon: longitud en coordenadas geográficas
- obs: valor observado
- fcst: Predicción determinista
- e(número) = valor del miembro del ensamble

Para evitar comportamientos incorrectos entre las variables; e interpretaciones erróneas de la información, se eliminaron los valores faltantes o nulos (NaN).

Finalmente, para evaluar los ensambles de pronóstico, fue necesario convertirlos en información probabilista. Para hacer esto, la probabilidad dada por los ensambles se estimó mediante un modelo de regresión logística, implementado con la biblioteca Scikit-learn de Python (Pedregosa et al., 2011, <https://scikit-learn.org>).

### 5.3.1. Modelo de regresión logística

La regresión logística es una variante de la regresión lineal, donde la variable de salida es categórica o clasificada con valores de 0 y 1.

El modelo de regresión lineal se define por la siguiente ecuación:

$$p = \frac{1}{1 + \exp[-(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)]} \quad (5.1)$$

Donde  $p$  es la probabilidad del evento;  $P$  es el número de predictores,  $\beta$  son los parámetros del modelo y  $x$  es la variable predictora. Para una descripción más detallada del modelo de regresión logística, consultar Kuhn and Johnson (2013; p. 282).

Este modelo es lineal en sus parámetros, los cuales son estimados por máxima verosimilitud. Con base en la distribución de probabilidad teórica y los valores observados, la función de verosimilitud es una declaración de la probabilidad que se puede hacer acerca de un conjunto particular de parámetros. Si se identifican dos conjuntos de valores de parámetros, el conjunto con mayor verosimilitud se considerará más consistente con los datos observados.

La función no lineal de la ecuación (5.1) es una función sigmoidea del modelo y limita las estimaciones de probabilidad con valores entre 0 y 1, como se observa en la gráfica siguiente:




Figura 5.8. Función sigmoidea.

Fuente: Swaminathan (2018).

Ahora que tenemos una forma de relacionar nuestro modelo con el parámetro de la distribución binomial<sup>26</sup>, podemos encontrar valores candidatos de los parámetros ( $\beta$ ) y; con nuestros datos observados, calcular un valor de la función de verosimilitud.

<sup>26</sup> Cada ensayo o prueba solo tiene dos resultados posibles: éxito o fracaso.



Una vez que se estimaron los valores de  $\beta$  con mayor verosimilitud, se usaron para predecir los resultados de la muestra.

Para evitar desviaciones o sesgos debido al origen de la información, los datos observados y de pronóstico se dividieron aleatoriamente en dos subconjuntos: 70% de los datos para entrenamiento y 30 % para pruebas.

Es necesario añadir que en el año 2005, Gouweleeuw et al. señalaron que el uso de los ensambles no es un reemplazo de las metodologías deterministas, pero sí agrega más valor si se combinan ambos tipos de pronósticos. Por estas razones, se consideró que la combinación de ENS y HRES tiene un valor agregado para el sistema de pronóstico; por lo que se incluyó al producto HRES como otro miembro del ensamble.

### **Validación cruzada de K iteraciones (k-Fold Cross-Validation)**

Para evaluar los resultados del análisis estadístico y garantizar la independencia de la partición entre el conjunto de entrenamiento y de prueba, se aplicó una técnica de validación cruzada. Esta técnica consistió en repetir el experimento varias veces partiendo los datos y calculando la media aritmética obtenida de las medias de evaluación, sobre las diferentes particiones llevadas a cabo.

El objetivo fue estimar la precisión del modelo predictivo, donde la técnica de validación cruzada permitió que el modelo no presentara un sobre ajuste de los datos del conjunto de entrenamiento y un comportamiento erróneo para el subconjunto de prueba.

Para este trabajo se utilizó la técnica k-fold cross-validation (Figura 5.9) implementada con la librería Scikit-learn de Python (ver scikitlearn, 2022). Para la validación cruzada k-fold, las muestras se dividen de forma aleatoria en  $K$  subconjuntos de aproximadamente el mismo tamaño. El modelo se ajusta usando todas las muestras con excepción del primer subconjunto (Este primer subconjunto se llama el primer pliegue o fold). Se aplica el modelo a la muestra retenida y los resultados se utilizan para estimar el desempeño. Posteriormente el primer subconjunto se regresa al set de entrenamiento y el procedimiento se repite con el segundo subconjunto y así sucesivamente, hasta alcanzar el valor de  $K$  iteraciones (Kuhn & Johnson, 2013, pag. 69).




Figura 5.9. Esquema de la técnica k-fold cross-validation

Fuente: Wikipedia, (2017)

Se utilizó un valor  $K = 10$  iteraciones para la validación del modelo de regresión logística. De cada una de las iteraciones se calculó la eficacia<sup>27</sup> o errores del modelo sobre el conjunto de prueba; y por último, se calculó la media aritmética de los errores cometidos en las  $K$  iteraciones del método.

Una vez estimadas las probabilidades del ensamble con el modelo predictivo, se utilizaron los métodos de verificación descritos en los siguientes subcapítulos para evaluar la calidad del pronóstico.

### 5.3.2. Métodos de verificación probabilistas

#### Dispersión

La dispersión es una medida indirecta de la precisión del pronóstico y viene dada por la desviación estándar del ensamble. Si la distribución del ensamble es adecuada, el valor observado tendrá la misma probabilidad de ocurrencia en cualquier percentil de la distribución (Wilks, 2006, pag. 234).

<sup>27</sup> Eficacia del modelo: El conjunto de “sí pronósticos” de la muestra debe coincidir exactamente con el conjunto de eventos sí observados o “verdaderos”.

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (5.2)$$

Donde  $x_i$  es el valor de lluvia del miembro del ensamble;  $\bar{x}$  es la media de los ensambles; y  $n$  es el número total de miembros del ensamble.

La media de los ensambles está más cerca del posible estado de la atmósfera si su dispersión es pequeña, esto quiere decir que, a mayor dispersión, mayor diferencia entre los miembros del ensamble; y, por ende, mayor incertidumbre.

### Diagrama de confiabilidad

Para evaluar la resolución, precisión y confiabilidad de los pronósticos probabilistas se usó el método de Diagrama de Confiabilidad (Bröcker & Smith, 2007). El diagrama de confiabilidad (Reliability Curve) responde qué tan bien las probabilidades ( $\hat{P} = q$ ) de un evento corresponden a sus frecuencias observadas  $f(q)$ . La curva de confiabilidad está condicionada por los pronósticos; es decir, dada la predicción de un evento, cuál es el resultado observado (Brooks et al., 2015); y se construye graficando los valores de  $f(q)$  contra  $q$  (Jolliffe & Stephenson, 2013).

La posición de la curva con respecto a la diagonal de  $45^\circ$  ayuda a interpretar los resultados (ver Figura 4.6). Si la curva se ubica debajo de la diagonal significa que el modelo o sistema está sobre pronosticando; si la curva se encuentra por encima de la diagonal, significa que el modelo o sistema subestima los eventos. Cuanto mejor calibrado o más confiable sea un pronóstico, más cerca aparecerá la curva a lo largo de la diagonal principal desde la parte inferior izquierda hasta la parte superior derecha de la gráfica.

### Característica Operativa del Receptor-Curvas ROC

Para medir la habilidad del pronóstico en la discriminación de eventos observados y no observados se utilizó el método de las curvas **ROC** (Relative Operating Characteristic). ROC es un gráfico de la tasa de aciertos ( $POD$  o sensibilidad) contra la tasa de falsas alarmas ( $POFD = 1 - especificidad$ ) usando umbrales de probabilidad creciente. Esta métrica

está condicionada por los eventos observados, es decir, dado que un evento ocurrió, cuál fue su pronóstico correspondiente.

Para un pronóstico perfecto, el área bajo la curva ROC será igual a uno; mientras que, para un modelo o sistema ineficaz, resulta en una curva cercana a una diagonal de 45° con un área bajo la curva igual a 0.50 (ver Figura 4.6).

La curva ROC se utilizó para evaluar de forma cuantitativa el desempeño del modelo de pronóstico. En la práctica común se considera que un área bajo la curva mayor a 0.80 es indicativo de un buen sistema de pronóstico; y el límite mínimo para un sistema útil es una área bajo la curva igual o mayor a 0.70 (R. Buizza et al., 2000). En este trabajo, se usó la biblioteca Scikit-learn de Python (Pedregosa et al., 2011, <https://scikit-learn.org>) para implementar este método.

### Brier Score

Para medir la precisión del pronóstico probabilista se usó el método de Brier Score. El índice de Brier brinda información de la magnitud de los errores del pronóstico de probabilidad y se define por la siguiente ecuación:

$$BS = \frac{1}{n} \sum_{j=1}^n (\hat{p}_j - x_j)^2 \quad (5.3)$$

Donde el subíndice “n” es el número de realizaciones (predicción – evento) del proceso de pronóstico sobre el cual se desarrolla la validación. Por cada realización  $j$ ,  $\hat{p}_j$  es la probabilidad de ocurrencia del evento, y  $x_j$  es un valor igual a 1 o 0 dependiendo si el evento ocurrió o no. Sí el pronóstico es perfecto,  $BS = 0$ ; por el contrario,  $BS = 1$  (Jolliffe & Stephenson, 2013).

Se pueden presentar casos en que BS resulte en valores en los rangos de  $0.45 \leq BS \leq 0.6$ , por lo que es difícil identificar si el pronóstico es bueno o no, es por eso que la forma convencional de medir el desempeño de un pronóstico probabilista es mediante la aplicación del Brier Skill Score (BSS), que toma como base de medición al  $BS$ .

$$BSS = \frac{BS - BS_{ref}}{0 - BS_{ref}} = 1 - \frac{BS}{BS_{ref}} \quad (5.4)$$

El sistema de referencia es considerado como el pronóstico climatológico de bajo desempeño en donde  $\hat{p}_j = s$  para toda  $j$ , donde  $s = p(X = 1)$  es la probabilidad de tasa base (climatológica) para la ocurrencia de un evento.

## 5.4. Herramientas de toma de decisiones

Como herramienta de toma de decisiones se utilizó Machine Learning para la construcción de un modelo predictivo de regresión logística. Este modelo se alimenta de información histórica pronosticada y observada con el fin de obtener los parámetros de la regresión que permita predecir la probabilidad de ocurrencia de un evento dado.

En este sentido, este trabajo propone generar escenarios para horizontes de pronóstico de 24, 48 y 72 horas; lo cual permitirá contar con mayor información de un evento de precipitación en la ciudad; y a su vez tener un panorama más completo de las condiciones atmosféricas que se pueden presentar en un horizonte de 3 días.

Debido a la baja frecuencia de eventos extremos y la poca disponibilidad de acceso a datos de pronóstico en la CDMX, se decidió construir el modelo predictivo para un umbral igual o mayor a 10 milímetros de lluvia acumulada en 24 horas para la CDMX. Este umbral marca la emisión de alerta amarilla de acuerdo con la Secretaría de Gestión Integral de Riesgos y Protección Civil, (2021).

### 5.4.1. Construcción del modelo predictivo de regresión logística

El proceso de creación del modelo predictivo involucró dos etapas en las que primero se utilizó la herramienta **statsmodels.api**<sup>28</sup> (statsmodels.org) para explorar y afinar el modelo de regresión logística. Posteriormente, una vez que se exploró y afinó el modelo,

---

<sup>28</sup> Módulo de Python que proporciona clases y funciones para la estimación de muchos modelos estadísticos diferentes, así como para realizar pruebas estadísticas y exploración de datos estadísticos.

se usó la herramienta Scikit-Learn (Pedregosa et al., 2011, <https://scikit-learn.org>) para la creación del modelo final y la predicción en la puesta en producción.

La herramienta statsmodels.api permitió reducir el número de miembros del ensamble mediante el cálculo de los *p valores* para un *umbral de significancia* del 5% ( $\alpha = 0.05$ ). El P valor corresponde al contraste de hipótesis de cada una de las variables; es decir si va a ser o no nulo; o, en otras palabras, es la probabilidad de error de aceptar la hipótesis como cierta y que en realidad sea falsa. Entre más pequeño es el P valor, la significación de la variable es mayor.

La importancia de reducir el número de miembros del ensamble se ve reflejada en la reducción de los tiempos de cálculo en la generación de los mapas de inundación.

Una vez que se analizó la información y se definieron los miembros del ensamble con mayor nivel de significancia, se implementó el modelo de regresión logística con la librería de Python Scikit-learn. La construcción del modelo se alimentó de información histórica pronosticada y observada con el fin de obtener los parámetros de la regresión que permita predecir la probabilidad de ocurrencia de un evento mayor a 10 milímetros de lluvia acumulada en 24 horas en la CDMX (alerta amarilla, Secretaría de Gestión Integral de Riesgos y Protección Civil, 2021).

Con el fin de construir el mejor modelo de pronóstico se analizaron tres casos de combinación de datos para la construcción de 3 modelos predictivos, los cuales se describen en la Tabla 5-5. El primer modelo predictivo se construyó utilizando únicamente la información emitida por el OH-IIUNAM, utilizando como variable la lluvia acumulada en 24 horas para los horizontes de tiempo 24, 28 y 72 horas. El segundo modelo se construyó utilizando la información combinada del OH-IIUNAM y las estaciones de CLICOM con cobertura la Cuenca del Valle de México; y por último, el tercer modelo se construyó con una combinación de datos del OH-IIUNAM y CLICOM, pero solo con cobertura para CDMX.

Al igual que en el proceso de verificación, para este caso se aplicó nuevamente el método de validación cruzada de K-iteraciones para corroborar la eficacia del modelo, y los datos fueron divididos aleatoriamente en dos subconjuntos: 80% de los datos para entrenamiento y 20% para prueba.

Tabla 5-5. Descripción de datos para la construcción de los modelos predictivos como herramienta de toma de decisiones

Modelo	Data based input				
	Dominio	Fuente de información	Paso de tiempo	Cantidad de datos	Periodo (MJJASON)
1	CDMX	OHIUNAM	24,48,72	22470	2017 - 2019
	CDMX	OHIUNAM	24,48,72	22470	2021 - 2019
2			+		
	CVM	CLICOM	24	121552	2007 - 2014
3	CDMX	OHIUNAM	24,48,72	22470	2021 - 2019
	CDMX	CLICOM	24	20544	2007 - 2014

Por último, los 3 modelos predictivos de la tabla anterior se aplicaron a los eventos observados y descritos en la Tabla 2-1, en donde la elección del modelo óptimo se estableció con base en los índices de desempeño establecidos en la Tabla 4-7 y en los métodos de diagrama de confiabilidad y curva ROC.

## 5.5. Proceso de Emergencia

Una vez que se dio inicio a la alerta por pronóstico de lluvia mayor a 10 mm en 24 horas, se continuará con el proceso de emergencia; el cual consiste en la comunicación de las zonas que podrían ser afectadas, mediante un mapa que muestre la extensión de los flujos de inundación, junto con la probabilidad de exceder los 20 cm de profundidad.

Como ya se ha mencionado en los capítulos anteriores, el proceso de emergencia debe ser oportuno, por lo que las simulaciones deben llevarse a cabo en el menor tiempo posible. Por estas razones, para la simulación de los flujos de inundación en calles y avenidas de la CDMX, y la generación de mapas probabilistas de inundación, se utilizó el modelo Autómata Celular **WCA2D** (Weighted Celular Autómata 2D). Este modelo no

resuelve las Ecuaciones de Aguas Someras (SWEs), en su lugar utiliza operaciones simples para reproducir el comportamiento complejo del agua. En consecuencia, el impacto computacional y los tiempos de simulación se reducen en comparación con los modelos de inundación 2D tradicionales.

El modelo WCA2D (Weighted Cellular Automata 2D) es parte del proyecto CADDIES-caflood (Cellular automata dual-drainage Simulation, Michele Guidolin et al., 2016); y consiste en un software de código libre desarrollado por la Universidad de Exeter en Reino Unido. El modelo cuenta con tres implementaciones:

1. Simple: aplicación que no usa cómputo en paralelo y usa variables flotantes de doble precisión.
2. OpenMP: aplicación que utiliza OpenMP para realizar cómputo en paralelo mediante múltiples procesadores. Usa variables flotantes de doble precisión.
3. OpenCL: aplicación que utiliza OpenMP para realizar cómputo en paralelo mediante múltiples procesadores o tarjeta gráfica (GPU). Usa variables flotantes de doble precisión.

El modelo WCA2D ignora los términos de inercia y conservación de momento y fue diseñado para trabajar con retículas rectangulares, hexagonales o triangulares (Figura 5.10). Las principales características del modelo son:

1. La proporción de agua transferida desde la celda central a la celda aguas abajo (volumen intercelular) se calcula usando un sistema ponderado;
2. El volumen de agua transferida entre la celda central y la vecina está limitado por la fórmula de Manning y la ecuación de flujo crítico.
3. Tanto el paso de tiempo adaptativo y la velocidad, son evaluadas dentro de un paso de tiempo actualizado más grande para acelerar la simulación.






Figura 5.10. Ejemplo de las retículas de cálculo del Modelo CA del proyecto CADDIES-caflood.

Fuente: M. Guidolin et al., (2012)

El sistema ponderado para el cálculo del volumen intercelular consiste de 4 pasos:

1. Se identifican las celdas vecinas aguas abajo;
2. Se calcula la ponderación específica de cada celda aguas abajo, con base en el volumen de almacenamiento disponible;
3. Se calcula el volumen total que saldrá de la celda central, y
4. Para cada celda aguas abajo, se fija el volumen intercelular; el cual depende de la ponderación y el volumen total de agua transferida previos.

### 5.5.1. Puesta a punta del modelo Autómata Celular

El modelo WCA2D funciona a partir de la aplicación caflood, basada en un archivo llamado “caflood.exe”; el cual puede ser ejecutado desde una línea de comando. El modelo trabaja con información digital de elevación en formato ASCII y utiliza un valor constante de rugosidad para todo el dominio de cálculo.

Para correr una simulación utilizando el ejecutable compilado, caflood requiere tres argumentos que deben proporcionarse en el siguiente orden:

- a) **Una carpeta de entrada:** Esta carpeta debe contener los datos y parámetros necesarios para llevar a cabo la simulación, por ejemplo, el DEM, los forzamientos del modelo y el archivo de configuración de parámetros.

- b) **Un archivo de configuración de parámetros:** El usuario debe generar un archivo de configuración de Valores Separados por Comas (CSV); que puede tener cualquier nombre, pero debe estar ubicado dentro de la carpeta de entrada. El archivo es una lista de comandos, archivos, instrucciones y parámetros que el modelo necesita para ejecutar la simulación y generar uno o más resultados (ver ejemplo en Capítulo 9.4).
- c) **Una carpeta de salida:** esta es la carpeta donde se guardarán los resultados de salida de modelo.

Entonces, para ejecutar el modelo se requieren tres argumentos obligatorios, y en este caso, se debe incluir el argumento “WCA2D” para especificar que el esquema de cálculo es el modelo autómeta celular ponderado en 2D (Weighted Cellular Automata 2D Model); ya que sin este argumento no se ejecutará la simulación. A continuación, se presenta un ejemplo para correr el modelo desde una línea de comando:

```
> caflowd.exe /WCA2D C:\Path\To\Input setup.csv C:\Path\To\Output
```

Para una descripción más detallada del modelo, consultar la guía de usuario de CADDIES: caflowd application (Michele Guidolin et al., 2015)

### Datos de Elevación

Para la representación de los eventos de inundación en la ciudad de México, se recopiló la información más actualizada de elevación tipo LiDAR y emitida por el Instituto Nacional de Geografía y Estadística (INEGI). De acuerdo al análisis preliminar presentado en el Capítulo 4.5.1 la información de elevación óptima para este tipo de simulaciones corresponde a la de tipo terreno. En la Figura 5.11 se observa el mapa con el dominio de cálculo y la unión de información LiDAR clasificada por clave de Carta Topográfica. El mini mapa presenta la extensión de la información clasificada por año de edición, en donde la información más reciente (año 2020) y con resolución de 1.5 x 1.5 m, corresponde a la zona centro de la CDMX.

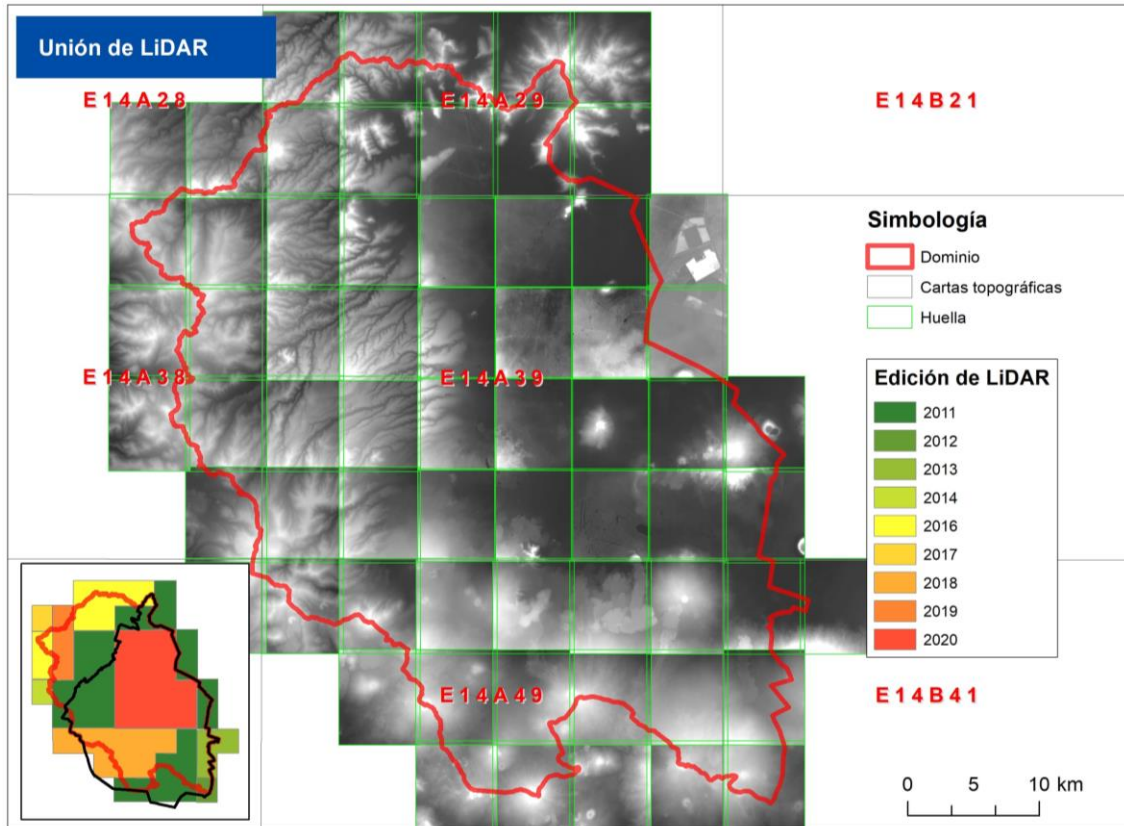


Figura 5.11. Unión de información LiDAR para el dominio de cálculo.

Una vez que se unió la información LiDAR, se interpoló a una resolución de 1.5 x 1.5 metros. Adicionalmente, se fijó la meta de corregir la información de elevación para obtener los mejores resultados posibles, logrando una buena representación de los escurrimientos sobre avenidas y colonias de la ciudad. Para lograr esto se aplicaron las siguientes correcciones:

1. Se aplicó un comando fill sinks para eliminar los sumideros dentro de las corrientes de agua, para evitar estancamientos del flujo.
2. Se realizó un dragado digital a los cuerpos de agua con un desnivel de -0.5 metros.
3. Se aplicó un quemado de los cauces y corrientes de agua (stream burning) con un desnivel de -1.00 metros.

4. Por último; para la representación de edificios dentro del dominio de cálculo, se modificó el valor de aquellos pixeles donde existieran edificios a un desnivel +5.00 metros (Figura 5.12), con base en la información vectorial disponible de Open Street Map (OSM, GEOFABRIK, 2022).

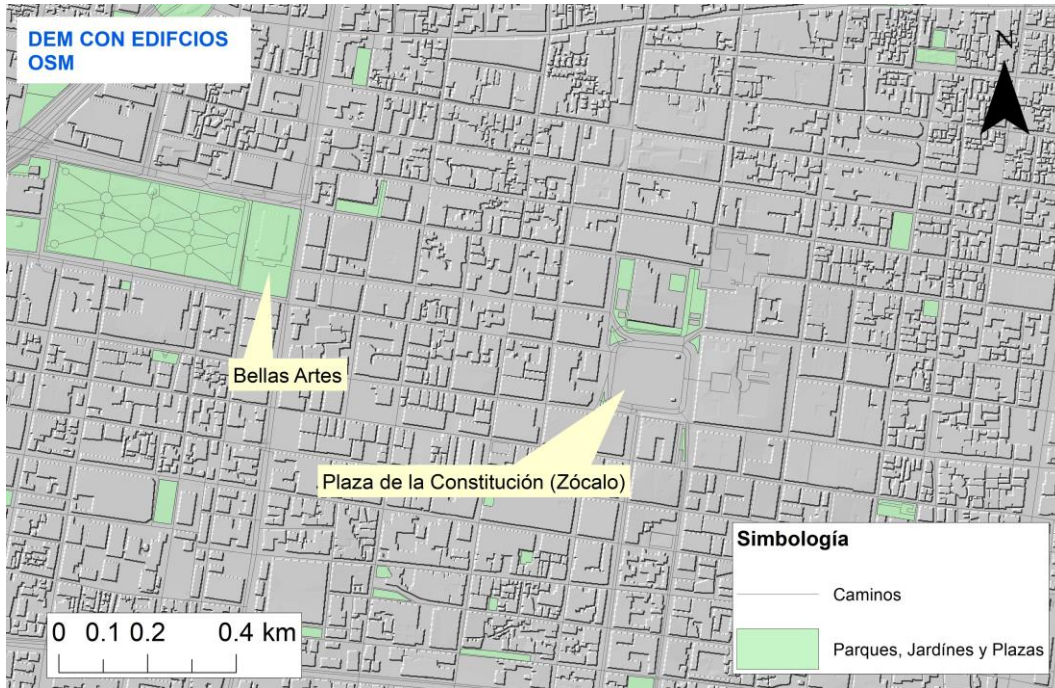


Figura 5.12. Mapa hillshade de DEM corregido. Resolución 1.5 x 1.5 m.

El mapa muestra la corrección llevada a cabo al modelo digital de elevación con la información vectorial de OSM. El mapa muestra un acercamiento al Centro Histórico de la Ciudad de México.

### Forzamientos

Para la distribución espacial de la lluvia, CAFLOOD permite simular distintos eventos dentro del dominio de cálculo mediante cajas de lluvia (Rain Box). Las cajas de lluvia se definen por coordenadas, extensión y hietograma respectivo. En este caso, las cajas de lluvia se definieron usando la misma resolución y coordenadas del producto HRES.

Para definir las cajas de lluvia es necesario construir un archivo separado por comas con el formato mostrado en la Tabla 5-6, cuyos parámetros se describen a continuación:

Tabla 5-6. Formato para la generación de cajas de lluvia. Modelo CADDIES\_caflood (Ejemplo)

Event Name	Rain Intensity for An Hour			
Rain Intensity (mm/hr)	0.0263	0.0778	0.1366	0.1157
Time Stop (seconds)	3600	7200	10800	14400
Zone (tlx tly w h)	473780.1	2161694	10485.01	11040.01

1. **Event name:** Nombre para identificar el evento de lluvia.
2. **Rain Intensity:** Es una lista de valores con la cantidad de lluvia en mm/h para pasos de tiempo específicos.
3. **Time Stop:** Lista de valores en segundos, correspondiente al tiempo de ocurrencia de los valores de intensidad de lluvia.
4. **Zone;** Es el área donde será aplicado el evento. Esta área se identifica con las coordenadas (x, y) de la esquina superior izquierda y el ancho y alto de la caja. Si este parámetro está vacío, el evento se aplica a todo el dominio de cálculo.

En total se definieron 25 cajas de lluvia sobre el dominio de cálculo. En la tabla siguiente se muestran las coordenadas al centroide de los pixeles (cajas de lluvia) y los parámetros para la definición de las cajas mostradas en el mapa de la Figura 5.13.

Tabla 5-7. Coordenadas de pixeles y parámetros para la definición de cajas de lluvia en el dominio de cálculo

Zone	Longitud	Latitud	tlx UTM	tly UTM	w m	h m
1	-99.3	19.6	465086.6	2167012	8616.27	5314.6
2	-99.2	19.6	473780	2166628	10466.13	4921
3	-99.1	19.6	484280	2166419	4381.96	4728.5
4	-99.4	19.5	454880.2	2158334	8375	7677
5	-99.3	19.5	463280.2	2161709	10472.64	11113.33
6	-99.2	19.5	473775	2161705	10472.64	11113.33

Zone	Longitud	Latitud	tlx UTM	tly UTM	w m	h m
7	-99.1	19.5	484265	2161692	10472.64	11113.33
8	-99.4	19.4	457116	2150666	6146.76	11113.33
9	-99.3	19.4	463263	2150658	10479.12	11113.33
10	-99.2	19.4	473759	2150639	10479.12	11113.33
11	-99.1	19.4	484255	2150627	10479.12	11113.33
12	-99	19.4	494772.8	2144749	6710.07	5192.68
13	-99.4	19.3	457862.1	2139580	5388.28	6066.46
14	-99.3	19.3	463240	2139592	10485.56	11113.33
15	-99.2	19.3	473743	2139574	10485.56	11113.33
16	-99.1	19.3	484246	2139562	10485.56	11113.33
17	-99	19.3	494749	2139556	10485.56	11113.33
18	-99.3	19.2	463218	2128527	10491.97	11113.33
19	-99.2	19.2	473727	2128509	10491.97	11113.33
20	-99.1	19.2	484236	2128497	10491.97	11113.33
21	-99	19.2	494765.4	2128473	10509.17	11065.02
22	-98.9	19.2	477595	2117416	995.58	1163
23	-99.2	19.1	477594.8	2117423	6625.54	6507.87
24	-99.1	19.1	484237	2117424	10507.39	6656.21
25	-99	19.1	494751.7	2117415	9985.91	7321.7

### Coefficiente de rugosidad

Por otra parte, la confiabilidad de los resultados del modelo de inundación también depende del coeficiente de rugosidad de Manning (Courty et al., 2017). Para estimar los valores de rugosidad en el dominio de cálculo se utilizó la información del producto global de cobertura del suelo (con resolución de 30m - GLC30) proporcionado por el Centro Nacional de Geomática de China (Chen et al., 2015). Se clasificaron los distintos usos del

suelo y posteriormente se relacionaron con los valores  $n$  de Manning de acuerdo con los publicados por Chow, (2007).

Se observa en la Figura 5.13 que las superficies artificiales tienen mayor predominancia dentro de la zona de estudio; por lo que se utilizó un valor de coeficiente de rugosidad constante de 0.019, para todo el dominio de cálculo.

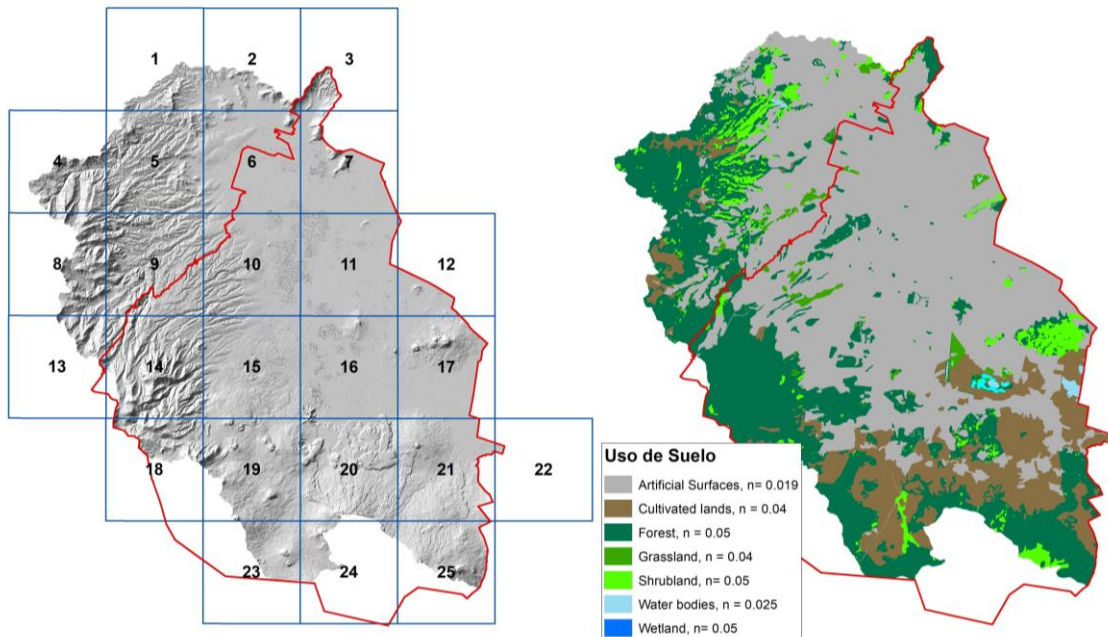


Figura 5.13. Cajas de lluvia (Rain Boxes), uso de suelo y coeficiente de rugosidad en el dominio de cálculo.

### Automatización de las simulaciones

Para finalizar con la puesta a punto del modelo CA, se utilizó un módulo que permite ejecutar programas externos y leer sus resultados en código Python llamado “subprocess” (<https://docs.python.org/es/3.10/library/subprocess.html>). De esta forma, fue posible ejecutar el modelo WCA2D dentro de un script de programación, para automatizar la simulación de los diferentes escenarios; así como la generación de los parámetros necesarios para ejecutar el modelo. Esta automatización consistió en los pasos siguientes:

1. Lectura de los productos de pronóstico; elección de fecha y horizonte de tiempo del evento de interés.
2. Extracción de los valores de los pronósticos HRES y ENS para los píxeles de influencia en el dominio de cálculo.
3. Interpolación de ENS a la resolución del producto HRES
4. Construcción del archivo de parámetros del evento de lluvia de 24 horas, para cada una de las cajas de lluvia y cada miembro del ensamble; y de acuerdo con el formato de la Tabla 5-6.
5. Una vez construidos los archivos de parámetros, se ejecuta el modelo `caflowd.exe`; y al finalizar la modelación, se crea una carpeta de salida específica para guardar el resultado máximo estadístico de los tirantes en formato ASCII.

Para acelerar los tiempos de cálculo se utilizó el comando “Expand Domain” (Michele Guidolin et al., 2015). Cuando este comando no está activado (`false`), el dominio computacional es el dominio completo, es decir, se procesa cada celda del modelo de elevación. Cuando se activa este comando, el dominio computacional se configura para que sea el mismo de los eventos dados y se expandirá cuando el agua alcance el límite del dominio computacional. Este comando es útil para ahorrar tiempo de ejecución cuando una simulación tiene un número limitado de fuentes puntuales de agua, como un evento de entrada de un área pequeña, o en este caso, si solo se desean simular cajas de lluvia específicas dentro del dominio de cálculo.

Con base en la experiencia de pruebas previas, se sabe que los tiempos de cálculo incrementan demasiado si se utiliza una alta resolución en el DEM, que para la extensión del dominio de cálculo corresponde a una resolución menor a los 15 metros. Así que con el objetivo de acelerar todavía aún más los tiempos de cálculo y considerar una alerta temprana se plantearon las siguientes dos condiciones:

1. Si el modelo predictivo pronostica que el evento ocurre durante las primeras 24 horas, se usará la información LiDAR con resolución de 30 m.



2. Si el modelo predictivo pronostica que el evento ocurre para las 48 o 72 horas, el modelo de elevación utilizado será LiDAR con resolución de 15 metros.

Finalmente, para poner a prueba los resultados del modelo, la generación de mapas probabilistas se aplicó a 3 de los casos de estudio descritos en la Tabla 2-1.

### 5.5.2. Generación de mapas probabilistas de inundación

Para la construcción de los mapas probabilistas, los resultados de las  $n$  simulaciones correspondientes al número de miembros del ensamble, fueron considerados como equiprobables; ya que no existen observaciones de la extensión de las manchas de inundación en CDMX.

La probabilidad de los eventos se calculó de acuerdo con la siguiente ecuación:

$$C_j = \frac{\sum_i w_{ij}}{n} \quad (5.5)$$

En donde  $C_j$  es el promedio probabilista del número de escenarios  $n$ ;  $w_{ij} = 1$  si la celda está húmeda y  $w_{ij} = 0$  si está seca.

#### Plataformas para generación de mapas web

Con el objetivo de poder visualizar inundaciones en la ciudad con un mejor detalle y un mejor manejo de la información, en este trabajo se propone el uso de herramientas para la generación de mapas web interactivos con actualización en tiempo real, como visualización tridimensional de calles y edificios de la ciudad de México.

Para la publicación de un mapa web con los resultados del pronóstico probabilista de inundaciones se utilizó el sistema **Mapbox** (Mapbox, 2018).

Mapbox es una plataforma de datos de localización para aplicaciones web y móviles. Esta plataforma provee información vectorial de edificios y características como mapas, búsqueda y navegación. Adicionalmente, permite distintas posibilidades para visualizar y

publicar información geográfica en un navegador de internet; y una de las grandes ventajas que ofrece este sistema es la presentación de mapas en tiempo real.

Mapbox permite la utilización de distintas bases de datos de información geográfica (como Open Street Map) para la generación de mapas web de alta calidad. Adicionalmente, la plataforma ayuda en la construcción de mapas más dinámicos, con el fin de generar aplicaciones útiles para los usuarios. Esta plataforma cuenta con la herramienta “Mapbox Studio” (Figura 5.14), que es una aplicación para el manejo de información espacial, personalización y diseño de mapas.

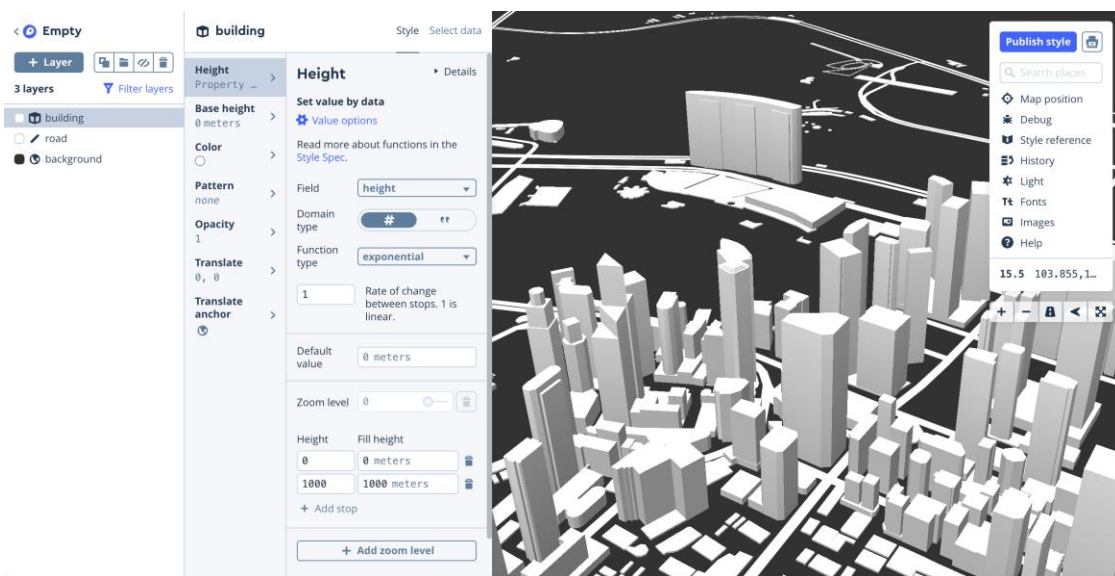


Figura 5.14. Display de Mapbox Studio.

Fuente: <https://www.app-scope.com/share/mapbox-studio-to-show-3d-buildings.html>

Con ayuda de esta herramienta se llevaron a cabo diferentes pruebas de visualización; entre ellas una vista 3D que muestra calles y edificios de la ciudad para una mejor representación de la información.

Una vez que se ha establecido la metodología y descrito todas las herramientas utilizadas, así como las bases de datos y productos de pronóstico; en el siguiente capítulo se presentan y analizan los resultados obtenidos del proceso de verificación de pronósticos, así como los mapas resultado de las simulaciones de los flujos de inundación en la Ciudad de México.



## Capítulo 6. Análisis y discusión de resultados

*“Un pronóstico preciso brinda información primordial a diferentes niveles sociales y económicos; permite salvar vidas, administrar y mitigar eventos de emergencia, y prever pérdidas económicas”.*

**Bauer et al., (2015)**

En el primer caso de estudio se verifican los productos de pronóstico del ECMWF a nivel cuenca. Este análisis permitió cuantificar el desempeño de los pronósticos en un periodo de 8 años (2007 – 2014).

En segundo lugar, se aplicaron las métricas de verificación para la predicción probabilista de lluvia en la ciudad de México. En este caso, los ensambles se verificaron considerando un periodo de 3 años (2016 - 2019); en donde se analizó la precisión, confiabilidad, resolución y discriminación de los pronósticos.

### **6.1. Verificación de pronósticos en zona 1: Cuenca del Valle de México**

La primera pregunta de este estudio buscó determinar la correspondencia entre pronósticos y observaciones en la Cuenca del Valle de México (CVM).

A continuación, se presentan los resultados de la verificación de pronósticos en la cuenca del Valle de México; donde se evaluó la correspondencia entre pronósticos y observaciones de la lluvia acumulada en 24 horas; así como las diferencias entre los productos ENS y HRES en relación a diferentes rangos de lluvia, tanto de baja intensidad como eventos extremos.

### **6.1.1. Exploración preliminar de los pronósticos**

Antes de convertir los pronósticos a información probabilística, se analizaron sus propiedades estadísticas básicas. En una primera fase, la verificación se centró en HRES y la media de los ensambles o “Ensemble Mean” (EMEAN). Las métricas de verificación aplicadas en este caso fueron: Eyeball, Bias; RMSE y método basado en umbrales (Tablas de Contingencia).

#### **Verificación Eyeball**

En este apartado se utilizó el método de verificación visual “Eyeball” en donde se compararon los pronósticos y observaciones lado a lado para juzgar los errores del pronóstico (Brooks et al., 2015). Para la construcción de los mapas se calculó la precipitación promedio de 24 horas por mes para el periodo 2007 – 2014; y se comparó contra la misma variable obtenida con la media de los ensambles “EMEAN”. Esto permitió establecer un juicio del comportamiento del pronóstico determinista dado por EMEAN con respecto a la precipitación observada en la cuenca en un periodo de 8 años.

La limitación del método Eyeball es la pérdida de información temporal, por lo que para contrarrestar esto, la Figura 6.1 muestra una comparación visual entre CLICOM, HRES y EMEAN para la precipitación acumulada de 24 horas promedio al mes en CVM. Los mapas muestran una similitud en la magnitud de la lluvia mes con mes; lo que corrobora una buena consistencia del pronóstico, principalmente porque se identifican adecuadamente los meses de mayor precipitación (MJJASON). No obstante, la media de los ensambles “EMEAN” tiende a sobre pronosticar la lluvia; sobre todo los eventos pequeños ubicados en el rango de 0 a 3 milímetros en 24 horas.

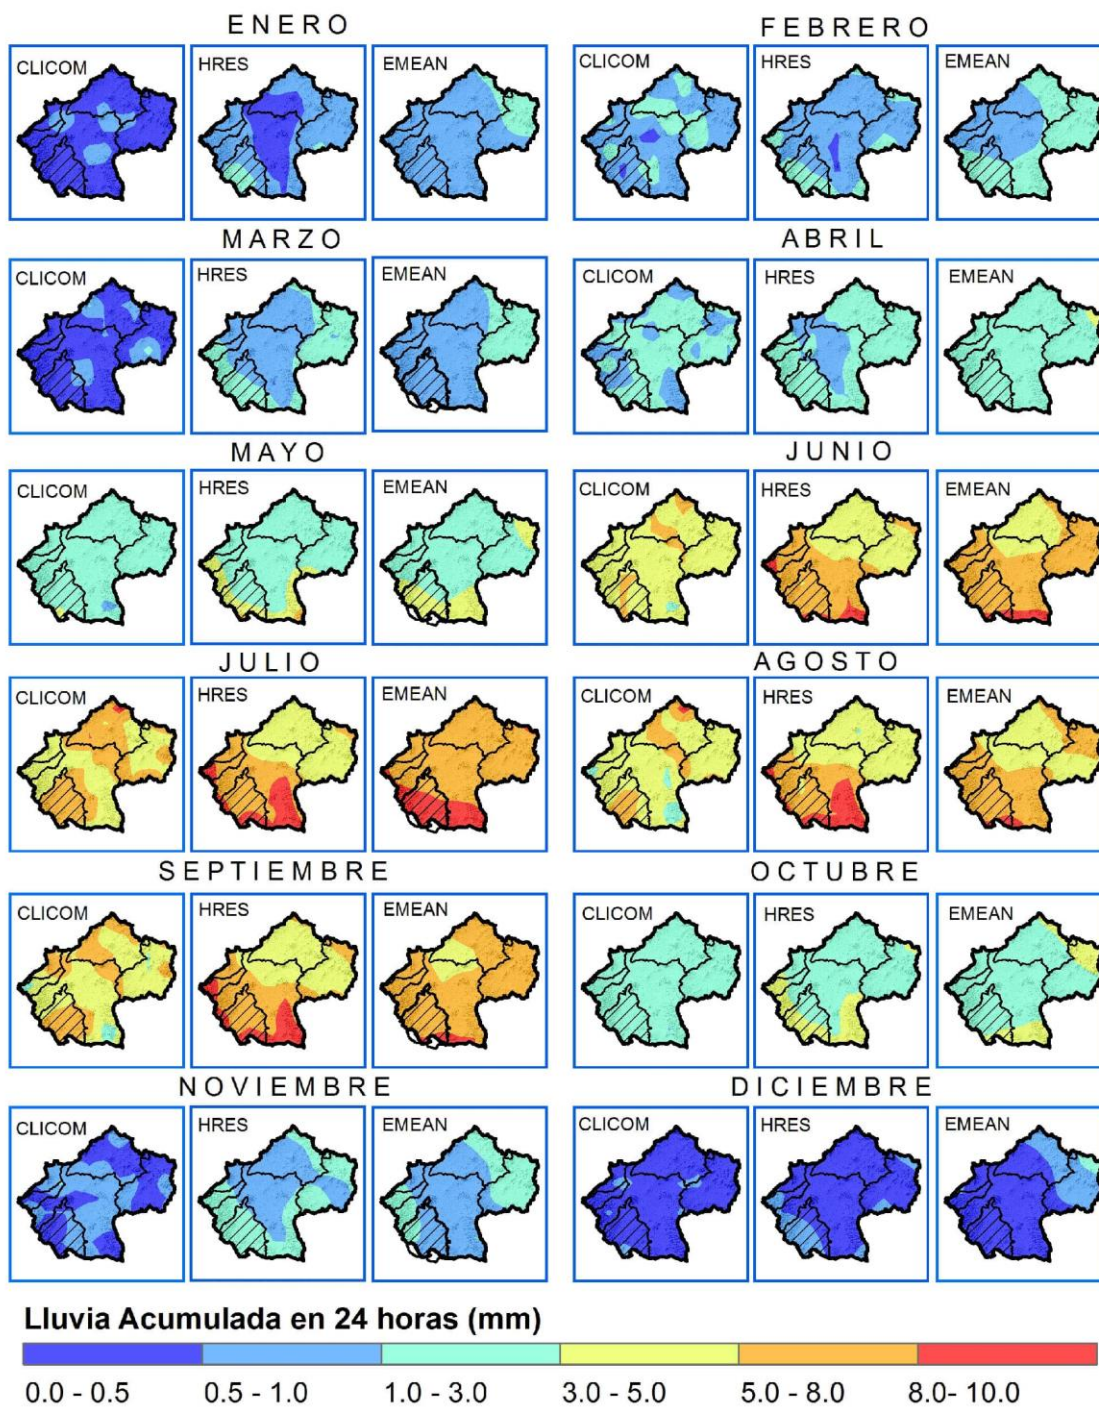


Figura 6.1. Mapas “Eyeball”. Lluvia promedio de 24 horas en CVM. Periodo 2007 – 2014.

Resultados de comparación visual de la lluvia observada por el sistema CLICOM contra el pronóstico no probabilista dado por la media de los ensambles “EMEAN”. Para interpolar los datos se aplicó una interpolación inversa del cuadrado de la distancia (IDW).

Con base en los mapas anteriores, se encontró que tanto HRES como EMEAN corresponden adecuadamente con los datos observados y, en general, logran identificar la temporada de lluvias (MJJASON). Las mayores inconsistencias ocurren para las zonas altas de la cuenca, donde se observa que tanto HRES como EMEAN sobre pronostican el evento; aunque HRES lo hace con mayor magnitud. Estos resultados son similares a los encontrados por Li et al., (2021) quienes reportaron una tendencia a sobre pronosticar las precipitaciones mensuales. Además, hay zonas donde las precipitaciones observadas no fueron identificadas adecuadamente por los pronósticos (por ejemplo, de enero a marzo).

Las diferencias observables entre observaciones y pronósticos se deben principalmente a la incertidumbre de las predicciones, aunque también existen otras posibles causas de error como la resolución de los pronósticos y la ocurrencia de lluvias convectivas; una mala distribución de las estaciones de medición; promedio aritmético de los datos observados; falta de datos y errores de medición.

### **Sesgo y Error Medio Cuadrático**

Para evaluar la magnitud promedio de los errores del pronóstico, la Figura 6.2 presenta el Sesgo (BIAS) y el error cuadrático medio (RMSE) promedio en la cuenca para HRES, EMEAN y CLICOM. El sesgo es una comparación del pronóstico promedio con la observación promedio y es una medida de la capacidad de discriminación del pronóstico. Como se muestra en la Figura 6.2a, el sesgo es mayor durante la temporada de lluvias (MJJASON); indicando sobre pronosticación cuando  $BIAS > 0$  y sub pronosticación de los eventos cuando  $BIAS < 0$ .

En general, existe una tendencia a sobre pronosticar los eventos. El sesgo de los productos HRES y EMEAN es similar; aunque EMEAN tiene un mejor rendimiento en comparación. Volviendo ahora a la Figura 6.2b, los resultados muestran un patrón año con año, donde los mayores errores ocurren durante la temporada de lluvias (MJJASON), con valores que oscilan entre los 0 y 20 milímetros.

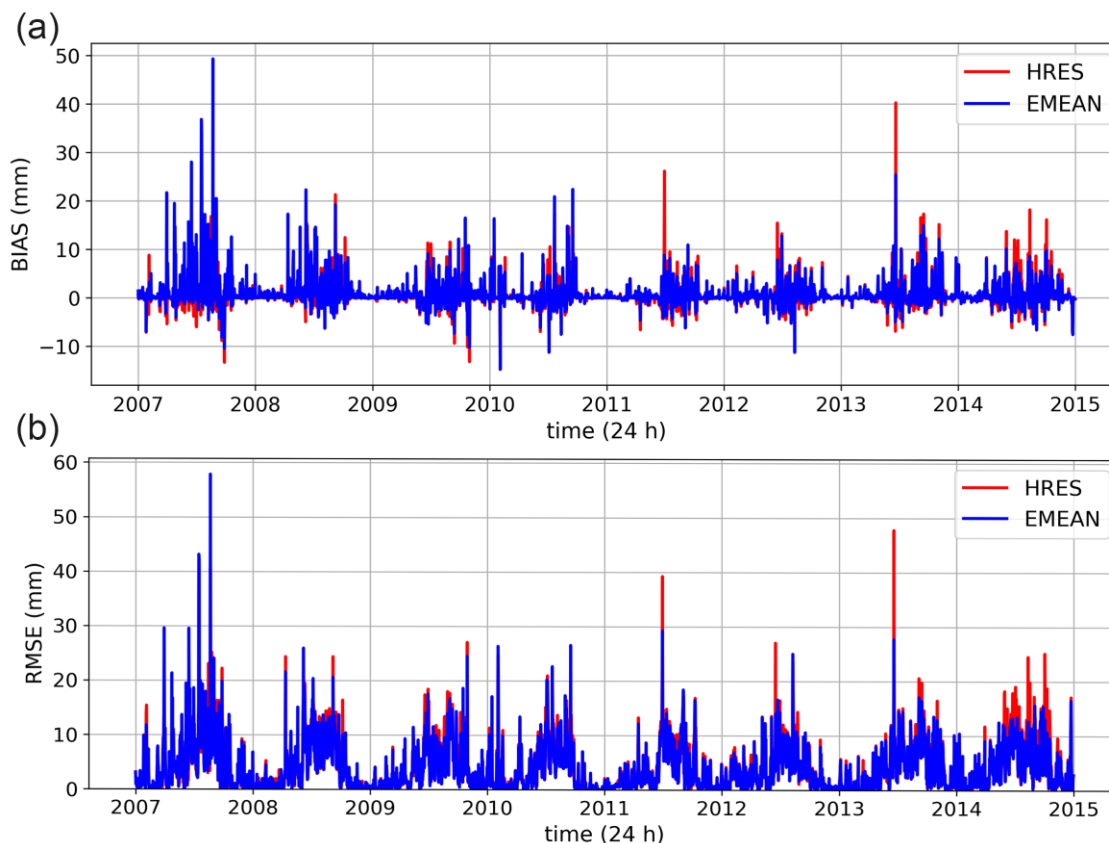


Figura 6.2. Sesgo y Error Medio Cuadrático de los productos HRES y EMEAN en la Cuenca del Valle de México

ECMWF 12 UTC,  $t = 24$  h. La variable estudiada corresponde a la precipitación acumulada diaria.

Los resultados muestran un crecimiento de errores y del sesgo durante los meses de mayo a noviembre (MJJASON); esto indica una mayor incertidumbre relacionada con los pronósticos de eventos extremos.

Ambos pronósticos deterministas presentaron resultados similares, aunque, EMEAN se desempeña mejor en comparación con HRES. Estos resultados demuestran un mejor desempeño de la media de los ensambles al utilizarse como pronóstico determinista.

### 6.1.2. Verificación no probabilista

Para medir la discriminación, resolución, precisión y confiabilidad del pronóstico determinista, fue necesario aplicar las métricas de desempeño descritas en la Tabla 4-7. En



las gráficas de la Figura 6.3 se presentan los resultados de los índices de desempeño para un rango de 0 - 70 milímetros de lluvia acumulada en 24 horas. Dicho rango de lluvia considera desde lluvias escasas hasta lluvias intensas, según la clasificación dada por la Unidad del Servicio Meteorológico Nacional (Salas Salinas & Jiménez Espinoza, 2014).

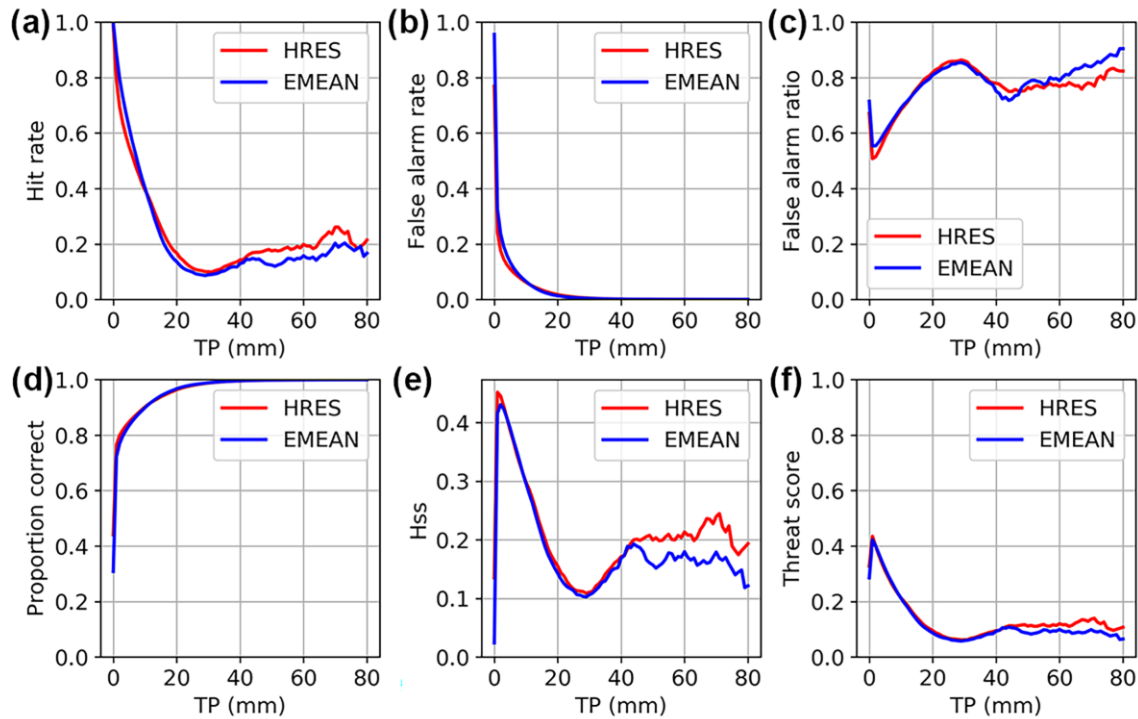


Figura 6.3. Métricas de desempeño de pronósticos HRES y EMEAN para la cuenca del Valle de México.

Umbral de precipitación acumulada de 0 a 70 mm en 24 horas. Periodo 2007 – 2014. a) índice de aciertos; b) Probabilidad de Falsa Alarma; c) Proporción de Falsa Alarma, d) Porcentaje Correcto; e) Heidke Skill Score y f) Total de Amenazas.

La Figura 6.3a muestra que la capacidad de los pronósticos para detectar eventos de interés es mayor para eventos de 0 a 10 mm ( $0.4 < \text{Tasa de Aciertos} < 1.0$ ). En la Figura 6.3b, el número de falsas alarmas es mayor para eventos de lluvia ligera (Precip < 10 mm). Los resultados en la Figura 6.3c indican pronósticos erróneos principalmente con FAR > 0.5 (sobre pronosticación de eventos menores y sub pronosticación de eventos fuertes). El índice PC en la Figura 6.3d muestra que la suma de aciertos positivos y negativos mejora para eventos mayores a 10 mm; mientras que para lluvias escasas (TP < 5 mm en 24 h) tiende a un valor de cero; lo que corrobora nuevamente la tendencia a sobre pronosticar

pequeños eventos. La Figura 6.3e presenta los resultados del índice HSS y muestra que la precisión del pronóstico es mayor para eventos de 2 a 10 milímetros. A diferencia de la Proporción Correcta, el total de amenaza o TS (Figura 6.3f) es más útil cuando el evento estudiado ocurre con menos frecuencia. Según el Threat Score (TS), el pronóstico de eventos de baja frecuencia es pobre con  $TS < 0.2$  para  $TP > 10$  mm, y presenta mejor desempeño para eventos en el rango de lluvia escasa a ligera ( $0 \text{ mm} < TP < 5 \text{ mm}$ ).

Los resultados anteriores sugieren que tanto HRES como EMEAN tienen un mejor desempeño para un rango de 2 a 10 mm de precipitación acumulada en 24 horas. La tasa de aciertos y la tasa de falsas alarmas (Figura 6.3a y Figura 6.3b) establecen que la capacidad de discriminación mejora para eventos en un rango de 0 a 10 mm en 24 h.

El número de falsas alarmas es mayor para eventos de precipitación mayores a 10 mm, lo que indica un sobrepronóstico de eventos de lluvia moderada. FAR (Figura 6.3c) sugiere baja confiabilidad de los pronósticos. Este índice también indica que ocurren más Falsas Alarmas para eventos mayores a 60 milímetros ( $TP > 60 \text{ mm}$ ).

Por otro lado, la precisión medida por PC (Figura 6.3d) muestra una tendencia a sobrepronosticar eventos menores a 5 mm y una mejor precisión para eventos mayores a 10 mm; aunque, con la baja frecuencia de eventos extremos, se podría argumentar que los resultados positivos se deben a la correcta identificación de los negativos correctos. Un método alternativo que resulta útil cuando el evento a pronosticar es de baja frecuencia es el Threat Score (TS) o Critical Success Index (CSI). En este caso el TS (Figura 6.3f) indica una precisión pobre en la identificación de eventos, con  $TS < 0.4$  para todos los umbrales.

Finalmente, los resultados indican que para lluvias mayores a 40 milímetros, EMEAN presenta un desempeño menor en comparación con HRES (Figura 6.3e). Este último resultado puede deberse a que; al centrarse en la media, EMEAN es más conservador y, por lo tanto, no logra identificar eventos extremos.

Para concluir con estos primeros resultados, HRES y EMEAN mostraron un comportamiento bastante similar, donde existe sobre pronosticación de eventos pequeños ( $TP < 2 \text{ mm}$ ) y sub pronosticación de eventos mayores ( $TP > 10 \text{ mm}$ ). Esto se traduce en un mejor desempeño de HRES y EMEAN en el rango de 2 a 10 milímetros de precipitación acumulada en 24 horas. Además, el porcentaje de aciertos negativos fue alto, lo que implica

un bajo porcentaje de falsas alarmas para eventos extremos; con todo, la capacidad de ambos productos para detectar este tipo de eventos tiende a ser baja o casi nula.

### 6.1.3. Verificación probabilista

#### Dispersión

La Figura 6.4 muestra un mapa promedio de la dispersión de los ensambles (periodo 2007 -2014) calculada con la ecuación (5.2, junto con las isoyetas de precipitación de CLICOM para la lluvia acumulada en 24 horas. Según las isoyetas, la precipitación observada varía en un rango promedio de 0 a 4 milímetros, mientras que la dispersión es mayor en las zonas altas de la cuenca, con una variación promedio menor a 0.5 milímetros.

#### CLICOM y DISPERSIÓN

Lluvia promedio diaria (mm)  
2007 - 2014

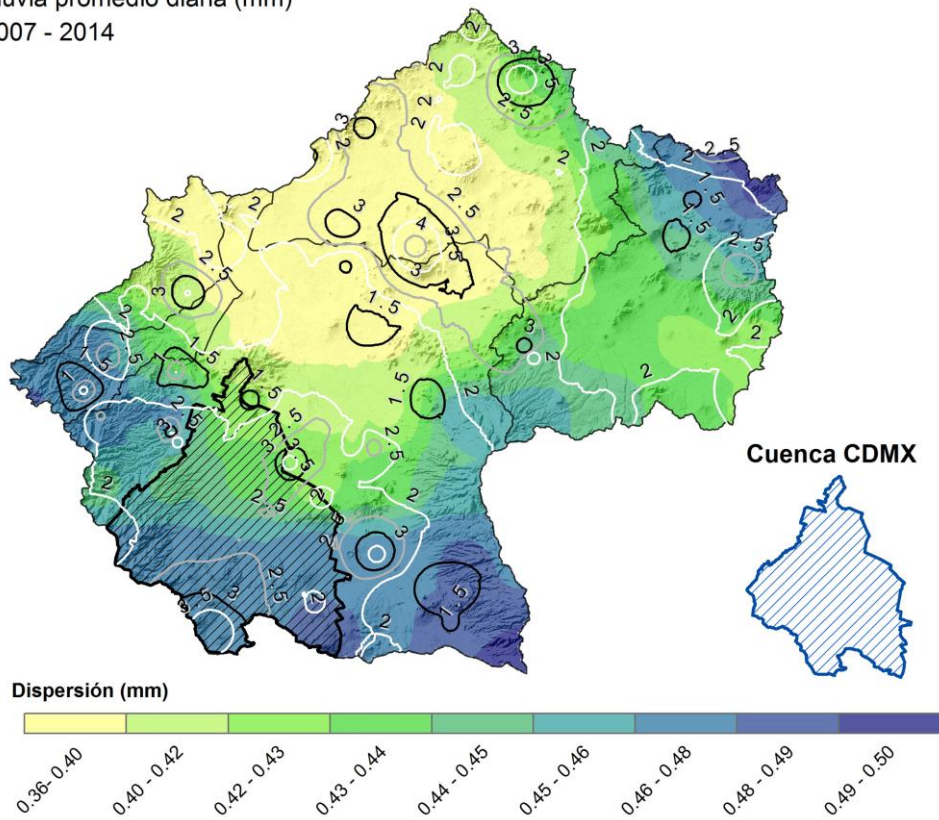


Figura 6.4. Mapa de dispersión de los ensambles en CVM.

Lluvia promedio diaria en la Cuenca del Valle de México (periodo 2007-2014). Isoyetas: CLICOM. Dispersión de los ensambles de pronóstico. 12 UTC, T = 24 Horas.

Los resultados en la Figura 6.4 son consistentes con los hallazgos anteriores; ya que la incertidumbre es mayor para las zonas altas de la cuenca, con valores medios de dispersión inferiores a 0.5 milímetros. Este hallazgo puede deberse a que el pronóstico probabilista está centrado en la media observada durante las primeras horas del horizonte de pronóstico. Aun así, se concluye que la dispersión no es significativa, por lo que se puede establecer que el producto ENS es lo suficientemente preciso para un horizonte de tiempo de 24 horas.

### Diagrama de Confiabilidad y curvas ROC

El diagrama de confiabilidad permitió saber qué tan bien corresponden las probabilidades pronosticadas de un evento con sus frecuencias observadas.

La Figura 6.5 muestra el Diagrama de Confiabilidad y las curvas ROC para el pronóstico probabilista de precipitación acumulada de 24 horas en CVM. Se establecieron tres umbrales: 5, 10 y 20 milímetros de lluvia acumulada, para considerar la ocurrencia de lluvias escasas a intensas de acuerdo con (Salas Salinas & Jiménez Espinoza, 2014). Para este análisis, se consideró que el evento ocurría con una probabilidad pronosticada mayor al 50%.

La Figura 6.5a muestra una mayor confiabilidad para umbrales de 0 a 10 milímetros. Para un umbral de lluvia menor a 5 milímetros, se presenta sub pronosticación de eventos asociados a probabilidades menores al 50%; lo cual puede deberse a que en general los ensambles pronostican valores mayores para los eventos de lluvia escasa. Por otro lado, para lluvias mayores a 5 milímetros, existe sobre pronosticación de eventos de alta probabilidad de ocurrencia ( $P > 60\%$ ). Para lluvias mayores a 10 milímetros, el pronóstico está sesgado y existe un sobrepronóstico para eventos de alta probabilidad. Finalmente, para un umbral de 20 milímetros, la forma de la curva indica que probablemente la muestra no es representativa del evento (Ebert, 2007). En este caso, sería necesario disponer de más datos históricos para obtener una buena estimación de las probabilidades para este último umbral.

Por otro lado, la gráfica ROC nos permite evaluar la habilidad del pronóstico en la discriminación de eventos observados y no observados. Las curvas ROC (Figura 6.5b) indican que los pronósticos presentan gran habilidad en la discriminación de eventos.

Además, el área bajo la curva (area under de curve, **auc**) se puede considerar como otra métrica de verificación. Curiosamente, el área bajo la curva de todos los umbrales analizados resultó ser de alrededor de 0.85. Esto podría deberse al hecho de que el modelo se ajusta bien a los verdaderos negativos en todos los umbrales (para los cuales la frecuencia es muy alta). Esto indica una baja probabilidad de falsas alarmas, lo que contribuye a la capacidad de discriminación del pronóstico.

Para finalizar, el área bajo las curvas ROC ( $auc = 0.85$ ) es indicativo de un buen sistema de pronóstico y un desempeño satisfactorio del modelo predictivo.

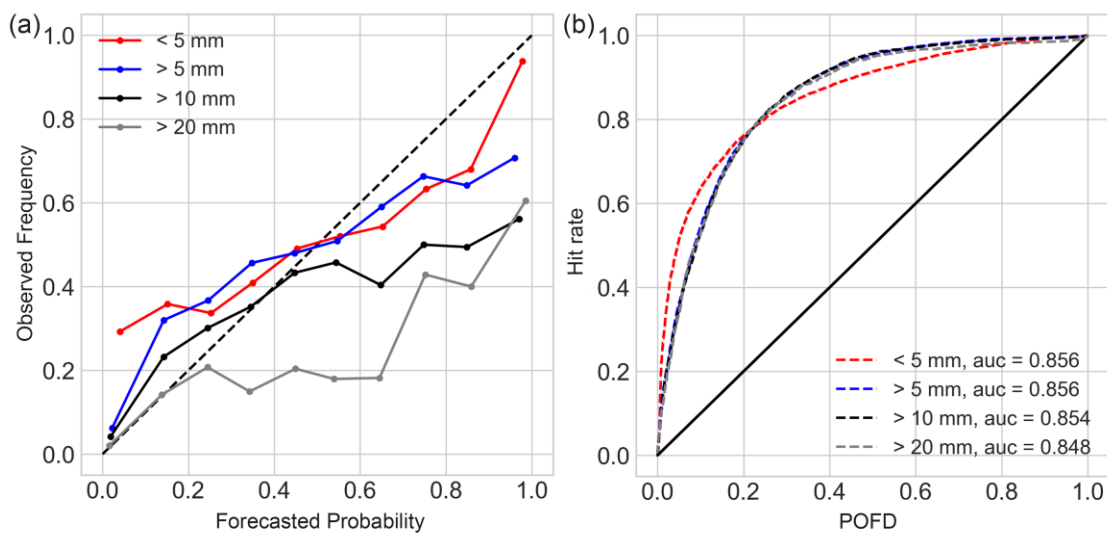


Figura 6.5 . Curvas de Confiabilidad y curvas ROC para  $t = 24$  horas en la Cuenca del Valle de México.

Las probabilidades fueron estimadas mediante el modelo de Regresión Logística descrito en el capítulo 5.3.1.

## 6.2. Verificación de pronósticos en zona 2: Ciudad de México

Este análisis se desarrolló para el polígono que define a la Ciudad de México, con el objetivo de abordar la incertidumbre meteorológica y evaluar el desempeño de los pronósticos.

Las lluvias convectivas son la principal fuente de inundaciones en la Ciudad de México, es por ello que la distribución espacial de la precipitación juega un papel fundamental. Por estas razones, es importante analizar los pronósticos de precipitación en

una escala de tiempo más pequeña; por lo que se evaluó la precipitación acumulada cada 6 horas y considerando un horizonte de tiempo de 90 horas ( $t = 0 + 90 \text{ h}$ ).

Conocer el pronóstico para un horizonte de 6 horas puede ser muy útil para los servicios de emergencia, ya que pueden centrar sus esfuerzos en puntos estratégicos de la ciudad con el tiempo suficiente.

### 6.2.1. Exploración preliminar

En el mapa de la Figura 6.6 se muestra una comparación de los productos HRES y EMEAN contra los datos observados por el OH-IIUNAM, mediante la Correlación de Pearson<sup>29</sup>. Este mapa permitió conocer la precisión del pronóstico en pasos de tiempo de 6 horas y para diferentes ventanas de tiempo. Los círculos del mapa de impacto representan a las estaciones de medición; de estos, los círculos en color rojo son aquellas estaciones en donde el producto EMEAN tiene mejor desempeño; en contraste, los círculos azules son las estaciones en donde HRES se ajusta mejor a los valores observados. Los resultados de la figura establecen que el pronóstico EMEAN es mejor para las diferentes ventanas de tiempo en comparación con el pronóstico determinista HRES, y ratifican el uso de la media de los ensambles como un mejor producto de pronóstico no probabilista.

En la Figura 6.7 se presenta un meteograma promedio de la precipitación en la Ciudad de México. El meteograma es resultado de la comparación de las estaciones puntuales del OH-IIUNAM con respecto a la cuadrícula de pronóstico del ECMWF. La gráfica muestra la evolución promedio de la precipitación observada y pronosticada durante la temporada de lluvias (MJASON). Las líneas roja y azul corresponden a la precipitación emitida por el OH-IIUNAM y HRES para un horizonte de 90 horas respectivamente; y las líneas envolventes corresponden a los percentiles del pronóstico probabilista ENS, calculados para un rango de 10% a 90%. Los resultados indican que la precipitación observada se ubica dentro del percentil 20% - 30% de la distribución de probabilidad y

---

<sup>29</sup> Es una medida estadística que indica la relación entre dos variables y trata de cuantificar la dependencia lineal entre dos variables aleatorias cuantitativas (Probabilidad y Estadística, 2022).

generalmente por debajo de la curva HRES (línea roja); lo que es indicativo de un sobrepronóstico de eventos.

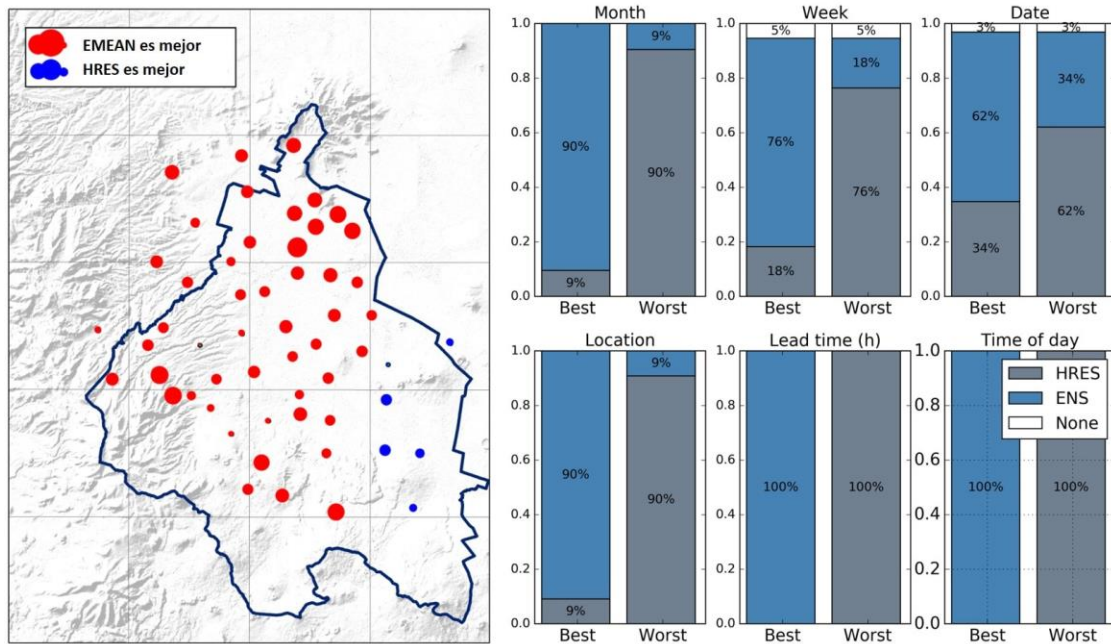


Figura 6.6. Mapa de impacto y correlación de Pearson para distintas ventanas de tiempo.

Izquierda: Mapa de Impacto de la ciudad de México. Resultados espaciales del error medio cuadrático. Los círculos representan las estaciones del Observatorio Hidrológico del Instituto de Ingeniería. Rojo: HRES es mejor; Azul: EMEAN es mejor. Derecha: Resultados de la correlación Pearson para diferentes ventanas de tiempo.

Como se observa en la Figura 6.7, el pronóstico HRES es suficientemente preciso en las primeras 36 horas; después de ese tiempo, comienza a sobrepronosticar eventos, por lo que ya no es confiable; es entonces cuando los ensambles presentan la mayor ventaja. Este hallazgo es consistente con Gouweleuw et al., (2005), quienes establecieron que algunos miembros del conjunto pueden ser representativos de eventos extremos y que se encuentran dentro del percentil 95 de la distribución. El meteograma promedio muestra que el evento observado está dentro del rango de la distribución de probabilidad. Esto es bueno ya que significa que la distribución de probabilidad dada por los ensambles constituye una buena representación de los posibles escenarios de la atmósfera a lo largo del horizonte de tiempo, y en donde la curva del evento observado no es estadísticamente distinta a cualquier otro miembro del ensamble.




Figura 6.7. Meteograma de precipitación promedio para la ciudad de México.

Horizonte de tiempo de 90 horas con pasos de tiempo de 6 horas. Línea azul: Precipitación observada promedio para la CDMX. Línea roja: Pronóstico no probabilista HRES. Percentiles 10 % a 90 % indicados por las envolventes en tonalidad gris. La gráfica muestra un resultado estadístico de la tendencia de la curva masa de lluvia en el periodo observado (2017 -2019).

### 6.2.2. Verificación probabilista

La Figura 6.8a muestra el Diagrama de Confiabilidad y las curvas ROC para pronósticos probabilísticos de precipitación acumulada cada 6 horas en la Ciudad de México, para un horizonte de tiempo de 0-90 horas y durante 2017-2019. Los umbrales se establecieron con base en la media ( $0 < Precip < 0.47 \text{ mm}$ ) y el percentil 95 ( $Precip > 2.4 \text{ mm}$ ) de los datos observados de precipitación. Se consideró que el evento ocurrió con una probabilidad pronosticada mayor al 50 %.

Para  $Precip > 0.47 \text{ mm}$ , se presenta sobre pronosticación de eventos asociados a altas probabilidades ( $Probabilidad \text{ pronosticada} > 60 \%$ ). Si pasamos ahora a las curvas ROC (Figura 6.8b), se puede ver que la curva se encuentra un poco más cerca de la diagonal de  $45^\circ$ , por lo que el desempeño del modelo no fue tan bueno como para la primera zona analizada (CVM). A pesar de ello, los valores de *auc* obtenidos están en torno a 0.72, por lo que el modelo se considera útil.






Figura 6.8. Curvas de Confiabilidad y ROC para  $t = 6$  horas y  $lt = 0+90$  h en CDMX.

Las probabilidades fueron estimadas mediante un modelo de Regresión Logística.

Por otra parte, los resultados del índice de Brier para los eventos en estudio se presentan en la gráfica de la Figura 6.9. El índice muestra mejores resultados mientras aumenta la precipitación. Esto significa que el ensamble es más preciso sí se consideran precipitaciones acumuladas mayores a 1 milímetro; lo cual demuestra nuevamente la tendencia a sobre pronosticar eventos pequeños ( $Precip < 1\text{ mm}$ ) por parte del producto ENS. Probablemente esta precisión se debe al hecho de que son pocos los eventos acumulados mayores a 2 milímetros y la precisión se presenta a causa de los correctos negativos.




Figura 6.9. Índice de Brier para eventos de precipitación de 0 a 5 mm acumulados en 6 horas.

La curva representa al índice promedio para la ciudad de México y periodo 2017-2018 MJJASON.

### 6.3. Evaluación del modelo Predictivo

De acuerdo con la metodología descrita en el capítulo 5.4.1, se crearon tres modelos predictivos utilizando la combinación de datos mostrada en la Tabla 6-1. El objetivo fue encontrar la combinación de información que brindara mejores resultados y una mayor confiabilidad en las predicciones. El Modelo 1 se construyó solo a partir de la información histórica del OH-IIUNAM; el Modelo 2 se construyó a partir de la combinación de la información del OH-IIUNAM y CLICOM para la CVM; y el Modelo 3 se construyó a partir de los datos combinados del OH-IIUNAM y CLICOM para la CDMX. En la Tabla 6-1 también se presentan los resultados de la validación cruzada para cada análisis de datos y el área obtenida bajo las curvas ROC de cada modelo.

Tabla 6-1. Reporte de resultados del Modelo Predictivo para lluvia mayor a 10 milímetros en 24 horas.

Modelo	Data based input				STATSMODELS	SKLEARN			ROC curve	
	Dominio	Fuente de la información	Paso de tiempo	Cantidad de datos	Periodo (MJASON)	Miembros significativos	Entrenamiento	Prueba	CVS*	AUC
1	CDMX	OHIUNAM	24,48,72	22470	2017 - 2019	27	0.8	0.2	0.91	0.74
	CDMX	OHIUNAM	24,48,72	22470	2021 - 2019					
2			+			39	0.8	0.2	0.895	0.8
	CVM	CLICOM	24	121552	2007 - 2014					
3	CDMX	OHIUNAM	24,48,72	22470	2021 - 2019					
			+			25	0.8	0.2	0.88	0.77
	CDMX	CLICOM	24	20544	2007 - 2014					

\*Índice de la Validación Cruzada (Cross Validation Score)

Las gráficas siguientes corresponden a los Diagramas de Confiabilidad y Curva ROC para los tres modelos predictivos. En primera instancia se observa que el Modelo 2 presenta un mejor desempeño, ya que su área bajo la curva es igual a 0.8 (Figura 6.10b) y su curva de confiabilidad presenta un buen ajuste, aunque con sobre pronosticación de

eventos de alta frecuencia (Figura 6.10e). En contraste, los modelos 1 y 3 presentan un comportamiento muy similar con áreas bajo la curva de 0.74 y 0.77; sin embargo, la forma de las curvas de confiabilidad (Figura 6.10a y Figura 6.10c) indica que la muestra de los datos no es representativa del evento estudiado, por lo que no se puede establecer con claridad la confiabilidad de dichos modelos.

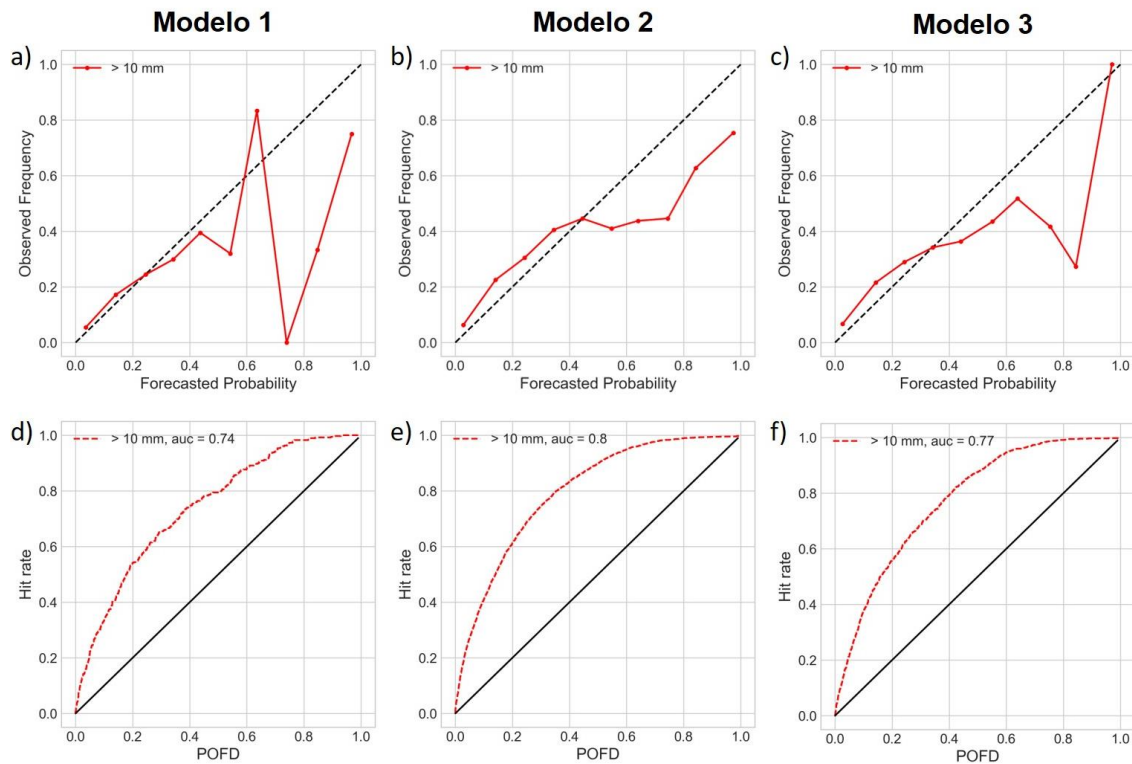


Figura 6.10. Diagrama de confiabilidad y curvas ROC para los modelos predictivos descritos en la Tabla 6-1. Resultados para un umbral de lluvia mayor a 10 mm en 24 h.

Por las razones anteriores; se decidió evaluar los resultados de los modelos mediante el Método basado en umbrales (Capítulo 4.3.1). Esta evaluación permitió conocer el desempeño de los modelos predictivos a escala espacial y temporal, mediante su aplicación y comparación con los eventos de lluvia observados y descritos en la Tabla 2-1. Con base en la experiencia ganada durante la creación de los modelos predictivos y la comparación con eventos observados, se decidió tener un enfoque más conservador en cuanto el umbral de decisión para alerta del evento, por lo que se consideró un umbral de 30% para decidir la sí ocurrencia de los eventos. Para analizar estos resultados se construyeron los mapas de las Figura 6.11 a Figura 6.20, que muestran los resultados de forma espacial, y

adicionalmente se incluyen las gráficas de la lluvia observada y pronosticada para cada uno de los pixeles de la cuadrícula del producto HRES.

Para el evento del 28-05-2017 (Figura 6.11), los tres modelos se desempeñan correctamente en las primeras 24 horas, en donde se pronostican probabilidades menores al 10% identificando correctamente los correctos negativos. Para las 48 horas, tanto los modelos 1 y 3 pronostican una probabilidad de ocurrencia del 10 al 20 % en las zonas 8 y 9, mientras que el modelo 2 estimó una probabilidad mayor al 20% de acierto en dichas zonas. No obstante, el modelo 2 no logró pronosticar la lluvia ocurrida en la zona 10. Para las 72 horas, el modelo 3 presenta falsas alarmas; mientras que los modelos 1 y 3 se comportan de forma similar al estimar probabilidades de ocurrencia menores al 20% para el evento que no ocurrió. Para este evento, tanto los modelo 1 y 3 tienen buen desempeño para las 24 y 72 horas, mientras que el modelo 2 se desempeñó mejor para las 24 y 48 horas.

En las primeras 24 horas para el evento del 27-06-2017 (Figura 6.12), los modelos 1 y 2 logran identificar con mejor desempeño la lluvia en las zonas 1, 2,4, 5, 8 y 9, con probabilidades de ocurrencia mayores al 30 %. Esto mismo ocurre para las 48 horas. En contraste, el modelo 3, falló pronosticando probabilidades menores al 30% para el evento observado. En cuanto al horizonte de 72 horas, los tres modelos identificaron correctamente los negativos correctos; aunque, fallaron en la identificación y pronóstico de la lluvia en la zona 3. Esto significa que el ensamble tiene problemas para reconocer eventos de lluvia ocasionados por una evolución rápida de las condiciones atmosféricas.

Para las primeras 24 horas del evento del 30-08-2017 (Figura 6.13), los modelos 1 y 3 identificaron de forma satisfactoria la lluvia en las zonas 1, 4 y 8 con probabilidades de ocurrencia mayores al 40 %; sin embargo, el modelo 3 presentó un mejor desempeño al identificar el evento que ocurrió para todo el dominio de cálculo. Para las 48 horas, los modelos 1 y 3 tienen un desempeño muy similar, no obstante, el modelo 1 pronosticó mejores probabilidades ( $P[X] > 30\%$ ) en las zonas 1 y 4. El modelo 2 tuvo un desempeño muy pobre, ya que obtuvo errores en su mayoría. Por último, los tres modelos no lograron identificar el aumento de la precipitación en la zona 9, debido a que el evento observado se sale de la distribución de probabilidad dada por los ensambles; y además, presentaron falsas alarmas para las 72 horas.

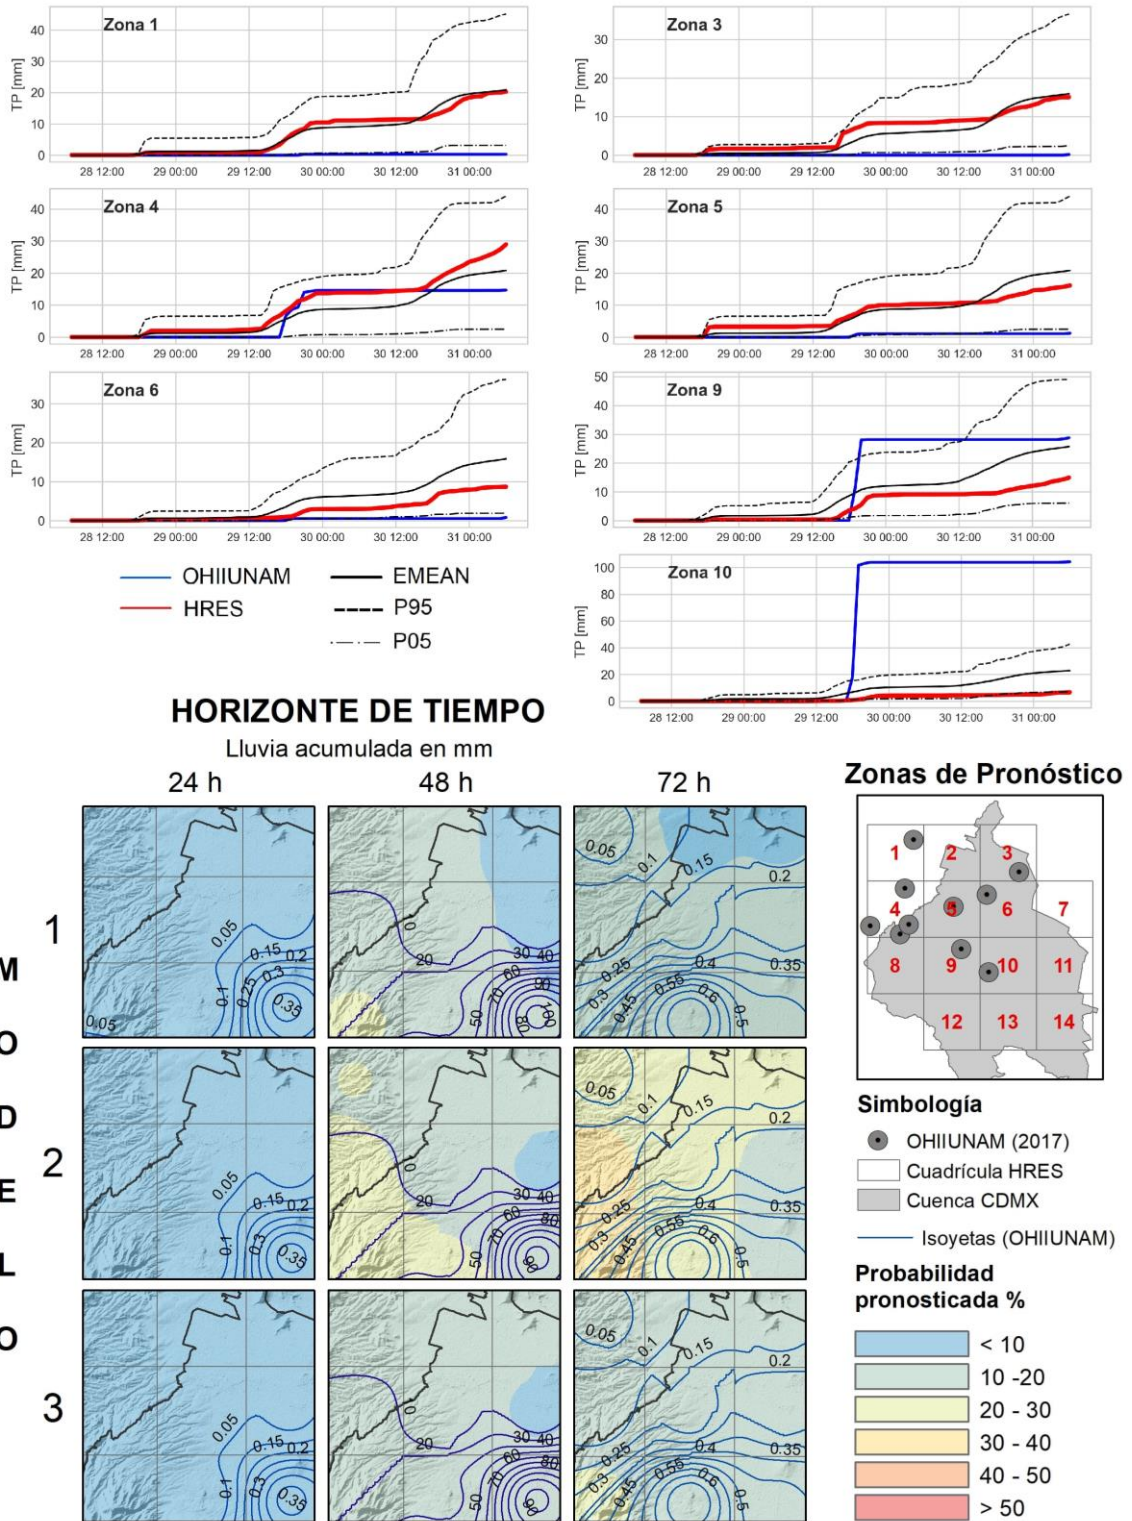


Figura 6.11. Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 h, estimadas a partir del modelo predictivo. Evento con tiempo base 28-05-2017 12 UTC y horizonte de tiempo de 72 horas. Gráficas en hora local.

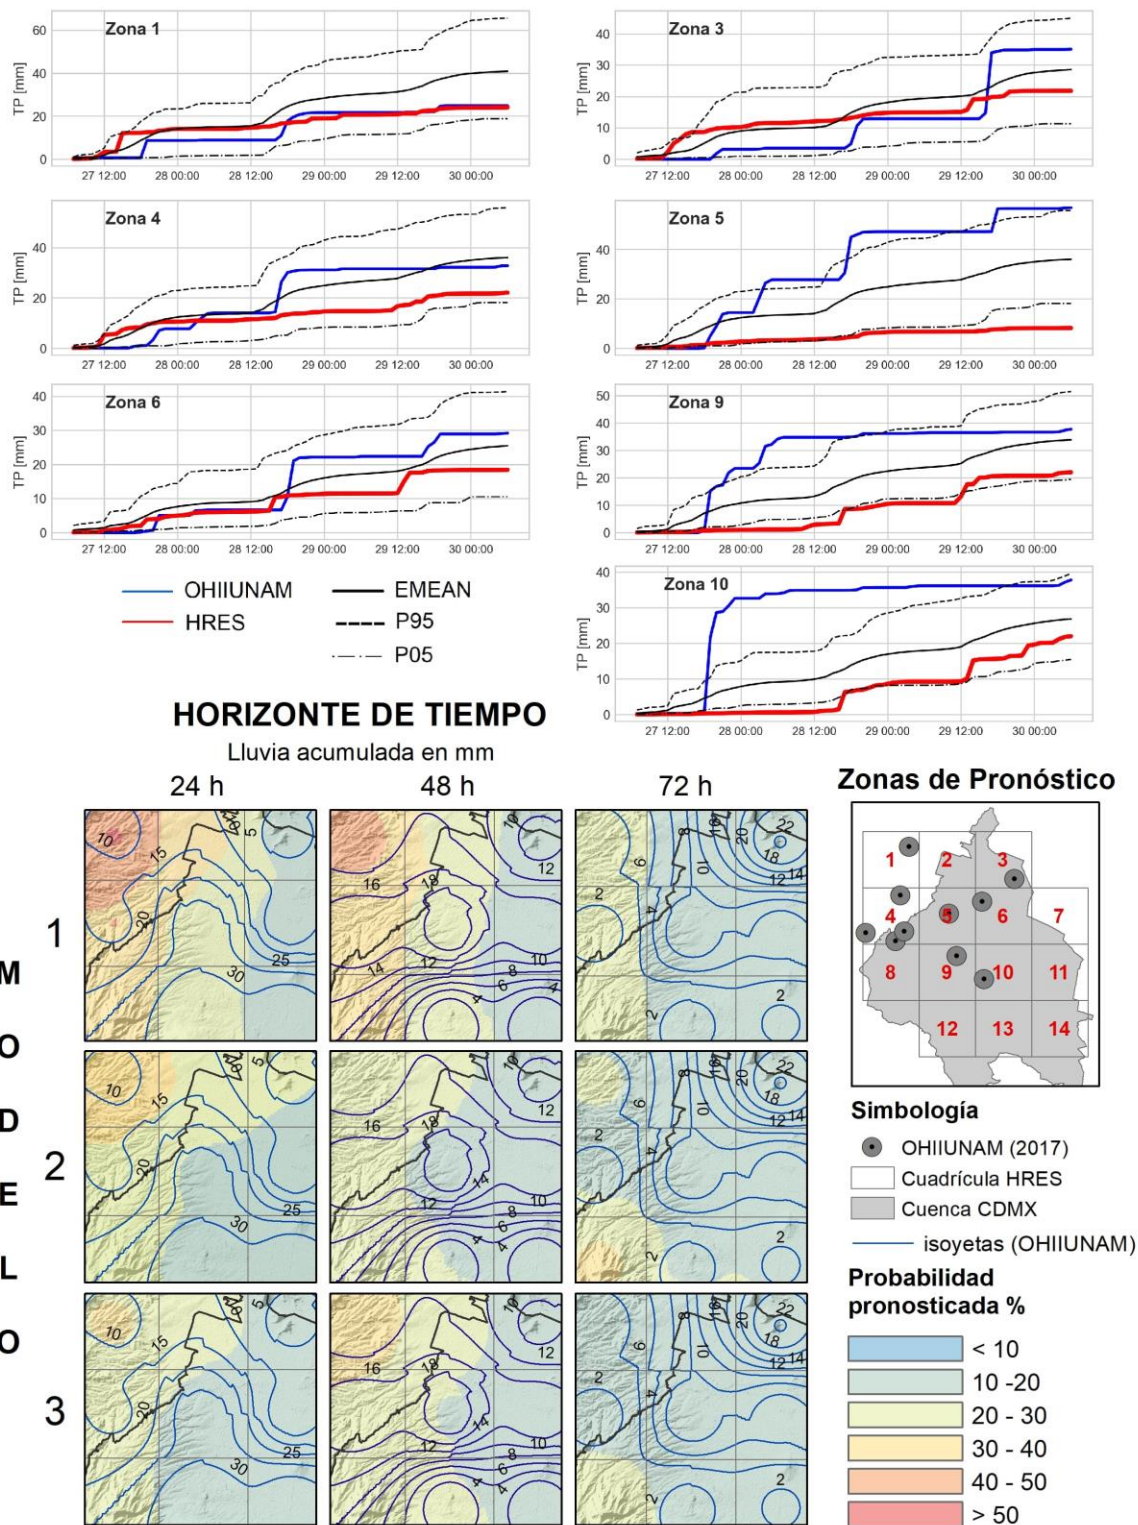


Figura 6.12 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 27-06-2017 12 UTC y horizonte de tiempo de 72 horas.

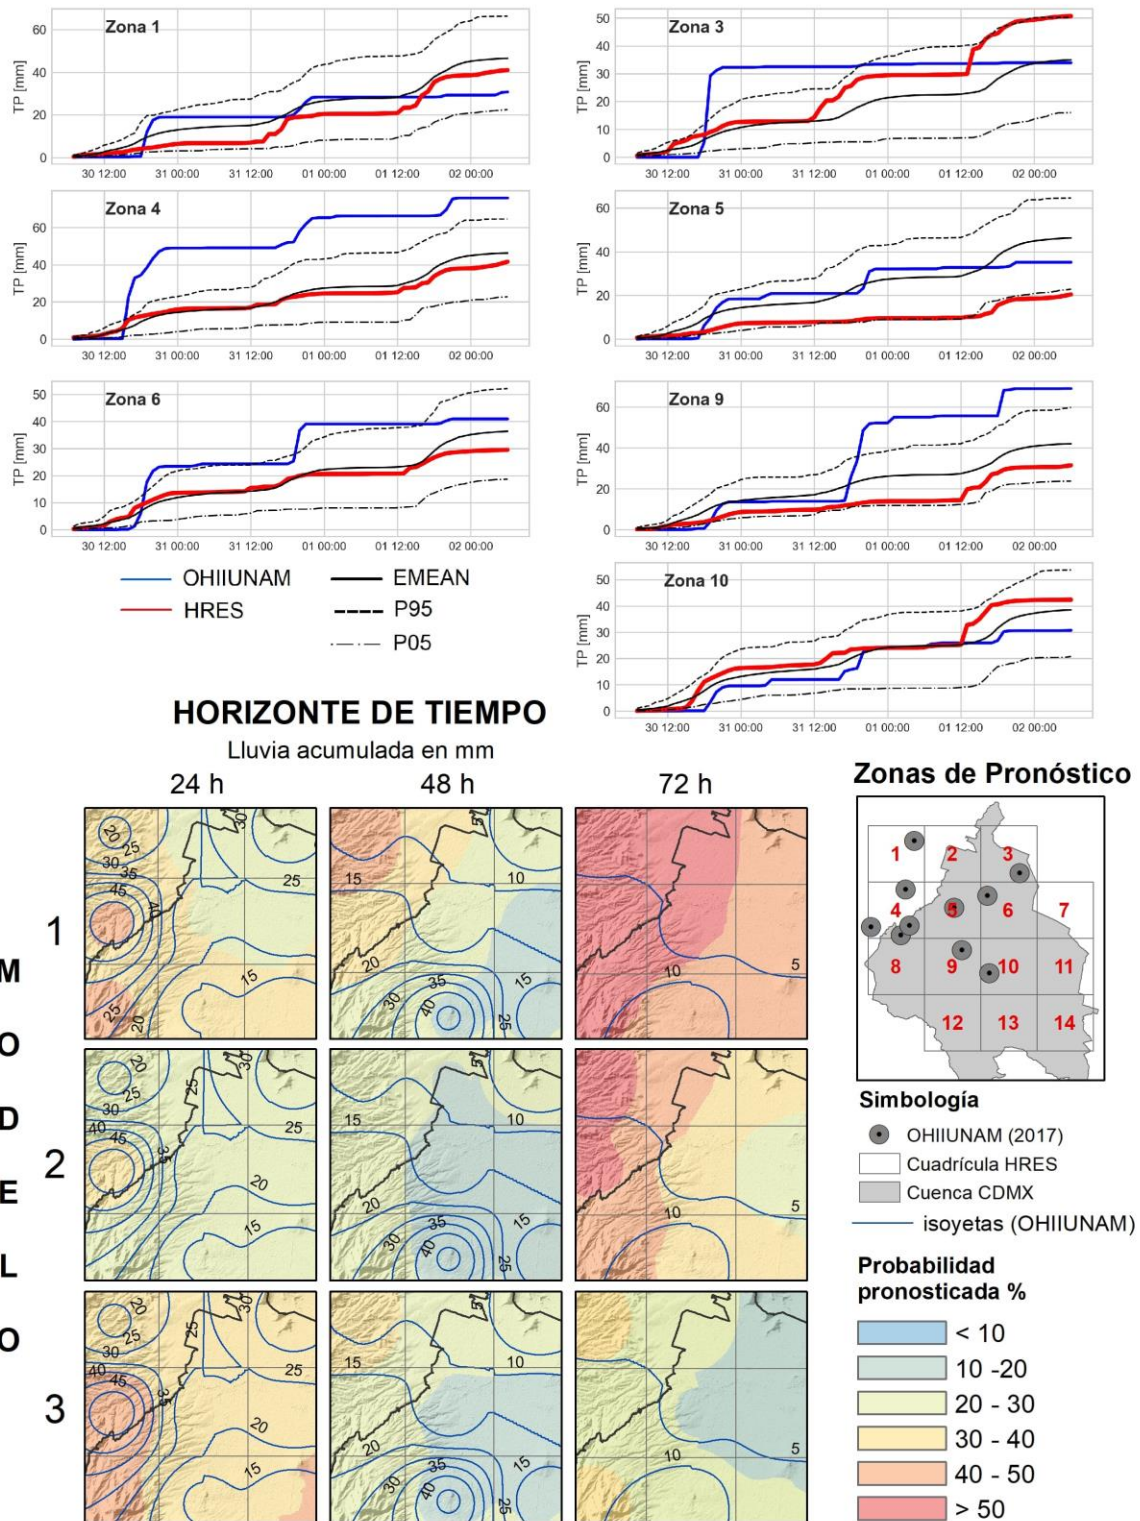


Figura 6.13 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 30-08-2017 12 UTC y horizonte de tiempo de 72 horas.

Durante las primeras 24 horas del evento del 06-09-2017 (Figura 6.14), los tres modelos pronosticaron probabilidades mayores al 50 % para la ocurrencia del evento en las zonas 1, 4, 5, 8, 9 y 10. En este caso podemos ver que se presenta sobre pronosticación de eventos en la zona 1, por otro lado, los modelos 1 y 3 lograron predecir la lluvia de 40 mm en la zona 10 con probabilidades mayores al 50 %. Posteriormente, para las 48 y 72 horas, no se presentó el evento, en donde el modelo 1 identificó correctamente la no ocurrencia, sin embargo, los modelos 2 y 3 presentan falsas alarmas (por ejemplo, en las zonas 5 y 10).

Para el evento del 04-08-2018 (Figura 6.15), los tres modelos presentaron resultados muy similares para todos los horizontes de pronóstico. El modelo 1 no pronostica falsas alarmas en las zonas 1 y 4 a diferencia de los modelos 2 y 3. Al igual que en el evento del 27-06-2017, en este caso la lluvia evolucionó de forma rápida para las 48 horas; y debido a esto, la lluvia no fue identificada en las zonas 4, 5, 8, 9, 11 y 12 por ninguno de los 3 modelos, ya que pronosticaron probabilidades de ocurrencia menores al 20 %. Para el horizonte de 72 horas, el modelo 1 mostró mejor desempeño en la identificación de no ocurrencias, en comparación con los modelos 2 y 3; sin embargo, ninguno de ellos logró predecir el incremento de la lluvia en la zona 3.

El evento del 19-08-2018 (Figura 6.16) presentó resultados muy similares al evento anterior, ya que nuevamente se observó que, al presentarse una evolución rápida de las condiciones atmosféricas, y sobre todo, cuando los valores de lluvia se salen de la distribución de probabilidad, el ensamble no identifica el evento, y por lo tanto, no logra predecir el evento. Esto se puede observar en la gráfica y los mapas de lluvia de la zona 4 para un horizonte de 48 horas. Por último es importante mencionar que los modelos 2 y tres pronosticaron falsas alarmas en las zonas 12, 13 y 14 para las 72 horas.

Para el evento del 26-08-2018 (Figura 6.17), todos los modelos se desempeñan de forma muy similar para los horizontes de 24 y 48 horas. El modelo 1 muestra mejor desempeño al identificar el evento en la zona 14 para las 48 horas, con una probabilidad de ocurrencia del 30%. También es importante notar que; para las 72 horas, los modelos fallan en predecir la lluvia ocurrida en la zona 7 (Evolución rápida de la lluvia). Lo anterior también sucede para las 48 horas del evento del 21-09-2018, en la zona 6 de pronóstico (ver Figura 6.18).



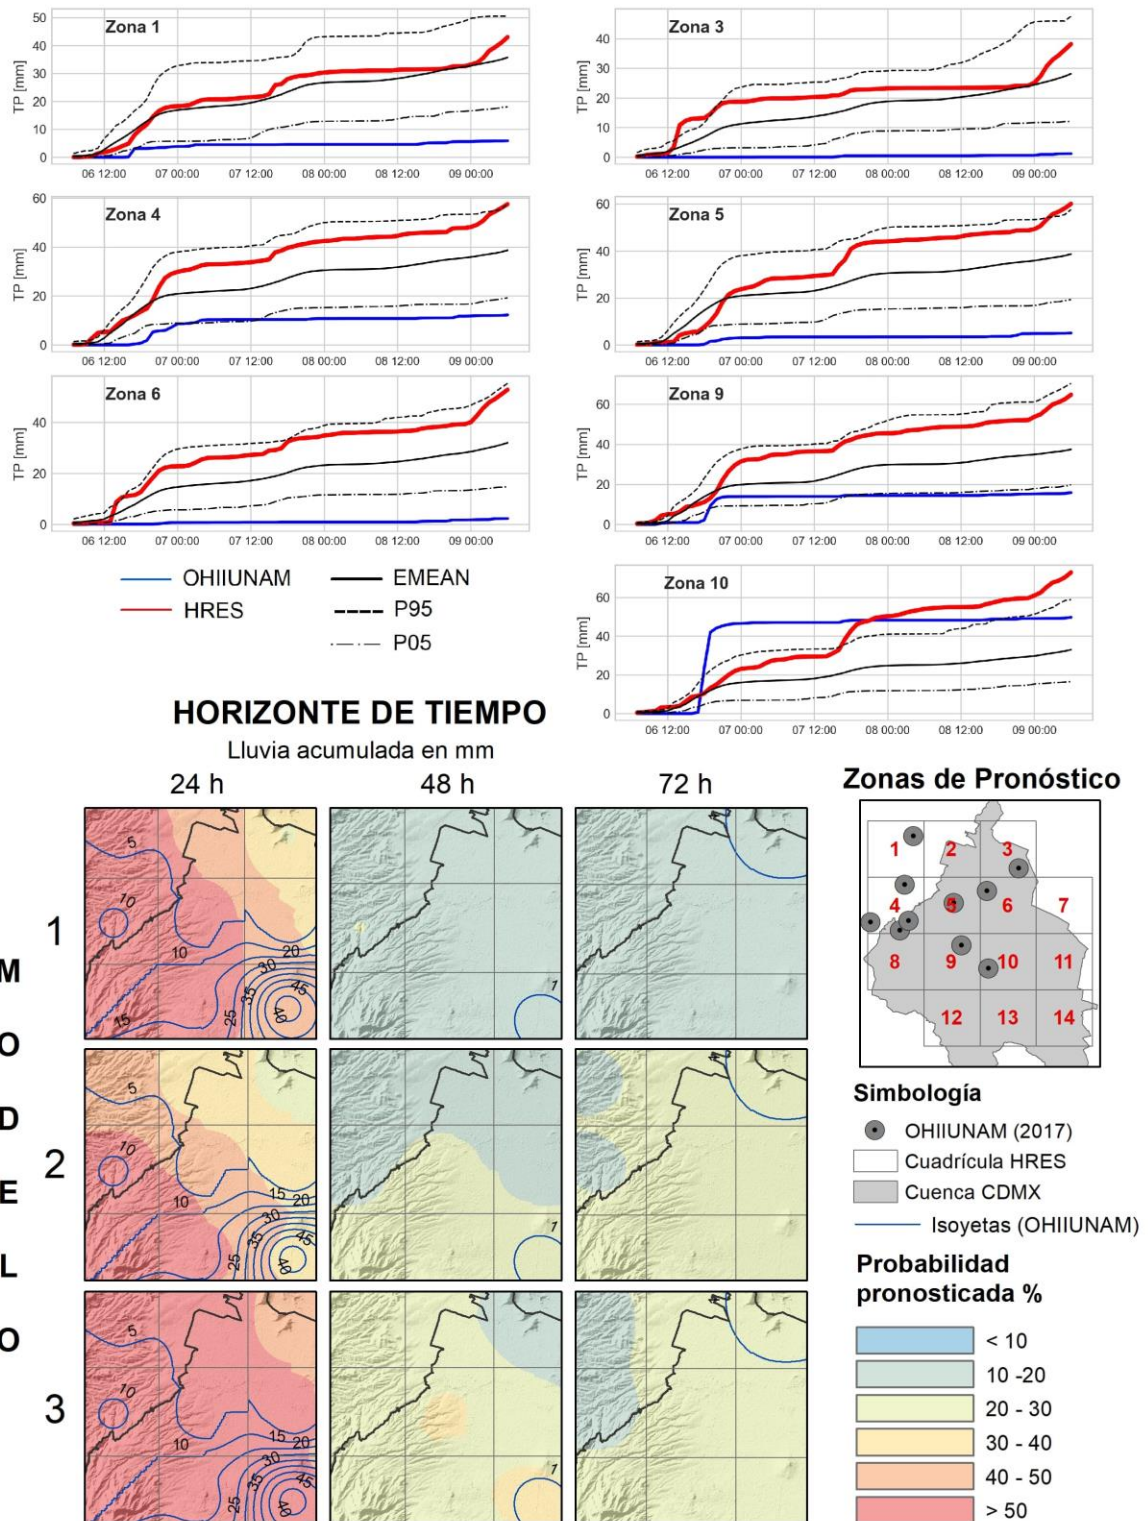
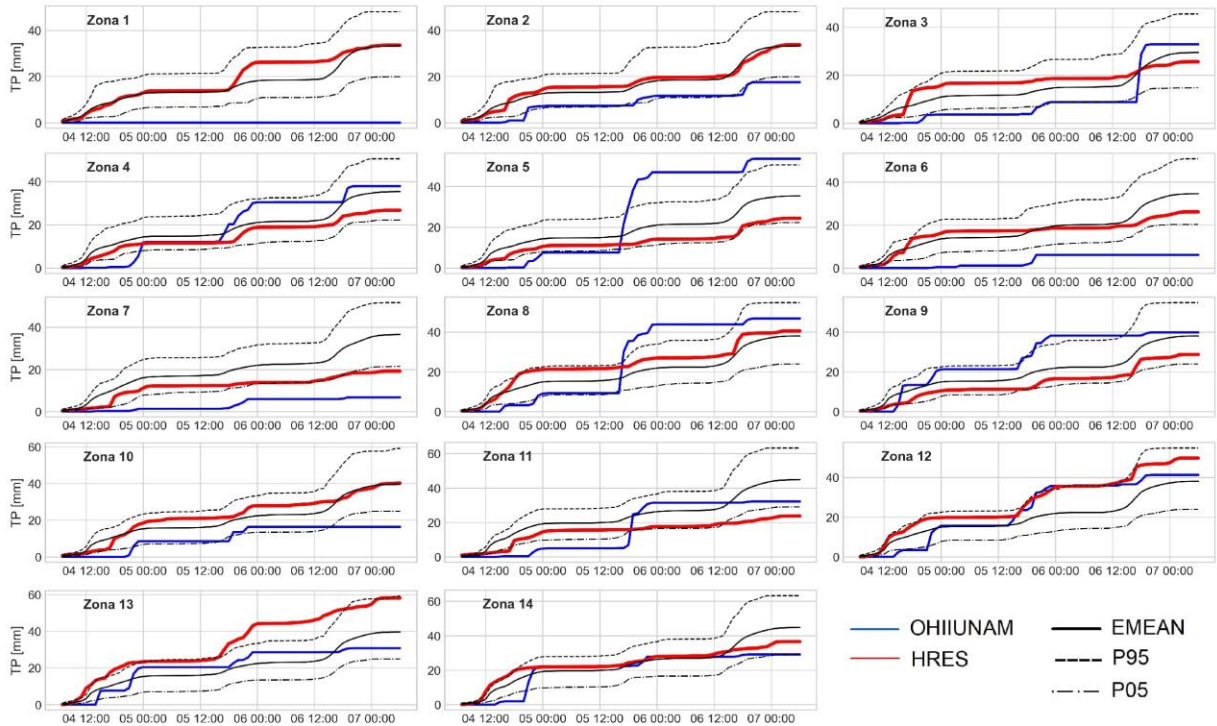


Figura 6.14 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 06-09-2017 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

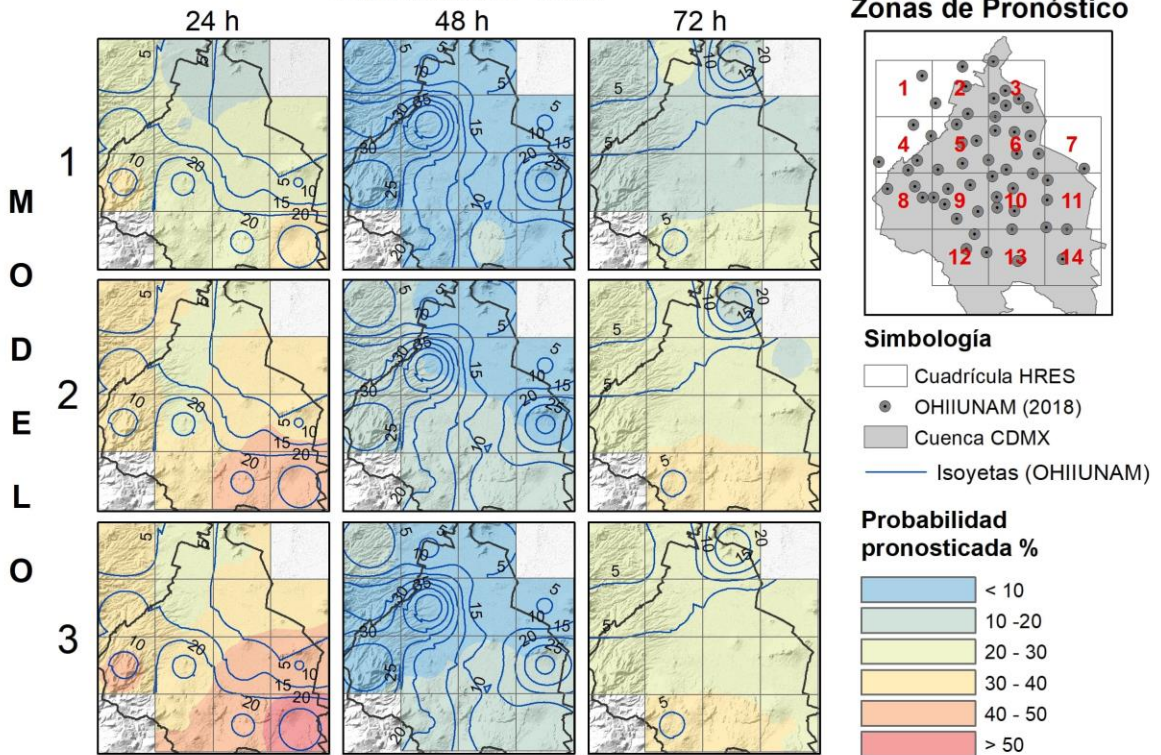
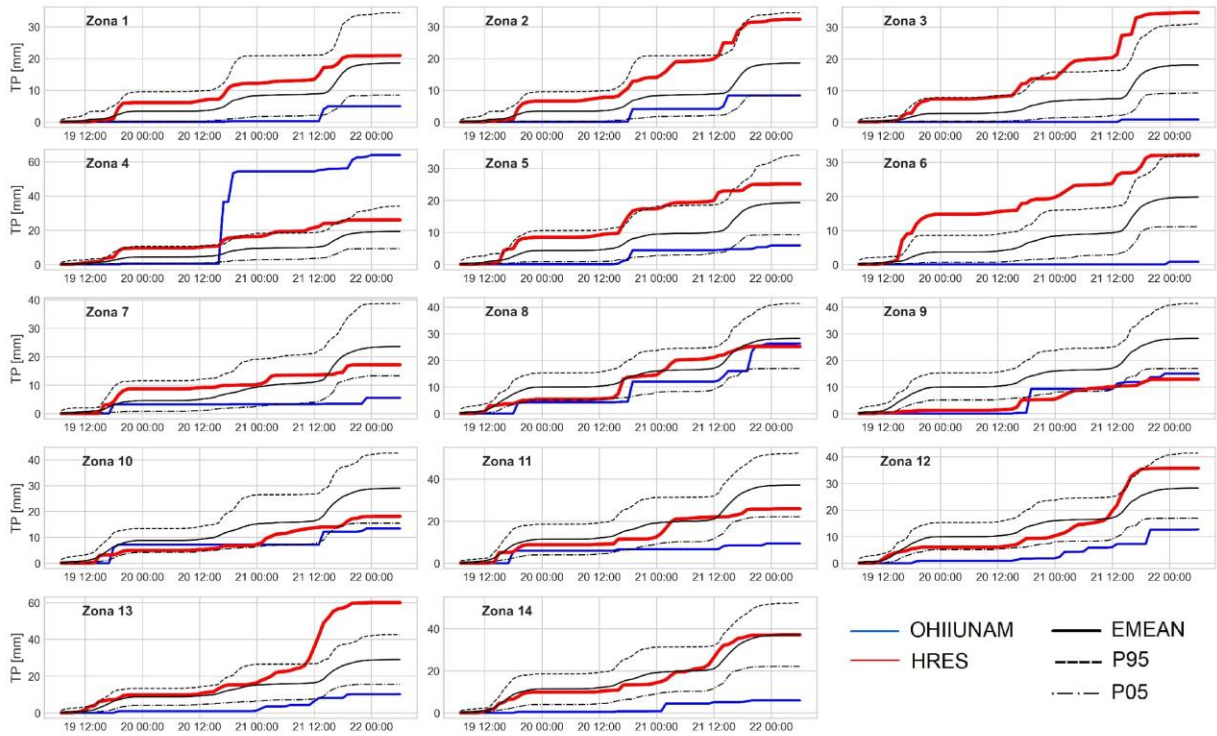


Figura 6.15 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 04-08-2018 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

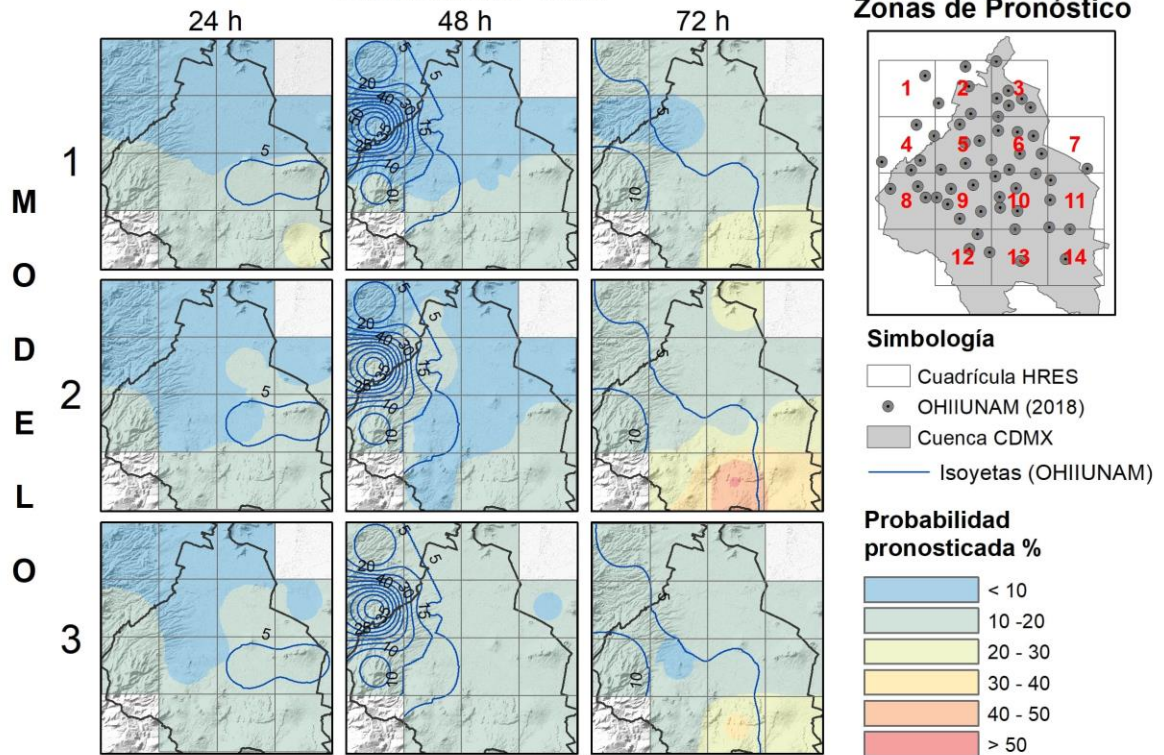
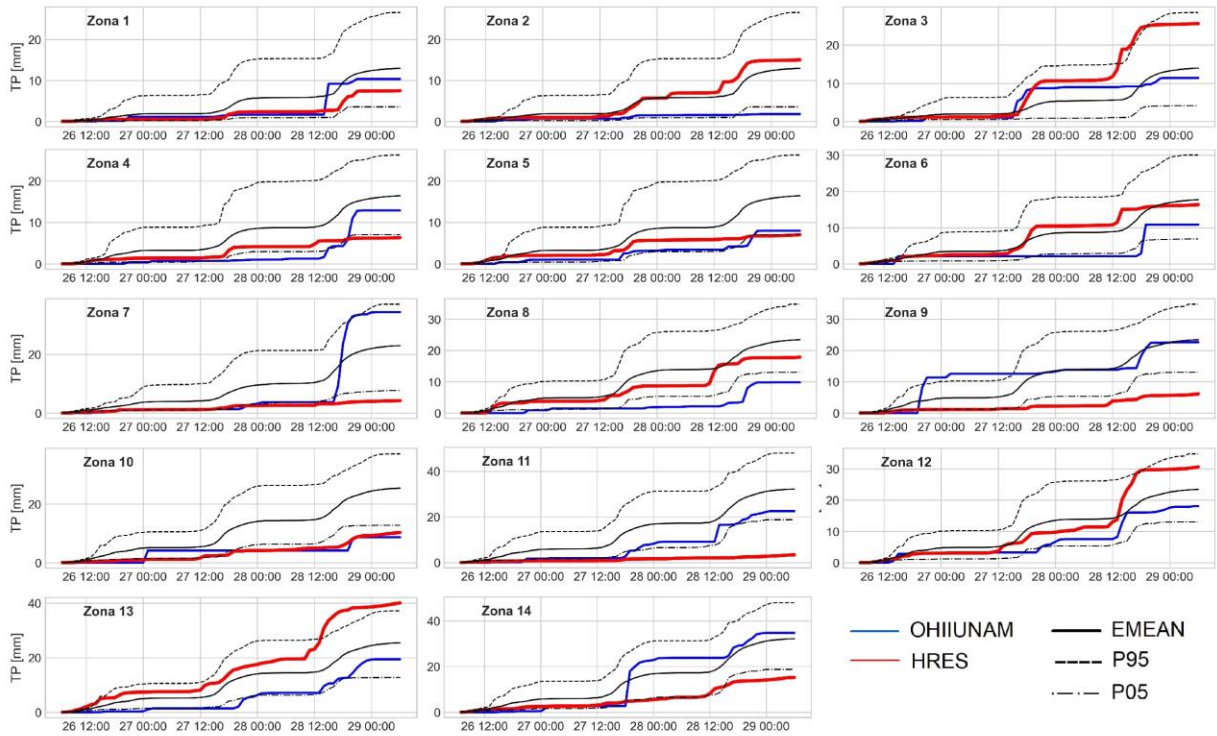


Figura 6.16 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 19-08-2018 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

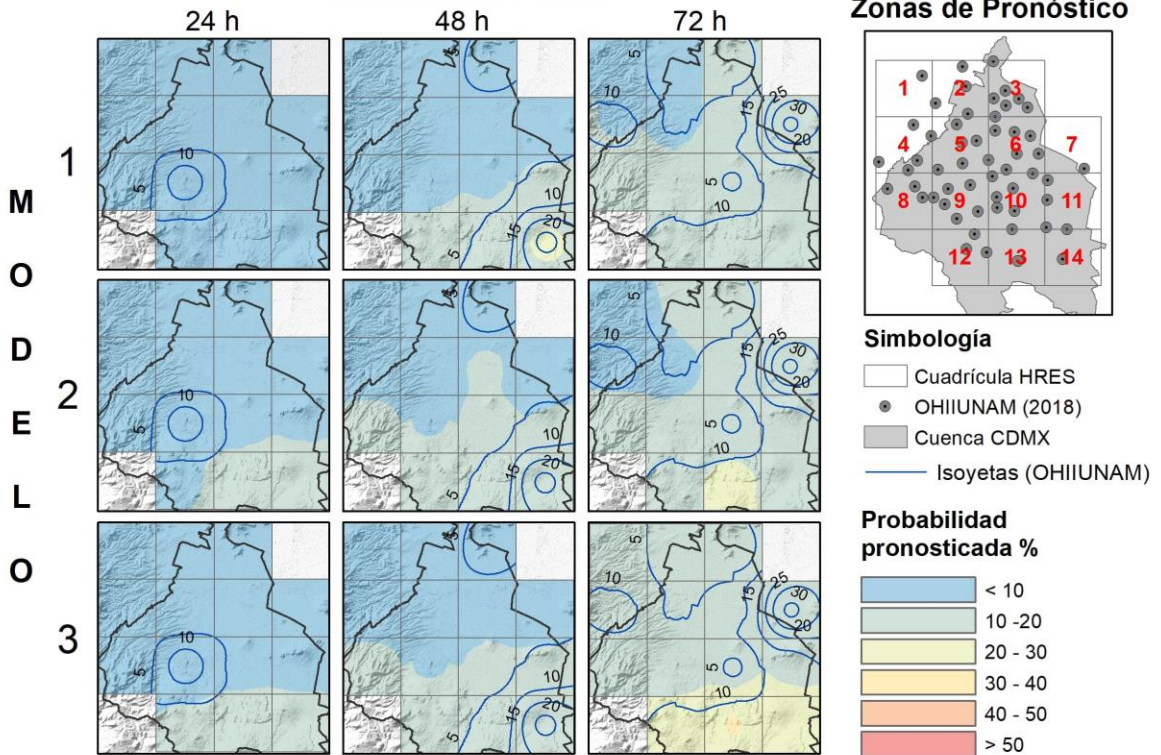
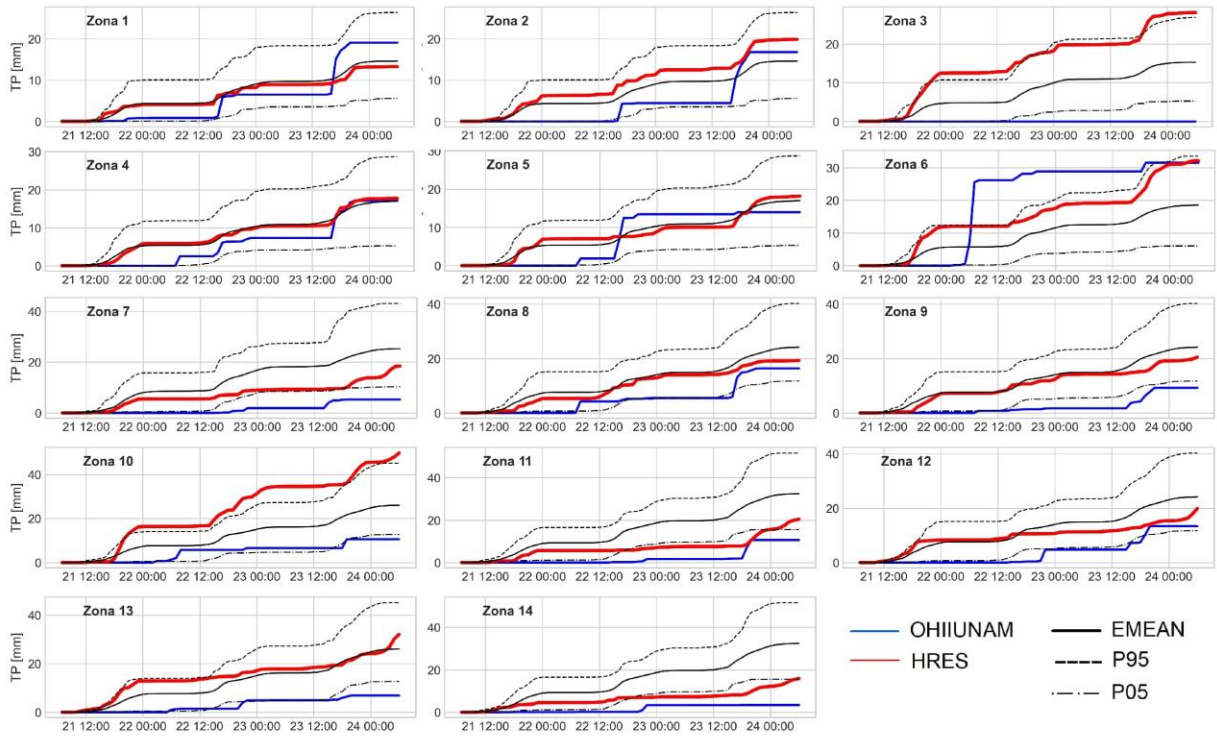


Figura 6.17 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 26-08-2018 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

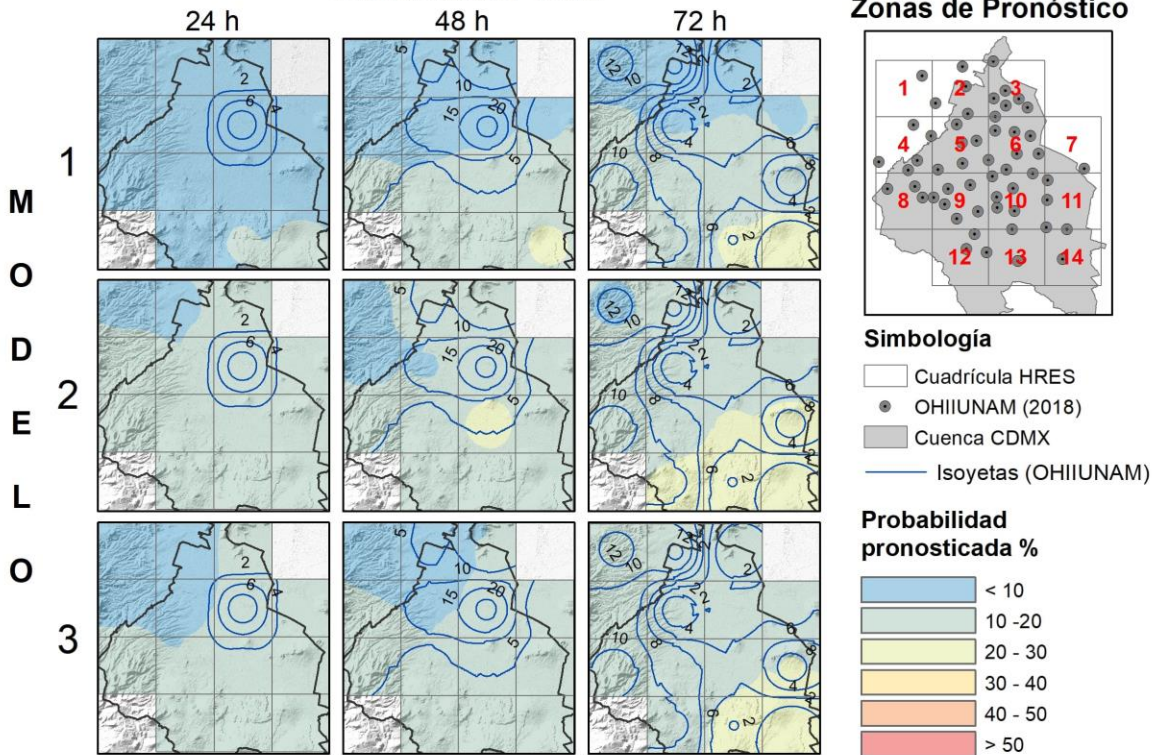
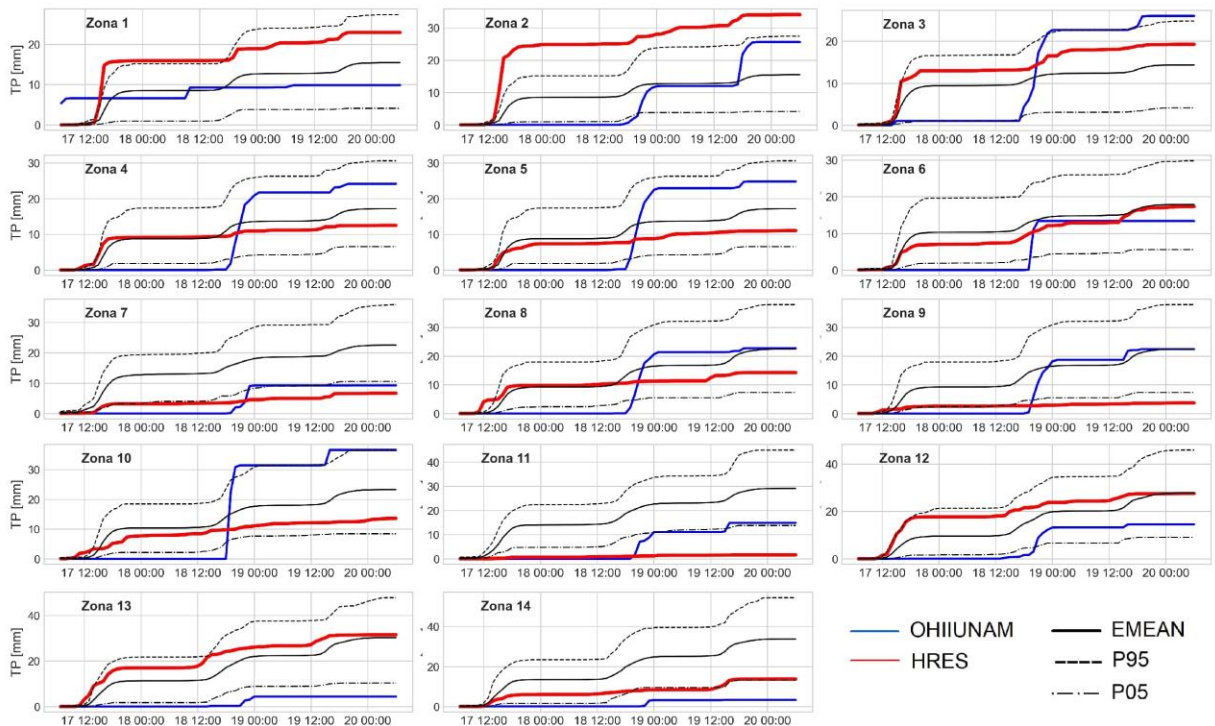


Figura 6.18 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 21-09-2018 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

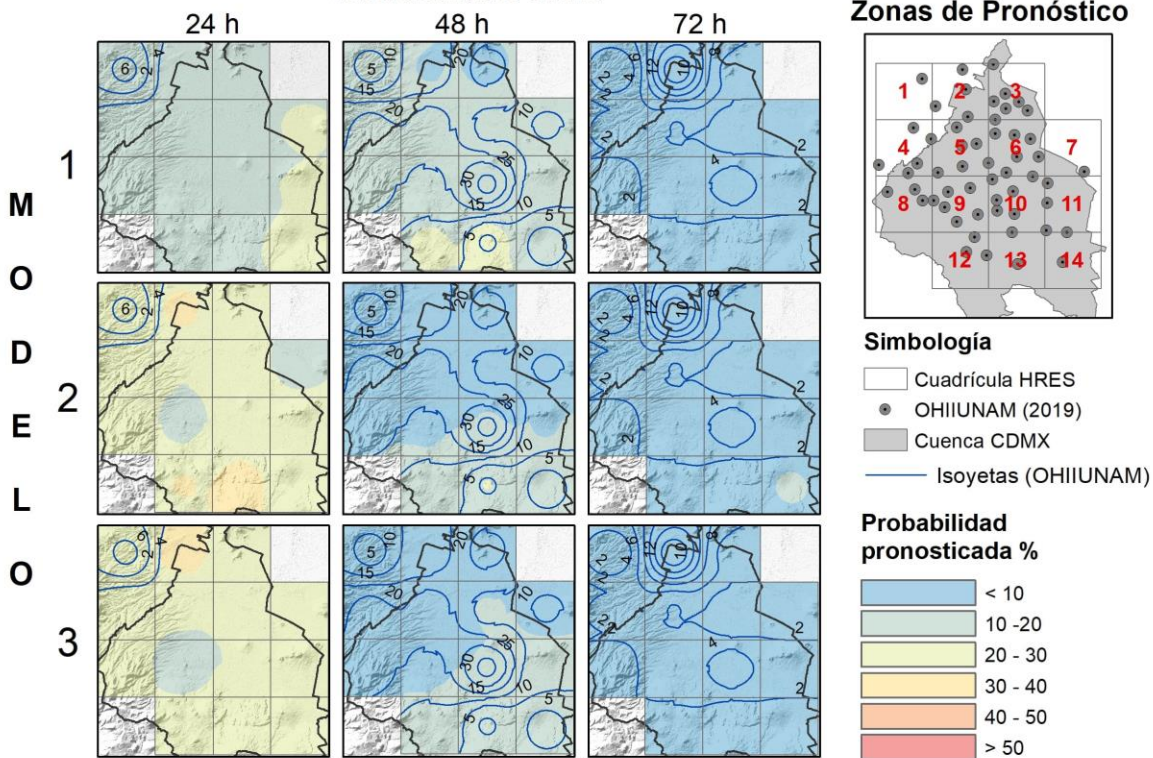
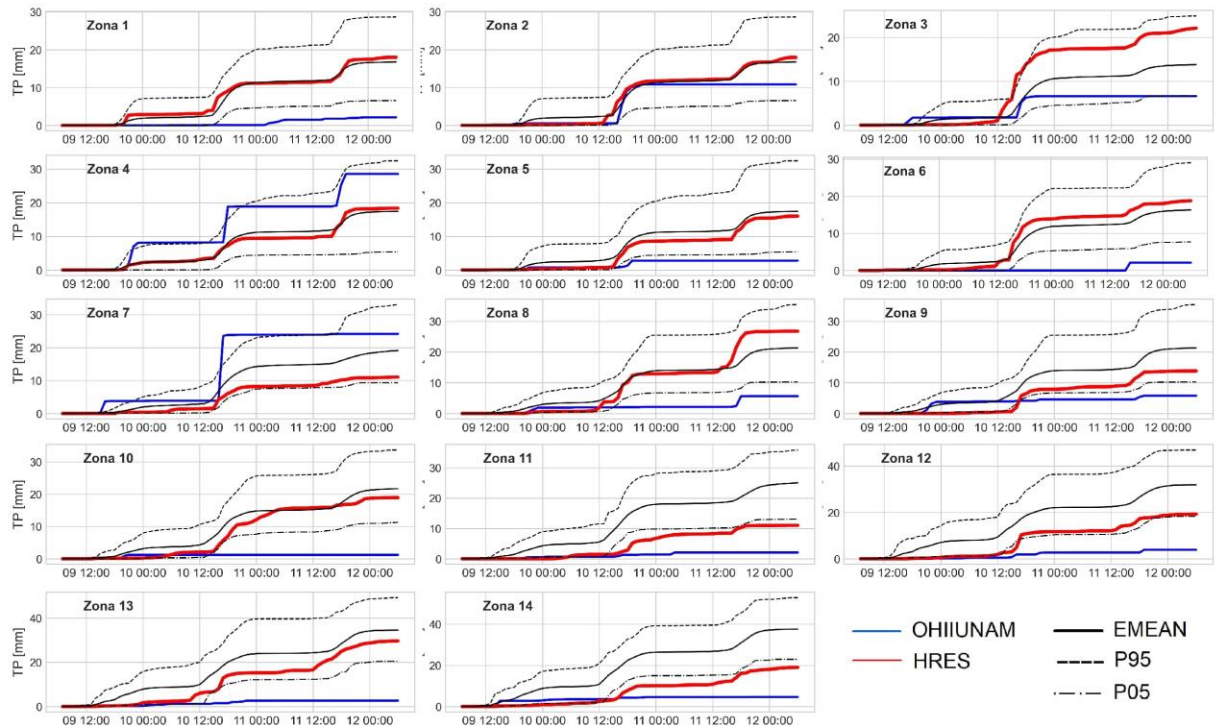


Figura 6.19 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 17-07-2019 12 UTC y horizonte de tiempo de 72 horas.



**HORIZONTE DE TIEMPO**

Lluvia acumulada en mm

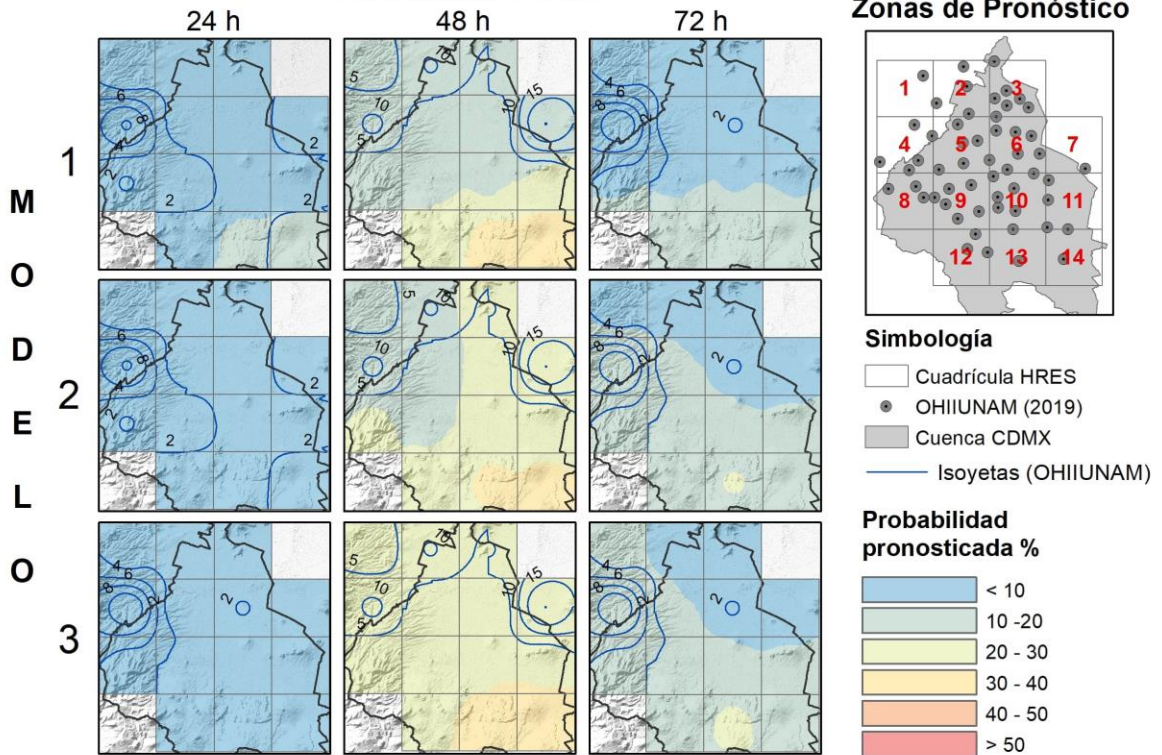


Figura 6.20 Resultados de la probabilidad de ocurrencia para lluvia mayor a 10 mm en 24 horas estimadas a partir del modelo predictivo; Evento con tiempo base 09-09-2019 12 UTC y horizonte de tiempo de 72 horas.

De acuerdo con la Figura 6.19, el modelo 1 mostró un mejor desempeño para las 24 primeras horas del evento del 17-07-2019, ya que en comparación con los modelos 2 y 3, éste no predijo falsas alarmas. Aun así, los tres modelos fallaron en pronosticar la lluvia en la zona 10 para las 48 horas; mientras que, para las 72 horas, todos los modelos predijeron adecuadamente los correctos negativos. Por último, para el evento del 09-09-2019 (Figura 6.20), el comportamiento de los modelos es muy similar, ya que nuevamente, existe una zona (zona 7), en donde no se logró predecir el evento para las 48 horas.

Con base en el análisis de resultados anteriores, se encontró que, por lo general, el modelo 1 presenta un mejor desempeño en comparación con los otros dos, esto podría resultar evidente ya que al estar generado a partir de la información histórica de los datos del OH-IIUNAM, se ajusta mejor a los eventos observados por el mismo observatorio; ahora bien, existen zonas donde el modelo 2 se comporta mejor, por ejemplo en las zonas 8 y 9 en el horizonte de tiempo de 48 horas del 28-05-2017 (ver Figura 6.11), o bien para las zonas de pronóstico 13 y 14 en las primeras 24 horas del 04-08-2018 (ver Figura 6.15). Lo mismo sucede para el Modelo 3, el cual tiene mejor desempeño para todas las zonas de pronóstico en las primeras 24 horas del 30-08-2017 (ver Figura 6.12), en comparación con los resultados del Modelo 1. Entonces, para obtener un valor que permitirá establecer cuál de los tres modelos es mejor, se aplicaron las métricas de la Tabla 4-7. Los resultados de las distintas métricas de verificación se presentan a continuación:

Tabla 6-2. Medidas de desempeño de los modelos predictivos

Medida de desempeño	Modelo		
	1	2	3
BIAS	0.88	1.30	1.38
F	0.12	0.27	0.27
FAR	0.46	0.67	0.65
PC	0.79	0.65	0.68
HSS	0.38	0.14	0.19
CSI	0.34	0.23	0.25

De acuerdo con la tabla anterior el modelo número 1 obtuvo el mejor desempeño, ya que presenta un menor índice de falsas alarmas ( $F = 0.12$ ) así como una mayor precisión del pronóstico con  $PC = 0.79$ , lo que significa que aproximadamente 4/5 eventos de lluvia



observados son correctamente pronosticados. Sin embargo, la Probabilidad de Falsa Alarma (FAR = 0.46) indica que cerca de 3/7 eventos pronosticados, no se observó el evento.

## 6.4. Pronóstico probabilista de inundaciones en CDMX

### 6.4.1. Evaluación preliminar del modelo CADDIES-caflood

La idea del modelo CA (Autómata Celular) no es reemplazar la complejidad de los modelos basados en la física, sino alcanzar el mejor desempeño manteniendo la precisión del análisis de flujos de inundación para aplicaciones a gran escala. Por ejemplo; en la Figura 6.21 se presenta una comparación del modelo simplificado de las ecuaciones de aguas someras LISFLOOD-FP contra el modelo autómatas celular WCA2D, que es parte del proyecto CADDIES-caflood (Cellular Automata Dual DrainagE Simulation, Michele Guidolin et al., 2016).

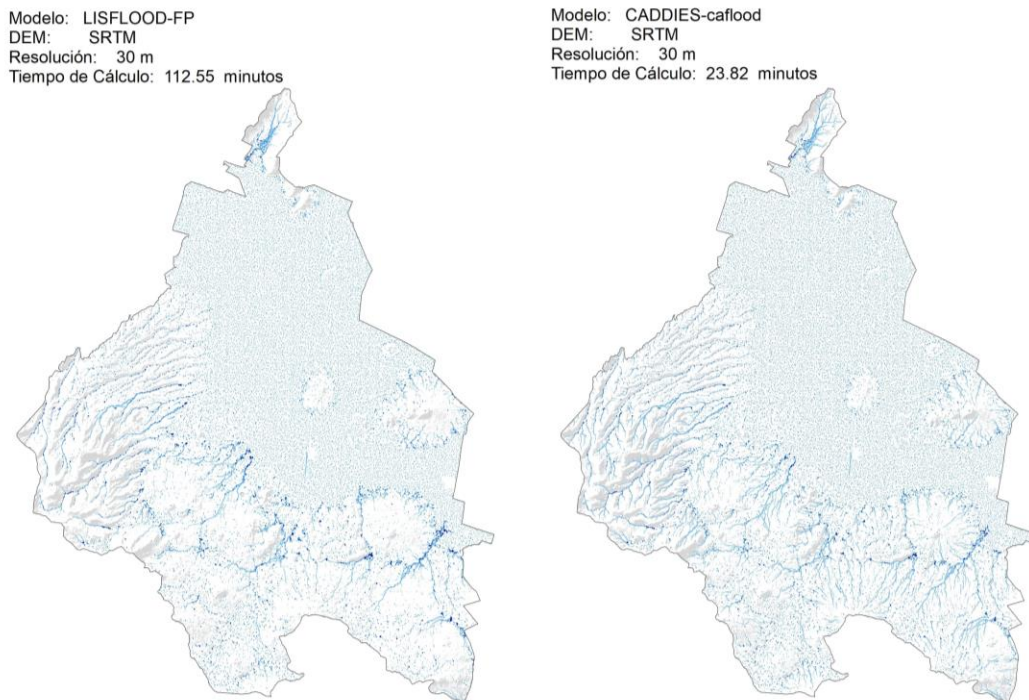


Figura 6.21. Comparación de los resultados del modelo LISFLOOD-FP vs CADDIES-caflood.

El evento simulado corresponde a la lluvia registrada por la estación CCHOTE del Observatorio Hidrológico del Instituto de Ingeniería de la UNAM (OH-IIUNAM) con fecha del 27/08/2018 12:00 pm al 28/08/2018 11:00 am. Dominio de cálculo con 2.8 millones de celdas.

Para el evento analizado, los resultados son prácticamente iguales. La mayor diferencia se ve reflejada en los tiempos de cálculo, ya que CADDIES-caflood (WCA2D) presenta una reducción de aproximadamente un 80% en los tiempos de cálculo, comparado con el modelo LISFLOOD-FP (ver Tabla 6-3). Adicionalmente, otra ventaja del modelo CADDIES-caflood es que permite simular lluvia espacialmente variada en el dominio de cálculo.

Para estudiar el desempeño del modelo CADDIES-caflood, se llevaron a cabo 8 simulaciones para el evento del 27 de agosto de 2018 (ver Figura 6.22), y los modelos digitales de elevación descritos en la Tabla 4-8. Estas simulaciones permitieron comparar el desempeño de los tiempos de cálculo de CADDIES-caflood contra el modelo LISFLOOD-FP. Adicionalmente, esta comparación permitió elegir qué modelo de elevación reproduce de forma más precisa los flujos de inundación en CDMX. Los resultados se presentan en la Figura 6.23.

El lunes 27 de agosto de 2018, las lluvias generadas por la Onda Tropical Número 32, causaron graves afectaciones al oriente de la Ciudad de México. De acuerdo con el Centro de Comando, Control, Cómputo, Comunicaciones y Contacto Ciudadano (C5), Iztapalapa fue la zona más afectada por inundaciones en la Calzada Ignacio Zaragoza (METRÓPOLI, 2018b), y puntos anegados en la colonia Juan Escutia, a la altura del deportivo Balvanera (Gómez Flores, 2018).




Figura 6.22. Hietograma del evento del 27-08-2018 registrado por la estación CCHOTE del OH-IUNAM. Inundación sobre Calz. Ignacio Zaragoza en dirección al Pte. desde República Federal hasta Guelatao (@C5\_CDMX)

Para la evaluación de los modelos digitales de elevación, se realizó un pre procesamiento con el objetivo de eliminar el ruido y definir los cauces existentes. Para cada uno de los 4 modelos, primero se aplicó un relleno de inconsistencias mediante una instrucción fill sinks, seguido por una corrección para eliminar pozos y por último un dragado digital de los escurrimientos (Stream Burning); mediante las herramientas “TopotoolBox” (Schwanghart & Kuhn, 2010).

Como se aprecia en los mapas de la Figura 6.23, los resultados obtenidos entre los modelos LISFLOOD y CADDIES-caflood son prácticamente iguales; sin embargo, los tiempos de cálculo mostrados en la Tabla 6-3, establecen que CADDIES-caflood tiene mejor desempeño, con tiempos de cálculo menores a 1 hora.

Los menores tiempos de cálculo se obtienen al utilizar la información de elevación del SRTM. No obstante, estos resultados carecen de precisión (Mapas 1 y 2 de la Figura 6.23); ya que presentan mucho ruido y no reproducen las manchas de inundación adecuadamente (p.ej. no se produce la inundación en la Calzada I. Zaragoza).

Los resultados obtenidos con el modelo AW3D son mejores en comparación con el SRTM, esto puede deberse a que, al ser un modelo de superficie, AW3D puede representar las calles y avenidas. Aun así, el modelo AW3D, presentó bastante ruido en los resultados.

Otra explicación del mal desempeño de los modelos SRTM y AW3D, es que utilizan un pixel de variable entera. Esto puede ocasionar una mala precisión en los resultados.

En comparación con los modelos de elevación anteriores, la información LiDAR de terreno sí logra reproducir la inundación en la zona de la Calzada I. Zaragoza (a la altura del deportivo Balvanera), y coincide con los reportes del C5. La mancha de inundación puede parecer un poco exagerada, pero esto es debido a que se consideró lluvia constante en el espacio.

Por último, los resultados con la información LiDAR de superficie no fueron satisfactorios. Este tipo de datos contiene mucho ruido (edificios, autos, vegetación, estructuras, etc.); por lo que los flujos de inundación se alteran demasiado y no es una opción viable para la modelación.

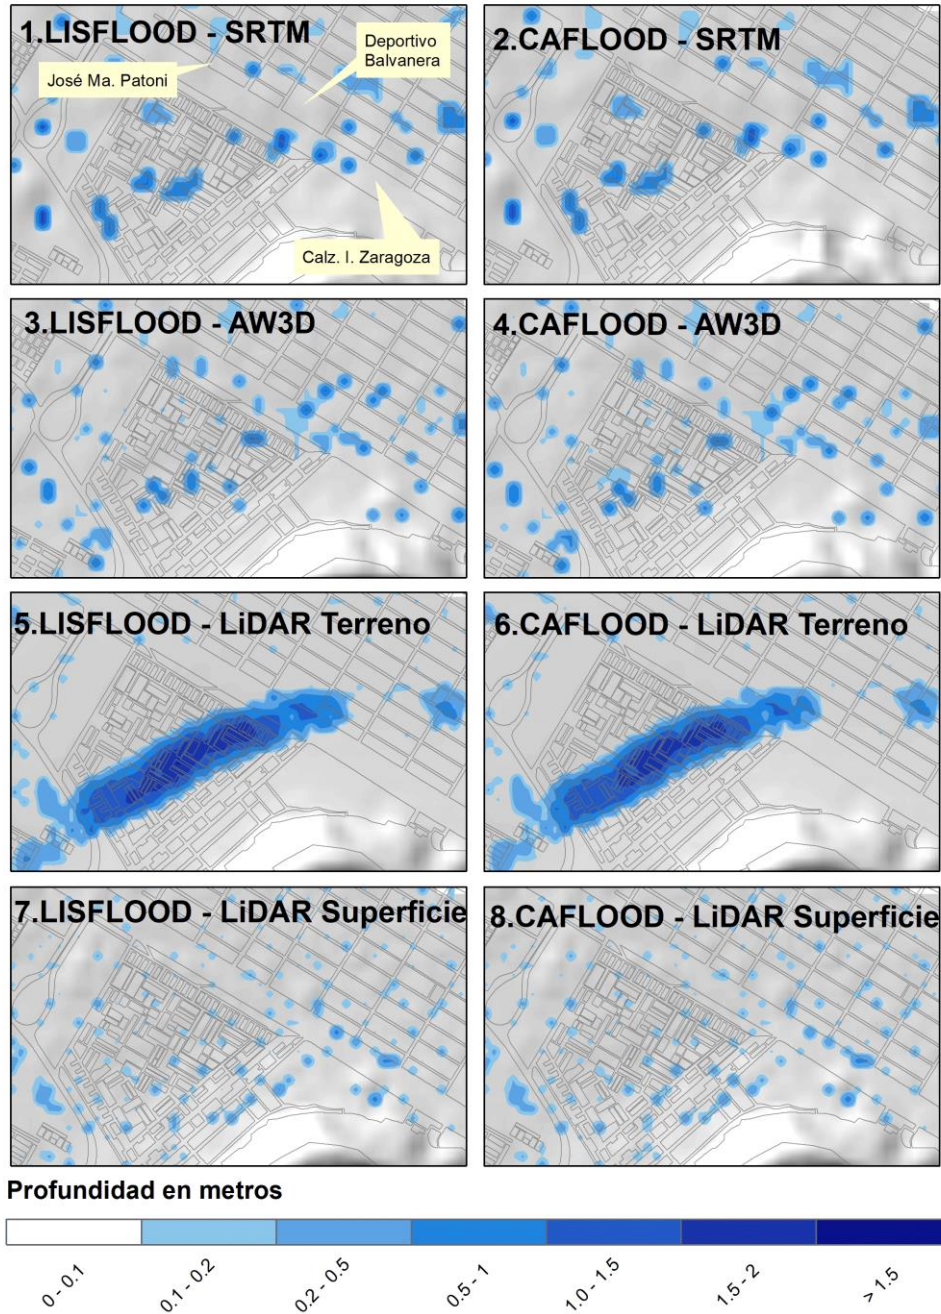


Figura 6.23. Comparación de CAFLOOD vs LISFLOOD para evento de del 27-08-2018. Zona de Calzada Ignacio Zaragoza.

Resultados para los modelos digitales de elevación: SRTM (Shuttle Radar Topography Mission), AW3D (ALOS 3D World Japan Aerospace Exploration Agency's) y LiDAR (Light Detection and Ranging) con resolución de 30 metros y considerando lluvia constante en el espacio. El evento simulado corresponde a la lluvia registrada por la estación CCHOTE del Observatorio Hidrológico del Instituto de Ingeniería de la UNAM (OH-IIUNAM) con fecha del 27/08/2018 12:00 pm al 28/08/2018 11:00 am, con resolución temporal de 1 hora.

Tabla 6-3. Resultados de tiempos de cálculo para los modelos de inundación LISFLOOD y CAFLOOD con información de elevación de SRTM, ALOS y LiDAR.

No.	Modelo 2D	Esquema de cálculo	DEM	Tiempo de cálculo* (min)
1	LISFLOOD-FP	Acceleration	SRTM raw	112.55
2	CAFLOOD	WCA2D-Openmp	SRTM raw	23.82
3	LISFLOOD-FP	Acceleration	ALOS raw	116.82
4	CAFLOOD	WCA2D-Openmp	ALOS raw	33.5
5	LISFLOOD-FP	Acceleration	LiDAR Terreno resample	113.97
6	CAFLOOD	WCA2D-Openmp	LiDAR Terreno resample	39.75
7	LISFLOOD-FP	Acceleration	LiDAR Superficie resample	127.3
8	CAFLOOD	Acceleration	LiDAR Superficie resample	28.8

\*Las simulaciones fueron llevadas a cabo utilizando un equipo Windows 10 Home 64 bits, Intel® Core™ i5-10210U CPU @ 1.60 GHz (8CPUs), ~2.1 GHz, y 8 G de memoria RAM.

### 6.4.2. Pronóstico y generación de mapas probabilistas de inundación

La evaluación del pronóstico probabilista de inundaciones en CDMX y los mapas de probabilidad generados a partir del modelo CA, se aplicaron a 3 eventos de inundación en CDMX: 28-06-2017, 05-09-2017 y 27-08-2018.

Para considerar la sí ocurrencia de una inundación se utilizó el umbral de tirante de 20 cm de acuerdo con lo establecido por Reinoso et al., (2012).

#### Evento del 28-08-2017

La tormenta que afectó en la tarde del 28-06-2017 al poniente de la Ciudad de México obligó a las autoridades del Sistema de Transporte Colectivo Metro a cerrar 9 de las 14 estaciones de la línea 7. Adicionalmente, se presentaron afectaciones en vialidades

principales de la ciudad como Ejército Nacional, Reforma, Circuito Interior y Constituyentes. Se presentó una concentración de agua de 7500 millones de litros de agua en la Alcaldía Miguel Hidalgo (ver Figura 6.24), alcanzando una precipitación acumulada de 54 mm en la zona (Evento correspondiente a un  $Tr = 5$  años). La afectación vial fue muy severa con 10 puntos de encharcamiento sobre circuito interior y reforma; por lo que la movilidad de la zona se vio colapsada (Aristegui, 2017).

El mapa de la Figura 6.27 presenta el mapa probabilista de inundación para este evento, y muestra un acercamiento en el cruce de Circuito Interior y Reforma, la cual fue una de las zonas más afectadas; y con un alto de riesgo de inundaciones. Los resultados corresponden a la simulación del evento con tiempo base de las 12 UTC y fecha de inicio del 27-06-2017 para un horizonte de pronóstico de 48 horas.



Figura 6.24. Afectaciones del evento del 28-06-2017.

a) Estación Metro Cuatro Caminos; b) Mazarik esquina con Horacio; c) Polanco (J. López, 2017)

La Figura 6.27a muestra los resultados de los escenarios simulación del evento con tiempo base de las 12 UTC y fecha de inicio del 27-06-2017. Se observa que la zona de inundación sí coincide con el evento observado y con el reporte de incidentes de Protección Civil. Para las primeras 24 horas de pronóstico, se indica una probabilidad mayor al 20% de exceder los 20 cm de tirante. Por otro lado, la Figura 6.27b muestra los resultados para un horizonte de pronóstico de 48 horas, indicando que las probabilidades de inundación son menores ( $P < 20\%$ ) para la fecha en que se observó el evento. Esto significa que a pesar de que se logran reproducir los flujos de inundación, estos son menos precisos.

Por último, en la Figura 6.27c se observan los resultados del pronóstico con tiempo base del 28-06-2017 12UTC, y demuestra que el evento se logra identificar con probabilidades mayores al 20% de exceder un tirante de 20 cm. Esta comparación corrobora que las primeras horas del pronóstico son las más precisas.

### **Evento del 06-09-2017**

Para el evento del 06-09-2017 se presentaron afectaciones por fuertes lluvias en la zona sur de la Ciudad de México. Las mayores precipitaciones sobrepasaron los 40 mm de lluvia acumulada ( $Tr < 5$  años). La Secretaria de Protección Civil de la ciudad activó la alerta roja en las Alcaldías Coyoacán, Tlalpan y Xochimilco. La demarcación de Xochimilco sufrió por los efectos de los huracanes Katya, Irma y José; lo que ocasionó el desbordamiento de los ríos San Buenaventura y de Guadalupe.

Las vialidades primarias con mayores afectaciones fueron Avenida San Lorenzo, División del Norte, Periférico Sur, Viaducto Tlalpan, Insurgentes Sur, Picacho Ajusco, Glorieta de Vaqueritos, Paseo del Pedregal y Revolución (ver Figura 6.25). Mientras que el servicio de 6 estaciones de la línea 1 del Metrobus tuvo que ser suspendido.

El mapa de la Figura 6.28 presenta el mapa probabilista de inundación para este evento, y muestra un acercamiento a la zona sur de la CDMX, la cual fue una de las zonas más afectadas. De acuerdo con el Atlas de riesgo, esta zona se encuentra dentro un riesgo muy alto de sufrir inundaciones. Los mapas muestran que las predicciones de las zonas

inundadas sí coinciden con el evento observado y con los incidentes reportados a Protección Civil.



Figura 6.25. Afectaciones del evento del 06-09-2017.

a) Zona Tlalpan e Insurgentes; b) Calzada Acoxta; c) Cierre de estación de Metrobús (El Sol de Mexico, 2017).

Los resultados de la Figura 6.28a corresponden a la simulación del evento con tiempo base de las 12 UTC y fecha de inicio del 05-09-2017 (día anterior al evento). En estas primeras 24 horas, se predicen inundaciones sobre Calzada Acoxta y la Lateral de Periférico, a la altura de Glorieta de Vaqueritos con una probabilidad de ocurrencia del evento menor al 20%.

Para el pronóstico de 48 horas (día del evento 06-09-2017, Figura 6.28b) se observa un incremento en los niveles y manchas de inundación con probabilidades de ocurrencia mayores al 60% de exceder los 20 cm; en zonas correspondientes con las del evento observado en dicha fecha. En este caso se resaltan las altas probabilidades de inundación en la zona de Vaqueritos, Acoxta, la Lateral de Periférico y Viaducto Tlalpan.

Por último, La Figura 6.28c muestra los resultados del pronóstico con tiempo base de 06-09-2017 12UTC (día del evento), y demuestra nuevamente las probabilidades de ocurrencia mayores al 20% en zonas correspondientes con los reportes de incidentes.



### Evento del 27-08-2018

Durante el evento del 27 de agosto de 2018, la Secretaría de Protección Civil activó la alerta naranja en las delegaciones Iztapalapa e Iztacalco, donde hubo nueve inundaciones y un deslizamiento de tierra, sin que se registraran heridos. Por esa razón se reportaron problemas viales y autos varados (Gómez Flores, 2018).

La lluvia de la tarde de este lunes generó graves problemas viales y retrasos en el servicio de la línea A del Metro, con dirección a La Paz, así como varios automóviles varados, por lo que brigadistas de la Agencia de Gestión Urbana, de la Secretaría de Protección Civil y del Cuerpo de Bomberos laboraron en esos puntos por varias horas.

De acuerdo con el C5, los puntos anegados fueron en calzada Ignacio Zaragoza, en la colonia Juan Escutia, a la altura del deportivo Balvanera (puntos ubicados en la zona de mayor riesgo de inundaciones). También carriles centrales y laterales de esa calzada, en dirección al oriente, se inundaron en la zona de la unidad habitacional Ejército Constitucionalista; lo mismo ocurrió en la avenida Texcoco y en varias colonias de Nezahualcóyotl. En la zona de calzada Ignacio Zaragoza, la precipitación sobrepasó los 20 mm de lluvia acumulada ( $Tr < 2$  años).



Figura 6.26. Afectaciones del evento del 27-08-2018.

a) Calzada Ignacio Zaragoza a la altura del Peñón; b) Gral. Antonio de León y Súper Manzana 1, Col. U.H. Ejército Constitucionalista, Iztapalapa; c) Zaragoza antes del puente Guelatao, carril lateral inundado.

Los resultados de la Figura 6.29a corresponden a la simulación del evento con tiempo base de las 12 UTC y fecha de inicio del 26-08-2018. En estas primeras 24 horas de pronóstico, se observa que la probabilidad de inundación sobre avenida Guelatao es menor al 20 %, incluso no se presenta una mancha de inundación extensa. Esto coincide con el evento, y que la inundación no se presentó, sino hasta la tarde del 27.

Al analizar el pronóstico de 48 horas (Figura 6.29b), se observa que la mancha y los flujos de inundación se reproducen adecuadamente, con una probabilidad mayor al 20 % de alcanzar un tirante de 20 cm. Lo importante, es que el modelo logra identificar adecuadamente, la zona y día exacto del evento.

En la Figura 6.29c se muestra nuevamente el pronóstico pero con un tiempo base del 26-08-2018 12 UTC. En este caso, la evidencia nuevamente revela que las primeras horas de pronóstico son las más confiables, debido a que se predice correctamente la zona inundada, y que corresponde adecuadamente con el reporte de incidente a protección civil.

Por último, en la tabla siguiente se muestran algunos ejemplos de los tiempos de cálculo necesarios para la simulación de los 27 escenarios, correspondientes de los eventos de estudiados en los mapas de las Figura 6.27 - Figura 6.29.

Tabla 6-4. Tiempos de cálculo para los eventos de estudio y generación de mapas probabilistas de inundación.

<b>Evento</b>	<b>Duración del evento horas</b>	<b>Resolución del DEM</b>	<b>Cajas de lluvia simuladas</b>	<b>Tiempo de cálculo horas</b>
28-06-2017	24	30	6	1.6
05-09-2017	24	15	1	12
06-09-2017	24	30	7	4.5
05-09-2017	24	15	2	10.6
26-08-2018	24	30	6	1

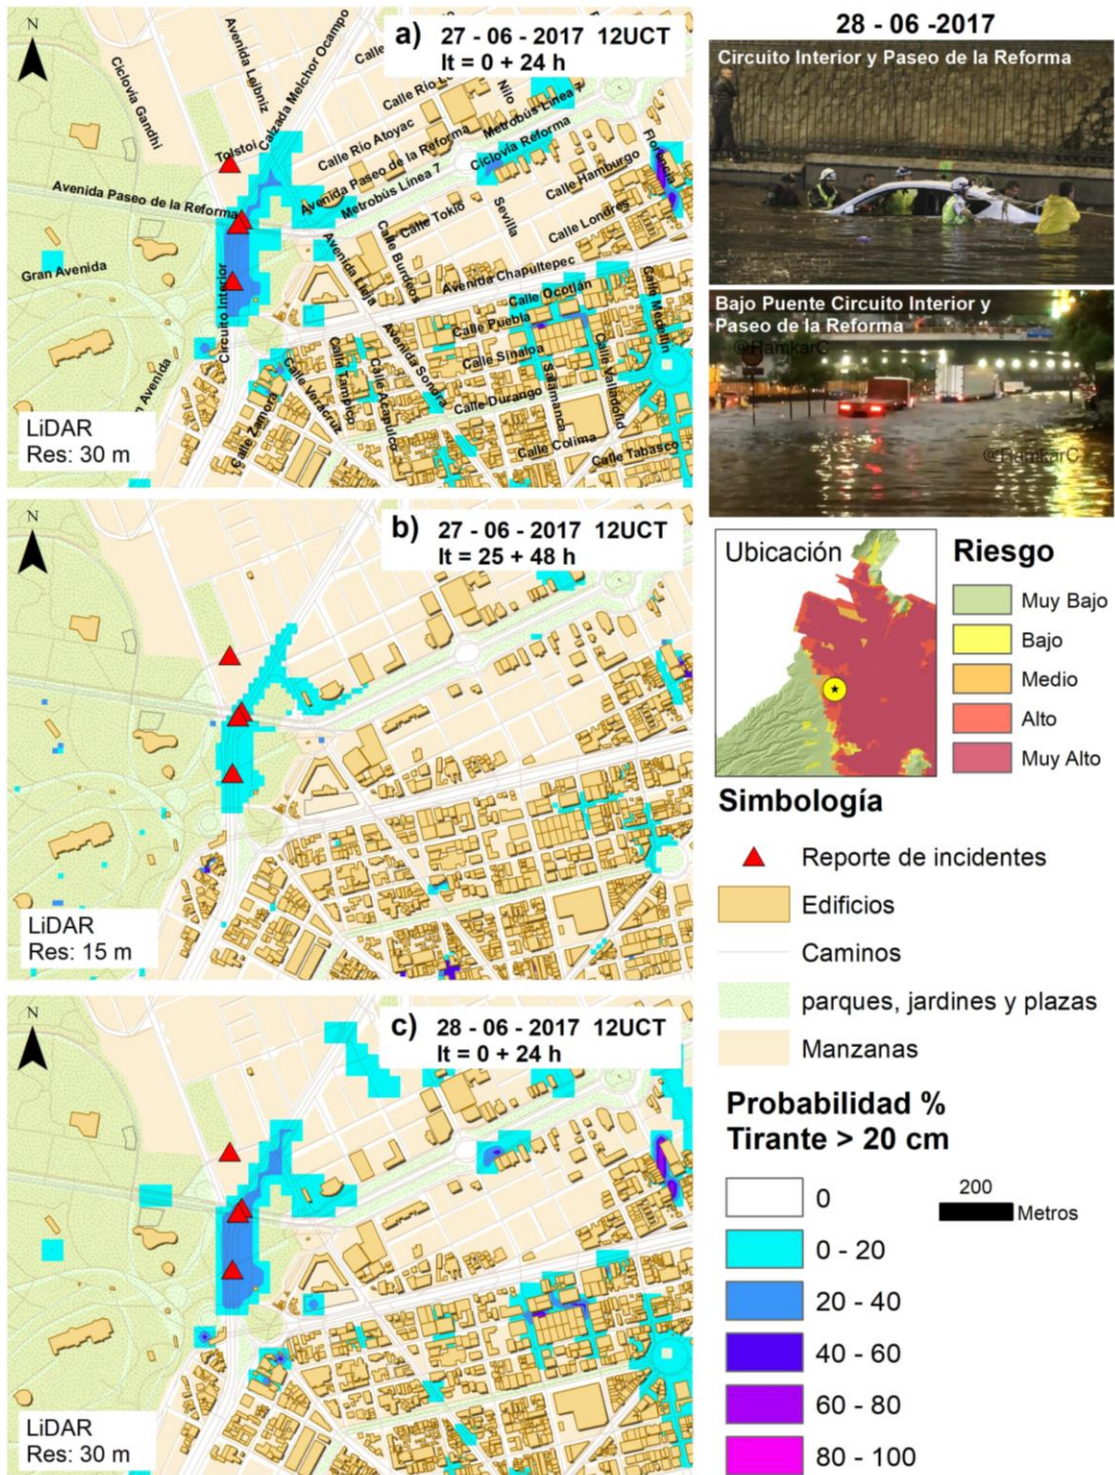


Figura 6.27. Mapas probabilistas de inundación pluvial en la zona de circuito interior y Reforma.

Figuras **a** y **b** con tiempo base del 27-06-2017 12 UTC. Figura **c** con tiempo base del 28-06-2017 12 UTC. Las fotografías muestran las afectaciones en el cruce de Circuito Interior y Reforma.

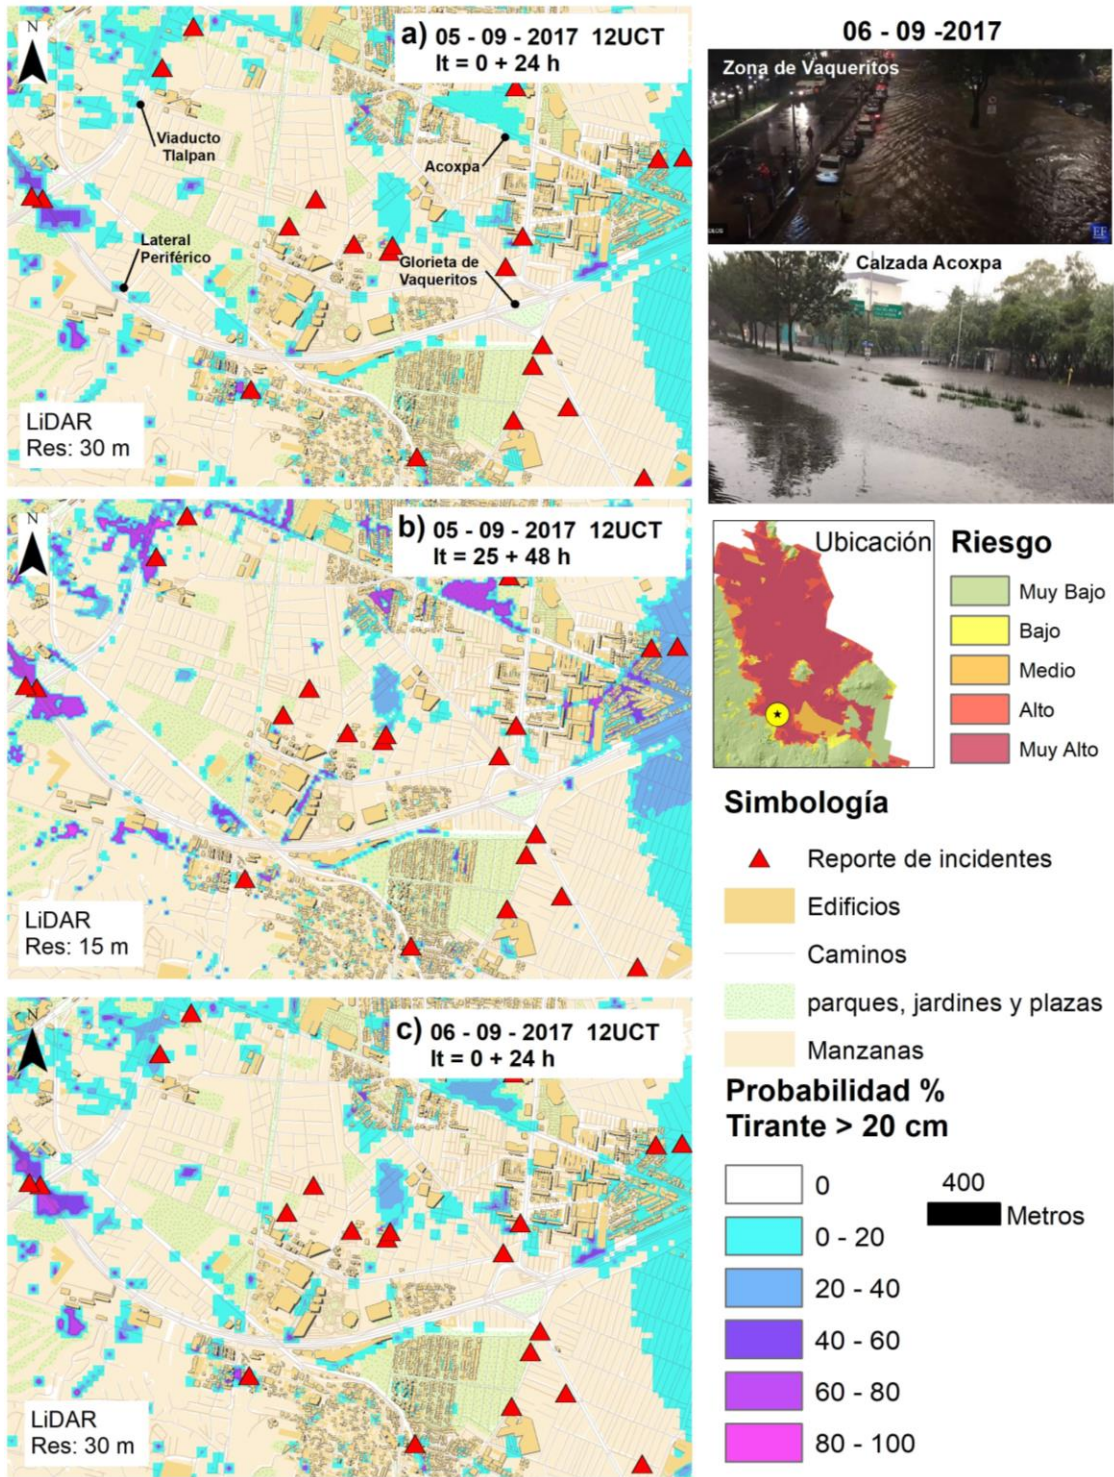


Figura 6.28. Mapas probabilistas de inundación pluvial en la zona sur de la CDMX.

Figuras **a** y **b** con tiempo base del 05-09-2017 12 UTC. Figura **c** con tiempo base del 06-09-2017 12 UTC.

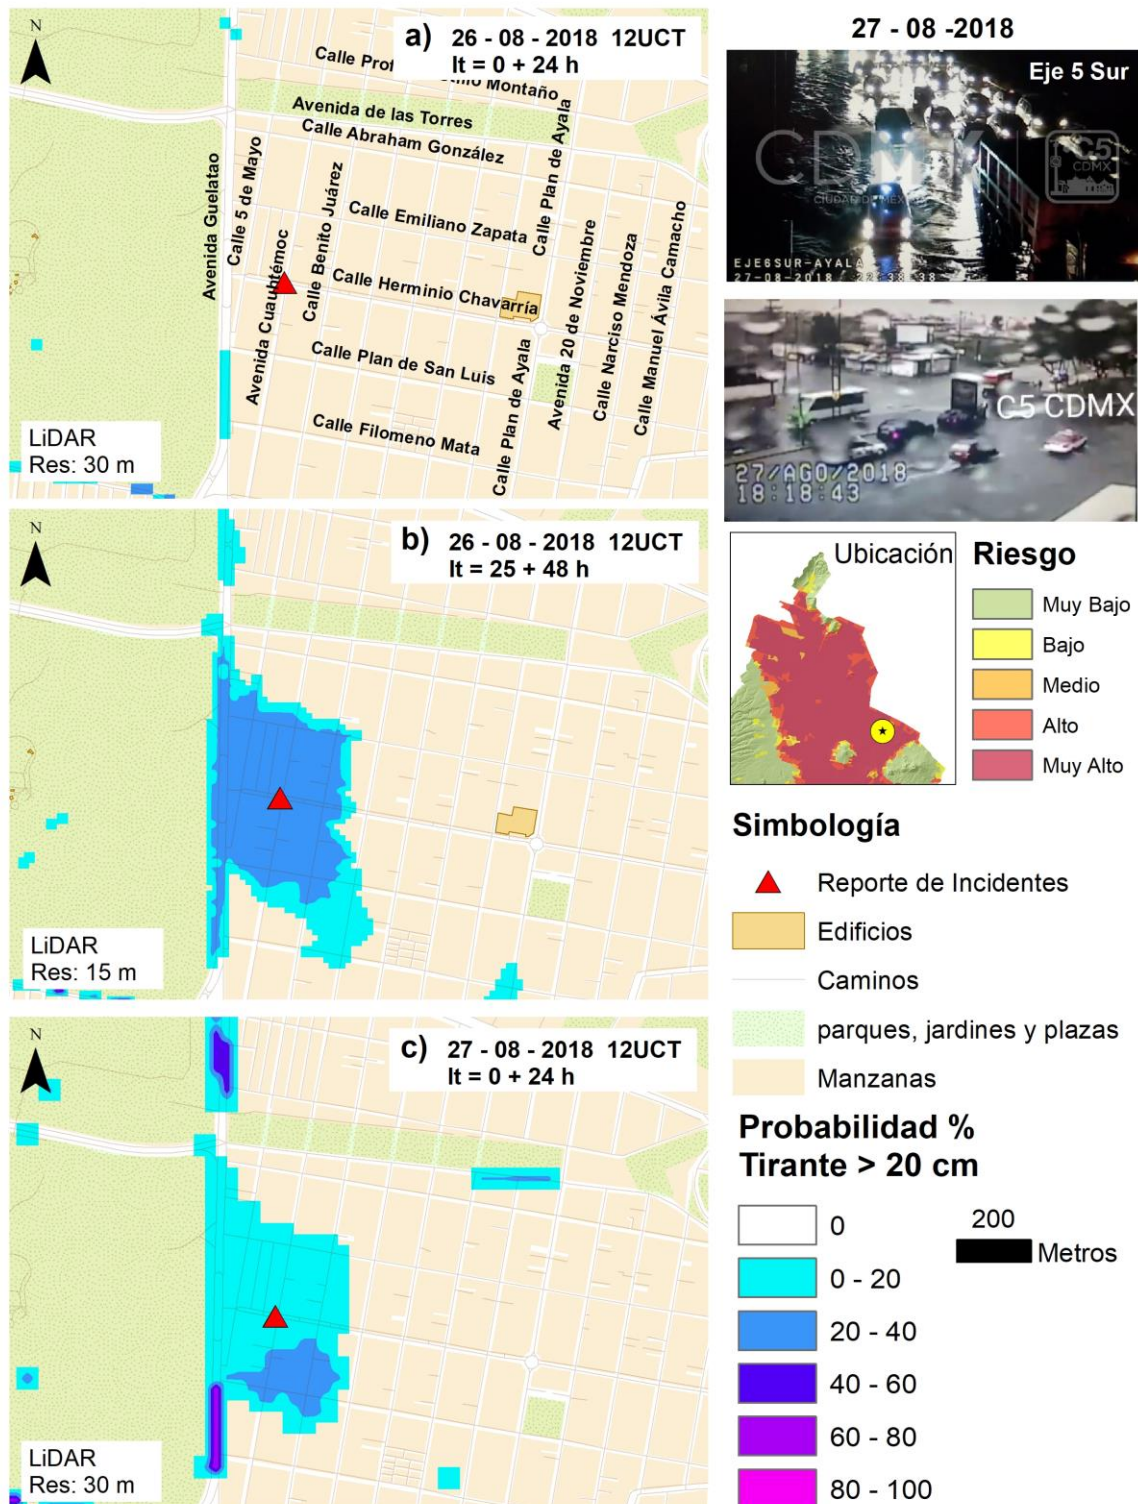


Figura 6.29. Mapas probabilistas de inundación pluvial en la zona oriente de la CDMX.

Figuras a y b con tiempo base del 26-08-2018 12 UTC. Figura c con tiempo base del 27-08-2018 12 UTC.

### 6.4.3. Publicación de mapa WEB (ejemplo)

Para finalizar con la presentación y análisis de los resultados, la Figura 6.30 y Figura 6.31 muestran un ejemplo de un mapa WEB, que muestra las manchas de inundación en la ciudad con su probabilidad de ocurrencia asociada. El evento corresponde al 28 de junio de 2017, (mismo evento presentado en los mapas de la Figura 6.28). Este mapa puede visualizarse desde un ordenador o dispositivo móvil en el enlace: <https://hydrowaysmx.com/como-comunicar-el-riesgo-por-inundaciones-en-la-cdmx/>

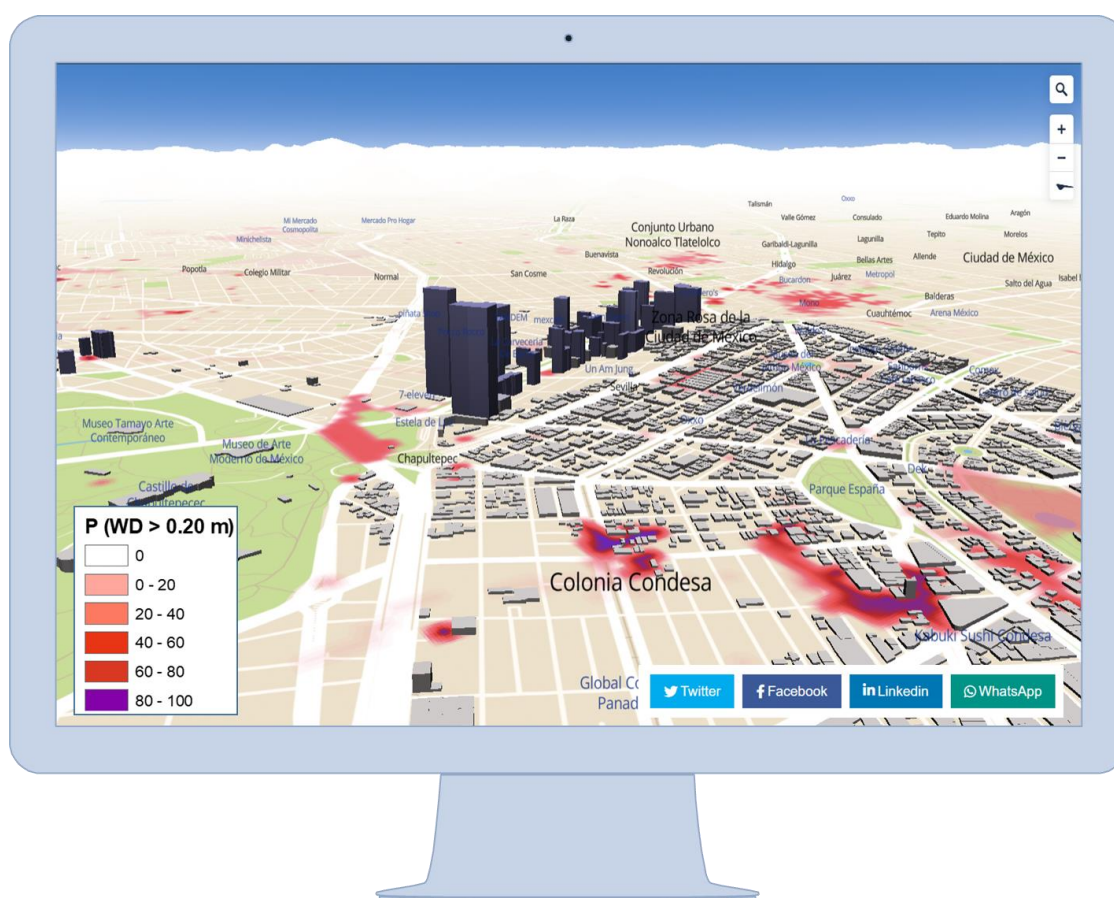


Figura 6.30. Publicación de mapa probabilista de inundaciones en CDMX. Mapas WEB con la plataforma Mapbox Studio. Versión de PC

En años recientes, y con el incremento del uso de los dispositivos móviles, se han presentado evidencias de que las redes sociales pueden ser utilizadas para desarrollar indicadores y dar seguimiento a la comunicación en tiempo real de eventos climáticos

extremos (Ripberger et al., 2014). Por estas razones, los mapas podrían servir como herramienta para comunicar la amenaza y riesgo de posibles eventos de inundación, el objetivo de hacer esta información público a partir de un medio digital permitiría cumplir con al menos de las dos primeras condiciones para una comunicación efectiva del riesgo: 1) estar expuesta a la información, 2) prestar atención a ella.

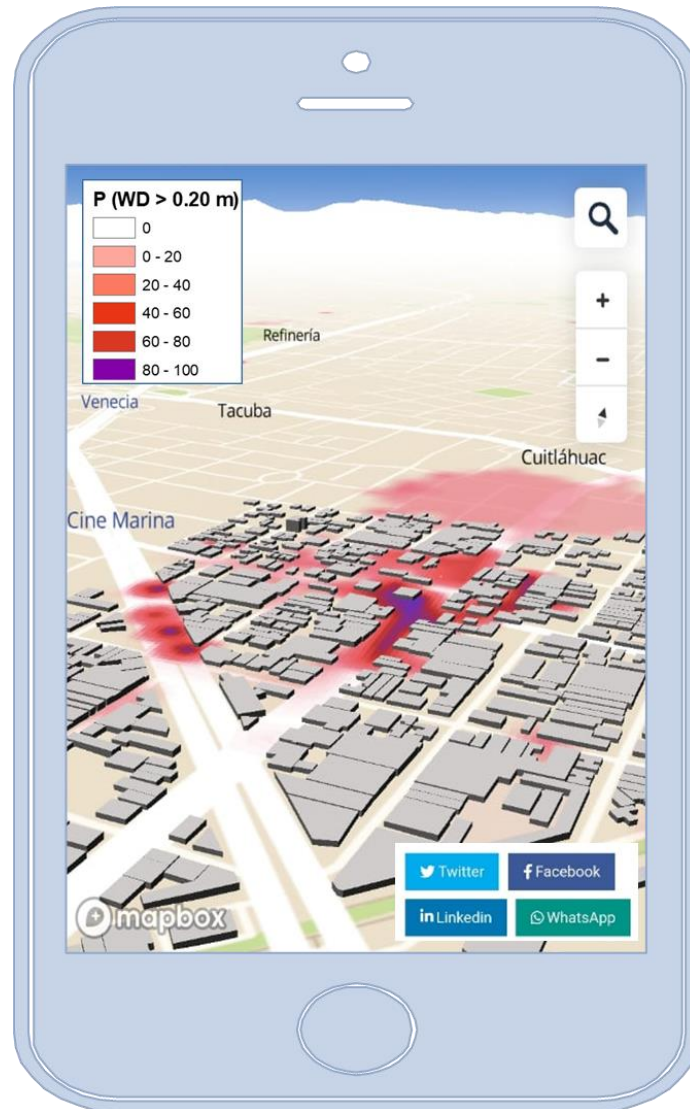


Figura 6.31. Publicación de mapa probabilista de inundaciones en CDMX. Mapas WEB con la plataforma Mapbox Studio. Versión en dispositivo móvil

## Capítulo 7. Conclusiones

*“Emplear herramientas basadas en Sistemas de Predicción por Ensamblados (EPS) es esencial para afrontar los desafíos futuros; y así, generar soluciones para los tomadores de decisiones”.*

**Gouweleeuw et al., (2005)**

El propósito de esta investigación fue desarrollar una metodología de Pronóstico Probabilista de Inundaciones en la Ciudad de México, a partir de los ensambles meteorológicos emitidos por el Centro Europeo para la Predicción de Clima de Plazo Medio (ECMWF).

Para investigar el potencial del Sistema de Predicción por Ensamblados como herramienta para el pronóstico de inundaciones pluviales urbanas se plantearon las siguientes preguntas de investigación: 1) qué tan bien se corresponden los pronósticos del ECMWF con la precipitación observada en el Valle de México; 2) cuál es la precisión y confiabilidad de los pronósticos, y 3) si su resolución es suficiente para la predicción de inundaciones en la Ciudad de México.

Para dar respuesta a las primeras dos preguntas de investigación, el análisis preliminar de los productos **EMEAN** (Media de los Ensamblados) y **HRES**; llevado a cabo en la Cuenca del Valle de México, evidenció mayor incertidumbre y errores del pronóstico durante la temporada de lluvias (MJASON). Las métricas: POD, FAR, HSS, PC, POFD y TS indicaron mayor confiabilidad ambos productos (HRES y EMEAN) para eventos en el



rango de 2 a 10 milímetros de precipitación acumulada en 24 horas (ver Figura 6.3). De forma general, **EMEAN** mostró un mejor rendimiento en comparación con **HRES**. Lo anterior significa que utilizar la media de los ensambles puede ser una mejor opción cuando se desea emitir un pronóstico determinista. En resumen, los pronósticos deterministas corresponden de forma adecuada con las observaciones dentro de la Cuenca del Valle de México para umbrales de lluvia en el rango de 2 a 10 mm en 24 horas.

A la luz de los resultados preliminares obtenidos, se reveló la necesaria participación de un pronóstico que sea representativo de la distribución de probabilidad de los estados futuros de la atmósfera y; por lo tanto, que sea capaz de identificar la ocurrencia de eventos extremos. En este sentido, la verificación probabilista del producto ENS (Ensamblados de Pronóstico) reveló mayor dispersión en las zonas altas de la Cuenca del Valle de México. Por otro lado, las curvas ROC (Figura 6.8) prueban que el modelo predictivo tiene un muy buen desempeño; con un área bajo la curva aproximada de 0.85, para la discriminación de eventos de 5, 10 y 20 mm acumulados en 24 horas. De acuerdo con estos resultados, se podría afirmar que los ensambles tienen buena calidad, precisión y desempeño para los umbrales de lluvia analizados. Lo anterior no significa que el pronóstico sea malo para umbrales de mayor magnitud, sin embargo, será necesario recopilar más datos que permitan obtener resultados confiables (representativos de la muestra) para eventos de lluvia mayores.

Para contestar a la pregunta de investigación número 3, el análisis visual de los eventos aislados en el capítulo 6.3 demostró que los ensambles son representativos del evento observado en todas las celdas del dominio de estudio; y a pesar de su resolución, son una herramienta muy útil para el análisis probabilista de la ocurrencia de un evento. Complementando lo anterior, el meteograma promedio en la CDMX (ver Figura 6.7) evidenció que el ensamble constituye una buena representación de los posibles escenarios de la atmósfera a lo largo del horizonte temporal. Como resultado, el evento observado no es estadísticamente diferente de ningún otro miembro del ensamble. A pesar de esto, las primeras 36 horas del pronóstico resultaron ser las más confiables; ya que después de ese tiempo, la incertidumbre aumenta.

En otro orden de cosas, los ensambles revelaron una buena confiabilidad para umbrales de 5 a 20 milímetros de lluvia acumulada en 24 horas y lograron representar adecuadamente la media y el percentil 95 de la lluvia acumulada cada 6 horas para un horizonte de tiempo de 90 horas (ver Figura 6.8). Adicionalmente, el modelo de regresión logística se desempeñó satisfactoriamente con áreas bajo las curvas ROC (auc) de 0.85 y 0.72 para la Cuenca del Valle de México y Ciudad de México, respectivamente (ver Figura 6.5 y Figura 6.8).

De acuerdo con estos últimos resultados, se puede afirmar que los ensambles sí tienen la resolución suficiente para el pronóstico de la lluvia en la Ciudad de México y buena confiabilidad para un horizonte de hasta 36 horas. En cuanto a la construcción del modelo predictivo, se encontró que los mejores resultados se presentaron para el modelo alimentado con la información histórica del OH-IIUNAM (Modelo 1), con una buena confiabilidad y discriminación de eventos, así como mejores resultados de las métricas de desempeño POD, FAR, HSS, PC, POFD y TS (ver Tabla 6-2). Estos hallazgos mostraron que los modelos basados en datos, pueden ser fundamentales para la implementación de una herramienta de alerta y toma de decisiones; sobre todo en las primeras etapas de diseño del Sistema de Alerta. Así mismo; derivado de la creación del modelo predictivo, se logró reducir el número de los miembros del ensamble a 27 miembros representativos; lo cual permitió optimizar los tiempos de cálculo y por ende obtener resultados de pronóstico en el menor tiempo posible.

Como parte del proceso de emergencia, los resultados revelaron que el modelo Autómata Celular; en combinación con la información LiDAR de terreno, permite estimar de manera confiable las zonas que son susceptibles a inundaciones en la Ciudad de México. Del mismo modo, los mapas de inundación ayudan a conocer y comunicar el pronóstico; con al menos 24 horas de antelación, lo que puede brindar información primordial en zonas de interés; así como a dar seguimiento a la evolución del evento; lo cual es de suma importancia para llevar a cabo acciones preventivas.

Con base en el umbral de alerta (si  $P(10 \text{ mm}/24\text{h}) > 30\%$ ), se dio inicio a las simulaciones con el modelo Autómata Celular (WCA2D). La opción del modelo para habilitación de cajas de lluvia (dominio expandible); posibilitó llevar a cabo el cálculo de

los escenarios en el menor tiempo posible. Esto tiene un gran alcance, ya que un escenario de pronóstico oportuno y basado en la incertidumbre, promueve una mejor toma de decisiones, así como una gestión efectiva ante la ocurrencia de desastres naturales.

Finalmente, se estableció que la comunicación del riesgo a través de mapas probabilistas de inundación, puede llevarse a cabo a través de una plataforma WEB. Los mapas son una opción adecuada que puede ayudar a los usuarios a consultar el pronóstico de acuerdo a su ubicación geográfica específica; lo que contribuye a solucionar necesidades particulares en la toma de acciones preventivas.

Con esto último se da cumplimiento a la hipótesis de este trabajo, haciendo posible la predicción probabilista de inundaciones en la Ciudad, mediante la integración una arquitectura estándar de pronóstico; conformada por datos observados, ensambles meteorológicos del ECMWF y un modelo Autómata Celular para la simulación de flujos de inundación.

Por otro lado, a pesar del uso de metodologías más recientes, que son resultado del crecimiento del poder de cómputo, existe una resistencia al uso de estos datos; y al empleo de nuevas metodologías (Rayner et al., 2005). No obstante, los conocimientos obtenidos de este estudio pueden ser de ayuda para motivar al uso de productos de pronóstico para la implementación de Sistemas de Alerta de Inundaciones a nivel local, ya que una de sus mayores ventajas es la ayuda que ofrecen para la toma de decisiones utilizando datos limitados y fáciles de usar.

Este estudio contribuye al entendimiento y aplicación de Sistemas de Predicción por Ensamblados para dar solución y evaluación de inundaciones urbanas de origen pluvial a nivel local. Este enfoque resultará útil para ampliar nuestra comprensión de eventos extremos de precipitación; sus impactos posibles futuros, y los riesgos asociados. Esta nueva comprensión debería ayudar a mejorar la gestión y control de amenazas meteorológicas, así como una mejor comunicación del riesgo a la sociedad y llevar a cabo acciones de protección civil de forma oportuna.

Los puntos fuertes de este estudio son la verificación de pronósticos a partir de datos de lluvia observada en tiempo real y de alta resolución; la evaluación de pronósticos para un horizonte de 72 horas y la creación preliminar de un sistema estándar de pronóstico de

inundaciones para la Ciudad de México. Esto permitió establecer el rango de tiempo más confiable de los pronósticos para el área de estudio. Además, los hallazgos brindan evidencia adicional de la confiabilidad y precisión de los ensambles a una resolución temporal de 6 horas; que pueden ser de ayuda para el análisis de inundaciones súbitas, y dar apoyo a los servicios de protección civil, permitiéndoles atender aquellas zonas vulnerables con suficiente antelación.

Con respecto a los métodos de investigación, es necesario reconocer algunas limitaciones: los datos observados fueron considerados como verdaderos; pero hay que tener en cuenta que los diferentes aparatos de medición también presentan cierto grado de error. Si bien el proceso de verificación se puede replicar, tener datos observados en tiempo real puede ser una limitación para la verificación de pronósticos a resoluciones temporales menores (tiempo < 12 h). Adicionalmente, la resolución del producto de pronóstico juega un papel importante, y el impacto de este factor en los resultados puede variar en función del área de la zona de estudio. Finalmente, ningún sistema de pronóstico puede lograr resultados perfectos y como indica Murphy (1993), el proceso de pronóstico culmina en la formulación de juicios por parte del pronosticador o del usuario sobre la ocurrencia o no de un evento de interés.

Es conveniente que la elección de los umbrales se establezca con el cuidado necesario para evitar posibles falsas alarmas o imprevistos que inevitablemente tendrían repercusiones sociales y económicas (Siccardi et al., 2005). Además, es recomendable hacer un uso combinado del producto HRES y ENS; ya que los pronósticos no probabilistas no logran identificar amenazas. Se debe considerar a los ensambles como un valor adicional al pronóstico determinista, y utilizar ambos productos para la toma de decisiones; por ejemplo, considerando al pronóstico determinista como otro miembro más del ensamble meteorológico (Gouweleeuw et al., 2005).

En cuanto futuras líneas de investigación, un estudio adicional podría evaluar y determinar los umbrales de lluvia apropiados para emisión de alertas; así como la probabilidad asociada a la ocurrencia de un evento para la toma de decisiones. Un mayor enfoque en el uso de modelos predictivos podría revelar hallazgos interesantes que ayuden a mejorar las probabilidades del ensamble o, en su caso, calibrar dichas probabilidades. De

igual manera, será importante explorar el uso del Sistema de Predicción por Ensamblajes para escalas de tiempo más pequeñas (por ejemplo, 1 hora); que permitan una mejor comunicación del riesgo; identificación de áreas más vulnerables a inundaciones y protección en zonas urbanas. Por último, también será necesario extender las variables de salida del pronóstico, por ejemplo, ligar los resultados de la probabilidad de inundación con las velocidades del flujo. Se sabe que la velocidad también es una variable importante para la evaluación del riesgo, por ejemplo, en aquellas zonas altas de la cuenca; sin embargo, un resultado probabilista de la velocidad del flujo por sí solo, no es muy útil. En este caso, en términos de comunicación de la amenaza, se considera que la velocidad se encuentra en segundo término en comparación con los tirantes de inundación, por lo que se podría explorar la opción de comunicar la velocidad del flujo de forma determinista de la siguiente manera: Si pasa A, entonces B, en donde A se define como la probabilidad de que en cierta zona se presente una inundación mayor a un umbral de profundidad definido; y B sería la velocidad de flujo correspondiente a dicho umbral (pronóstico determinista de la velocidad); así como sus posibles repercusiones.

Por último, es importante mencionar que el pronóstico es una medida no estructural que contribuye al control de inundaciones; a pesar de ello, debe ir acompañada con una adecuada reglamentación del uso de suelo y vigilancia permanente de su aplicación, delimitación y reglamentación de las zonas de inundación, la aplicación de seguros contra inundaciones y la ejecución de medidas de protección física en cada casa. Para desarrollar una infraestructura adecuada y resiliente se requiere contar con una planeación adecuada del desarrollo urbano.

## Capítulo 8. Referencias

- Abdullah, A. F., Vojinovic, Z., Price, R. K., & Aziz, N. A. A. (2012). A methodology for processing raw LiDAR data to support urban flood modelling framework. *Journal of Hydroinformatics*, 14(1), 75. <https://doi.org/10.2166/hydro.2011.089>
- Adams, T. E., & Pagano, T. C. (2016). Flood Forecasting A Global Perspective. In T. E. Adams & T. C. Pagano (Eds.), *Danish Hydraulics* (Vol. 16). Elsevier. <https://doi.org/10.1038/scientificamerican0538-261>
- Alfieri, L., Burek, P., Dutra, E., Krzeminski, B., Muraro, D., Thielen, J., & Pappenberger, F. (2013). GloFAS-global ensemble streamflow forecasting and flood early warning. *Hydrology and Earth System Sciences*, 17(3), 1161–1175. <https://doi.org/10.5194/hess-17-1161-2013>
- Alfonso, L., Mukolwe, M. M., & Di Baldassarre, G. (2015). Probabilistic Flood Maps to support decision-making: Mapping the Value of Information. *Journal of the American Water Resources Association*, 5(3), 2–2. <https://doi.org/10.1002/2015WR017378>
- Amici, A. (2018). *Cfgrib : Easy and Efficient Grib File Access in Xarray* (pp. 1–30). <https://www.ecmwf.int/sites/default/files/elibrary/2018/18727-cfgrib-easy-and-efficient-grib-file-access-xarray.pdf>
- Aristegui, C. (2017). *Inundaciones por lluvias afectaron 120 viviendas en CDMX (Floods due to rains affected 120 homes in CDMX)*. <https://aristeguinoicias.com/2906/mexico/inundaciones-por-lluvias-afectaron-120-viviendas-en-cdmx-video/>
- Atger, F. (2001). Verification of intense precipitation forecasts from single models and ensemble prediction systems. *Nonlinear Processes in Geophysics, European Geosciences Union (EGU)*, 8(6), 401–4017. <https://doi.org/hal-00331059>
- Bates, P. D., & De Roo, A. P. J. (2000). A simple raster-based model for flood inundation simulation. *Journal of Hydrology*, 236(1–2), 54–77. [https://doi.org/10.1016/S0022-1694\(00\)00278-X](https://doi.org/10.1016/S0022-1694(00)00278-X)
- Bauer, P., Thorpe, A., & Brunet, G. (2015). The quiet revolution of numerical weather prediction. *Nature*, 525(7567), 47–55. <https://doi.org/10.1038/nature14956>
- Belitskaya, V. D. (2017). Un modelo de verificación de pronósticos de precipitación (A model of precipitation forecast verification). *Revista Académica de La Facultad de Ingeniería, Universidad Autónoma de Yucatán, October 2016*.
- Bresch, D. (2009). Shallow-Water Equations and Related Topics. In *Handbook of Differential Equations: Evolutionary Equations* (Vol. 5, Issue 08). Elsevier Masson SAS. [https://doi.org/10.1016/S1874-5717\(08\)00208-9](https://doi.org/10.1016/S1874-5717(08)00208-9)
- Bröcker, J., & Smith, L. A. (2007). Increasing the reliability of reliability diagrams. *Weather and Forecasting*, 22(3), 651–661. <https://doi.org/10.1175/WAF993.1>
- Brooks, H., Brown, B., Ebert, B., Ebert, C., Jolliffe, I., Koh, T.-Y., Roebber, P., Stephenson, D., Metéo-France, Purdue University, & NOAA. (2015). *Forecast*

*Verification Methods Across Time and Space Scales*. Webmaster.  
<https://www.cawcr.gov.au/projects/verification/>

- Browniee, J. (2018). *How and When to Use a Calibrated Classification Model with scikit-learn*. Machine Learning Mastery. <https://machinelearningmastery.com/calibrated-classification-model-in-scikit-learn/>
- Buizza, F. M. R. (1996). The ECMWF ensemble prediction system: Methodology and Validation. *Quarterly Journal of the Royal Meteorological Society*, 122, 73–119.
- Buizza, R., Hollingsworth, A., Lalauette, F., & Ghelli, A. (2000). Probabilistic Predictions of Precipitation Using the ECMWF Ensemble Prediction System. *Weather and Forecasting*, 14(3), 168–189. [https://doi.org/10.1175/1520-0434\(2000\)015<0365:COPPOP>2.0.CO;2](https://doi.org/10.1175/1520-0434(2000)015<0365:COPPOP>2.0.CO;2)
- Burgos, V. H. V., Salcedo, A., & Nacional, I. (2016). Modelos digitales de elevación : Tendencias , correcciones hidrológicas y nuevas fuentes de información. *Instituto Nacional Del Agua - Centro Regional Andino, October 2014*, 16. <http://www.b.ns.ina.gov.ar/ifrh-2014/Eje3/3.10.pdf>
- Camacho Servin, F. (2018, December 30). Rechazan en Tula proyecto para llevar más aguas negras a la región. *La Jornada*, 1. <https://www.jornada.com.mx/ultimas/sociedad/2018/12/30/rechazan-en-tula-proyecto-para-llevar-mas-aguas-negras-a-la-region-7394.html>
- Carr, R. H., Montz, B., Maxfield, K., Hoekskstra, S., Semmmms, K., & Goldman, E. (2016). Effectively communicating risk and uncertainty to the public: Assessing the national weather service’s flood forecast and warning tools. *Bulletin of the American Meteorological Society*, 97(9), 1649–1665. <https://doi.org/10.1175/BAMS-D-14-00248.1>
- Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., Lu, M., Zhang, W., Tong, X., & Mills, J. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 7–27. <https://doi.org/10.1016/j.isprsjprs.2014.09.002>
- Chilango. (2019). *¡Vete por otro lado! Tláloc dejó inundaciones en estas zonas*. Chilango. <https://www.chilango.com/noticias/lluvia-del-10-de-septiembre/>
- Chow, V. Te. (1959). *Open-channel hydraulics, McGraw-Hill civil engineering series Civil Engineering Series* (Internatio). McGraw-Hill.
- Cigna, F., & Tapete, D. (2020). Present-day land subsidence rates, surface faulting hazard and risk in Mexico City with 2014–2020 Sentinel-1 IW InSAR. *Remote Sensing of Environment*, September, 112161. <https://doi.org/10.1016/j.rse.2020.112161>
- Cloke, H. L., & Pappenberger, F. (2009). Ensemble flood forecasting: A review. *Journal of Hydrology*, 375(3–4), 613–626. <https://doi.org/10.1016/j.jhydrol.2009.06.005>
- Collier, C. G. (2007). Flash flood forecasting: What are the limits of predictability. *Quarterly Journal of the Royal ...*, 133(October), 937–948. <https://doi.org/10.1002/qj>
- Conagua. (2008). *El Túnel Emisor Oriente duplicará la capacidad del drenaje profundo del Valle de México*.

- Connolly, P. (1999). Mexico City: Our common future? *Environment and Urbanization*, 11(1), 53–78. <https://doi.org/10.1177/095624789901100116>
- Coulthard, T. J., & Frostick, L. E. (2010). The Hull floods of 2007: Implications for the governance and management of urban drainage systems. *Journal of Flood Risk Management*, 3(3), 223–231. <https://doi.org/10.1111/j.1753-318X.2010.01072.x>
- Courty, L. G., Pedrozo-Acuña, A., & Bates, P. D. (2017). Itzi (version 17.1): An open-source, distributed GIS model for dynamic flood simulation. *Geoscientific Model Development*, 10(4), 1835–1847. <https://doi.org/10.5194/gmd-10-1835-2017>
- De Almeida, G. A. ., Bates, P., & Ozdemir, H. (2018). Modelling urban floods at submetre resolution: challenges or opportunities for flood risk management? *Journal of Flood Risk Management*, 11, S855–S865. <https://doi.org/10.1111/jfr3.12276>
- De La Torre, A. C., & Martín, H. O. (1997). A survey of cellular automata like the “game of life.” *Physica A: Statistical Mechanics and Its Applications*, 240(3–4), 560–570. [https://doi.org/10.1016/S0378-4371\(97\)00046-0](https://doi.org/10.1016/S0378-4371(97)00046-0)
- Di Baldassarre, G. (2012). Floods in a Changing Climate - Inundation Modelling. In C. U. Press (Ed.), *International Hydrological Programme (IHP)* (Vol. 48, Issue 04). <https://doi.org/10.5860/choice.48-1788>
- Di Baldassarre, G., Schumann, G., Bates, P. D., Freer, J. E., & Beven, K. J. (2010a). Cartographie de zone inondable: Un examen critique d’approches déterministe et probabiliste. *Hydrological Sciences Journal*, 55(3), 364–376. <https://doi.org/10.1080/02626661003683389>
- Di Baldassarre, G., Schumann, G., Bates, P. D., Freer, J. E., & Beven, K. J. (2010b). Flood-plain mapping: a critical discussion of deterministic and probabilistic approaches. *Hydrological Sciences Journal*, 55(3), 364–376. <https://doi.org/10.1080/02626661003683389>
- Dominguez Mora, R., Garduño, G. E., Antonio, B. M., Mendoza Reséndiz, A., Arganis Juárez, M. L., & Carrizosa Elizondo, E. (2008). *Manual del Modelo para pronóstico de escurrimiento*. Instituto de Ingeniería, UNAM.
- Domínguez, R., Carrizosa, E., Fuentes, G. E., Arganis, M. L., Osnaya, J., & Galván-Torres, A. E. (2018). Análisis regional para estimar precipitaciones de diseño en la república mexicana. *Tecnología y Ciencias Del Agua*, 9(1), 05–29. <https://doi.org/10.24850/jtyca-2018-01-01>
- Ebert, E. (2007). Verification of Probability Forecasts. *3rd International Verification Methods Workshop, February*. <http://www.ecmwf.int/newsevents/meetings/workshops/2007/jwgv/>
- ECMWF. (2018). <https://www.ecmwf.int/>
- EL PAÍS. (2017). *Las lluvias paralizan Ciudad de México durante horas*. [https://elpais.com/internacional/2017/08/31/mexico/1504189322\\_978073.html](https://elpais.com/internacional/2017/08/31/mexico/1504189322_978073.html)
- El Sol de Mexico. (2017). *Lluvias colapsan el sur de la CDMX: afectaciones en Coapa, Xochimilco y Tlalpan*. METRÓPOLI. <https://www.elsoldemexico.com.mx/metropoli/valle-de-mexico/Lluvias-colapsan-el->



sur-de-la-CDMX-afectaciones-en-Coapa-Xochimilco-y-Tlalpan-250667.html

- Emerton, R. E., Stephens, E. M., Pappenberger, F., Pagano, T. C., Weerts, A. H., Wood, A. W., Salamon, P., Brown, J. D., Hjerdt, N., Donnelly, C., Baugh, C. A., & Cloke, H. L. (2016). Continental and global scale flood forecasting systems. *Wiley Interdisciplinary Reviews: Water*, 3(3), 391–418. <https://doi.org/10.1002/wat2.1137>
- Espinoza, V., Collado, J., Morales, J., & Hernández, J. (2012). El gran reto del agua en la Ciudad de México: pasado, presente y perspectivas de solución para una de las ciudades más complejas del mundo. *Sistema de Aguas de La Ciudad de México*, 191. [http://laopiniondelaciudad.mx/wp-content/uploads/2016/02/ElGranRetodelAgua\\_enla\\_CiudadMexico.pdf](http://laopiniondelaciudad.mx/wp-content/uploads/2016/02/ElGranRetodelAgua_enla_CiudadMexico.pdf)
- ESRI. (2022). *¿Qué son los datos ráster?* ArGIS for Desktop. <https://desktop.arcgis.com/es/arcmap/10.3/manage-data/raster-and-images/what-is-raster-data.htm>
- EXPANSIÓN. (2017). *La Ciudad de México vive una de las lluvias más fuertes desde el 2000*. <https://expansion.mx/nacional/2017/05/30/la-ciudad-de-mexico-vive-una-de-las-lluvias-mas-fuertes-desde-el-2000>
- Falconer, R. H., Cobby, D., Smyth, P., Astle, G., Dent, J., & Golding, B. (2009). Pluvial flooding: New approaches in flood warning, mapping and risk management. *Journal of Flood Risk Management*, 2(3), 198–208. <https://doi.org/10.1111/j.1753-318X.2009.01034.x>
- Ferraris, L., Rudari, R., & Siccardi, F. (2002). The Uncertainty in the Prediction of Flash Floods in the Northern Mediterranean Environment. *Journal of Hydrometeorology*, 3(6), 714–727. [https://doi.org/10.1175/1525-7541\(2002\)003<0714:TUITPO>2.0.CO;2](https://doi.org/10.1175/1525-7541(2002)003<0714:TUITPO>2.0.CO;2)
- FINANCIERO, E. (2017). *Caos al sur de la Ciudad de México por lluvia*. EL FINANCIERO. <https://www.elfinanciero.com.mx/nacional/proteccion-civil-activa-alerta-roja-en-el-sur-de-la-cdmx-por-lluvias/>
- Forbes. (2018, May). CDMX, la quinta ciudad más habitada en el mundo: ONU. *Forbes Mexico*. <https://www.forbes.com.mx/cdmx-la-quinta-ciudad-mas-habitada-en-el-mundo-onu/>
- Galloway, D. L., & Burbey, T. J. (2011). Review: Regional land subsidence accompanying groundwater extraction. *Hydrogeology Journal*, 19(8), 1459–1486. <https://doi.org/10.1007/s10040-011-0775-5>
- Garroncho Rangel, C. (2011). *Población Flotante , Población en Movimiento : Conceptos Clave y Métodos de Análisis Exitosos* (Issue November 2011).
- GEOFABRIK. (2022). *Download OpenStreetMap data for this region: Mexico*. <http://download.geofabrik.de/north-america/mexico.html>
- Gobierno de México. (2020). *Servicio Meteorológico Nacional*. <https://smn.conagua.gob.mx/es/>
- Gobierno de México. (2021a). *SIAT CT: Sistema de Alerta Temprana para Ciclones Tropicales*. <http://preparados.gob.mx/SIAT-CT/index.php>
- Gobierno de México. (2021b). *Visor de Radares Meteorológicos(Beta): Radar Cerro*

- Catedral*. <https://smn.conagua.gob.mx/es/observando-el-tiempo/radares-meteorologicos-separador/visor-radares>
- Gómez Flores, L. (2018, August 28). Lluvia ocasiona anegaciones en la zona oriente. *La Jornada*, 34. <https://www.jornada.com.mx/2018/08/28/capital/034n1cap>
- González, M. (2017). *Tremendas inundaciones colapsan sur de la Ciudad de México*. CNN. <https://cnnespanol.cnn.com/video/cnnee-perspectivas-mexico-vo-lluvias-ciudad-mexico-sur-colapso-vias-alerta-inundaciones/>
- Gouweleeuw, B. T., Thielen, J., Franchello, G., De Roo, A. P. J., & Buizza, R. (2005). Flood forecasting using medium-range probabilistic weather prediction. *Hydrology and Earth System Sciences*, 9(4), 365–380. <https://doi.org/10.5194/hess-9-365-2005>
- Guidolin, M., Duncan, a., & Ghimire, B. (2012). CADDIES: A New Framework for Rapid Development of Parallel Cellular Automata Algorithms for Flood Simulation. *10th International Conference on Hydroinformatics*, 8. <https://ore.exeter.ac.uk/repository/handle/10036/3742>
- Guidolin, Michele, Chen, A. S., Ghimire, B., Keedwell, E. C., Djordjević, S., & Savić, D. A. (2016). A weighted cellular automata 2D inundation model for rapid flood analysis. *Environmental Modelling and Software*, 84, 378–394. <https://doi.org/10.1016/j.envsoft.2016.07.008>
- Guidolin, Michele, Chen, A. S., Pasquale, N., Guidolin, M., Chen, A. S., & Pasquale, N. (2015). *CADDIES: caiflood application USER GUIDE Application Version 110*. April. <https://emps.exeter.ac.uk/engineering/research/cws/resources/caddies-framework/caddies-download/>
- Gweon, H., & Yu, H. (2019). How reliable is your reliability diagram? *Pattern Recognition Letters*, 125, 687–693. <https://doi.org/10.1016/j.patrec.2019.07.012>
- Hamill, T. M., & Colucci, S. J. (1998). Evaluation of Eta-RSM ensemble probabilistic precipitation forecasts. *Monthly Weather Review*, 126(3), 711–724. [https://doi.org/10.1175/1520-0493\(1998\)126<0711:EOEREP>2.0.CO;2](https://doi.org/10.1175/1520-0493(1998)126<0711:EOEREP>2.0.CO;2)
- Hamill, T. M., Hagedorn, R., & Whitaker, J. S. (2008). Probabilistic Forecast Calibration Using ECMWF and GFS Ensemble Reforecasts. Part II: Precipitation. *Monthly Weather Review*, 136(7), 2620–2632. <https://doi.org/10.1175/2007mwr2411.1>
- Hankin, B., Waller, S., Astle, G., & Kellagher, R. (2008). Mapping space for water: screening for urban flash flooding. *Journal of Flood Risk Management*, 1(1), 13–22. <https://doi.org/10.1111/j.1753-318x.2008.00003.x>
- Hawking, S. (1988). *HISTORIA DEL TIEMPO Del Big Bang a los Agujeros Negros*. 256.
- Henonin, J., Russo, B., Mark, O., & Gourbesville, P. (2013). Real-time urban flood forecasting and modelling – a state of the art. *Journal of Hydroinformatics*, 15(3), 717. <https://doi.org/10.2166/hydro.2013.132>
- Horritt, M. S., & Bates, P. D. (2001). Predicting floodplain inundation: Raster-based modelling versus the finite-element approach. *Hydrological Processes*, 15(5), 825–842. <https://doi.org/10.1002/hyp.188>
- INEGI. (2010). Levantamiento-Manual de cartografía geoestadística. In *Inegi*.

[http://www.inegi.org.mx/geo/contenidos/geoestadistica/doc/manual\\_cartografia\\_censal.pdf](http://www.inegi.org.mx/geo/contenidos/geoestadistica/doc/manual_cartografia_censal.pdf)

- INEGI. (2021a). *Diccionario de Datos Topográficos - Escala 1:50 000 (versión 2)* (p. 152). <https://www.inegi.org.mx/temas/topografia/#Descargas>
- INEGI. (2021b). *Marco Gesostadístico 2021* (p. 6). Instituto Nacional de Estadística y Geografía.
- Instituto de Investigaciones Históricas - UNAM. (2020). *Galería*. Noticonquista-UNAM. <https://www.noticonquista.unam.mx/imagen-popup/1003>
- Jain, S. K., Mani, P., Jain, S. K., Prakash, P., Singh, V. P., Tullos, D., Kumar, S., Agarwal, S. P., & Dimri, A. P. (2018). A Brief review of flood forecasting techniques and their applications. *International Journal of River Basin Management*, 16(3), 329–344. <https://doi.org/10.1080/15715124.2017.1411920>
- Jarihani, A. a., Callow, J. N., McVicar, T. R., Van Niel, T. G., & Larsen, J. R. (2015). Satellite-derived Digital Elevation Model (DEM) selection, preparation and correction for hydrodynamic modelling in large, low-gradient and data-sparse catchments. *Journal of Hydrology*, 524, 489–506. <https://doi.org/10.1016/j.jhydrol.2015.02.049>
- Jaun, S., Ahrens, B., Walser, A., Ewen, T., & Schär, C. (2008). A probabilistic view on the August 2005 floods in the upper Rhine catchment. *Natural Hazards and Earth System Science*, 8(2), 281–291. <https://doi.org/10.5194/nhess-8-281-2008>
- JAXA. (2021). *ALOS WORLD 3D - 30 m*. <https://portal.opentopography.org/dataSearch?search=alos>
- Jolliffe, I. T., & Stephenson, D. B. (2013). Forecast Verification A Practitioner's Guide in Atmospheric Science. In *Journal of Chemical Information and Modeling* (Vol. 53, Issue 9). Wiley. <https://doi.org/10.1017/CBO9781107415324.004>
- Krzysztofowicz, R. (2001). The case for probabilistic forecasting in hydrology. *Journal of Hydrology*, 249(1–4), 2–9. [https://doi.org/10.1016/S0022-1694\(01\)00420-6](https://doi.org/10.1016/S0022-1694(01)00420-6)
- Kuhn, M., & Johnson, K. (2013). Applied predictive modeling. In *Division of Nonclinical Statistics Pfizer Global Research and Development*. Springer. <https://doi.org/10.1007/978-1-4614-6849-3>
- LA SILLA ROTA. (2018). *Lluvias dejan inundaciones en la capital*. LA SILLA ROTA. <https://lasillarota.com/lluvias-cdmx-capital-inundaciones-5-agosto/239415>
- Lee, K. T., Lin, G.-F., Ho, J.-Y., Yang, T.-H., & Kao, H.-M. (2018). Using ensemble precipitation forecasts and a rainfall-runoff model for hourly reservoir inflow forecasting during typhoon periods. *Journal of Hydro-Environment Research*, 22(May 2018), 29–37. <https://doi.org/10.1016/j.jher.2018.05.002>
- Leitão, J. P., & de Sousa, L. M. (2018). Towards the optimal fusion of high-resolution Digital Elevation Models for detailed urban flood assessment. *Journal of Hydrology*, 561(April), 651–661. <https://doi.org/10.1016/j.jhydrol.2018.04.043>
- León, C., & Neri, C. (2010). *Pobreza Urbana Y Cambio Climático Para La Ciudad De México (Urban Poverty and Climate Change for Mexico City)*.

- Leonard, M., Westra, S., Phatak, A., Lambert, M., van den Hurk, B., McInnes, K., Risbey, J., Schuster, S., Jakob, D., & Stafford-Smith, M. (2014). A compound event framework for understanding extreme impacts. *Wiley Interdisciplinary Reviews: Climate Change*, 5(1), 113–128. <https://doi.org/10.1002/wcc.252>
- Li, Y., Xu, B., Wang, D., Wang, Q., Zheng, X., Xu, J., Zhou, F., Huang, H., & Xu, Y. (2021). Deterministic and probabilistic evaluation of raw and post-processing monthly precipitation forecasts: a case study of China. *Journal of Hydroinformatics*, 1–20. <https://doi.org/10.2166/hydro.2021.176>
- Llanas y Fernández, R. (2017). *Inundaciones históricas de la Ciudad de México (1552-1910)*. IIUNAM. <https://www.youtube.com/watch?v=cK0yY9qJrrc>
- López, J. (2017). *Fotogalería: ‘Se cae el cielo’ e inunda la zona de Polanco*. EXCELSIOR. <https://www.excelsior.com.mx/comunidad/2017/06/28/1172558>
- López, J. (2018). *Lluvias dejan caos y ocho inundaciones en la CDMX (Rains leave chaos and eight floods in CDMX)*. EXCELSIOR. <https://www.excelsior.com.mx/comunidad/lluvias-dejan-caos-y-ocho-inundaciones-en-la-cdmx/1259807>
- López, P. (2019). *Avanza la mancha urbana sobre CDMX*. Gaceta UNAM. <https://www.gaceta.unam.mx/avanza-la-mancha-urbana-sobre-cdmx/>
- Mao, J. (1996). Artificial Neuronal Networks: A Tutorial. *Theme Feature*, 31–44.
- Mejía Estrada, P. I., Rodríguez Rincón, J. P., & Pedrozo-Acuña, A. (2013). Análisis del evento hidrometeorológico extremo en Acapulco, Guerrero, 2013: Lecciones aprendidas. *Revista Digital Tláloc AMH*, 66(ENERO-MARZO 2015), 7–19. [http://amh.org.mx/wp-content/uploads/2018/06/Revista-66\\_baja.pdf](http://amh.org.mx/wp-content/uploads/2018/06/Revista-66_baja.pdf)
- meteologix. (2021). *meteologix*. <https://meteologix.com/mx>
- METRÓPOLI. (2018a). *Inundaciones, caídas de bardas y vehículos varados, el saldo de las lluvias en CDMX*. EL UNIVERSAL. <http://www.eluniversal.com.mx/metropoli/cdmx/inundaciones-caidas-de-bardas-y-vehiculos-varados-el-saldo-de-las-lluvias-en-cdmx>
- METRÓPOLI. (2018b, August 27). *Lluvias dejan graves inundaciones al oriente de CDMX (Rains leave serious floods east of CDMX)*. LA SILLA ROTA. <https://lasillarota.com/lluvia-inundaciones-cdmx-zaragoza-iztapalapa-cdmx-27-agosto/243707>
- Molinari, D., De Bruijn, K. M., Castillo-Rodríguez, J. T., Aronica, G. T., & Boucher, L. M. (2019). Validation of flood risk models: Current practice and possible improvements. *International Journal of Disaster Risk Reduction*, 33(May 2018), 441–448. <https://doi.org/10.1016/j.ijdr.2018.10.022>
- Moore, R. J., Bell, V. A., & Jones, D. A. (2005). Forecasting for flood warning. *Comptes Rendus - Geoscience*, 337(1–2), 203–217. <https://doi.org/10.1016/j.crte.2004.10.017>
- Morss, R. E., Demuth, J. L., & Lazo, J. K. (2008). Communicating uncertainty in weather forecasts: A survey of the U.S. public. *Weather and Forecasting*, 23(5), 974–991. <https://doi.org/10.1175/2008WAF2007088.1>

- Mosavi, A., Ozturk, P., & Chau, K. W. (2018). Flood prediction using machine learning models: Literature review. *Water (Switzerland)*, *10*(11), 1–40. <https://doi.org/10.3390/w10111536>
- Murphy, A. H. (1993). What Is a Good Forecast? An Essay on the Nature of Goodness in Weather Forecasting. *American Meteorological Society*, *8*, 281–293.
- Neal, J., Fewtrell, T., & Trigg, M. (2009). Parallelisation of storage cell flood models using OpenMP. *Environmental Modelling and Software*, *24*(7), 872–877. <https://doi.org/10.1016/j.envsoft.2008.12.004>
- Niculescu-Mizil, A., & Caruana, R. (2005). Predicting good probabilities with supervised learning. *ICML 2005 - Proceedings of the 22nd International Conference on Machine Learning*, *22*, 625–632. <https://doi.org/10.1145/1102351.1102430>
- Nipen, T., Siuta, D., & Chu, T. (2019). *Verif* (1.1). <https://github.com/WFRT/verif>
- NOTIMEX. (2018). *Lluvia deja encharcamientos e inundaciones en la CDMX*. NOTIMEX. <https://www.excelsior.com.mx/comunidad/lluvia-deja-encharcamientos-e-inundaciones-en-la-cdmx/1256743>
- Office of Water Prediction. (2018). *The National Water Model*. <http://water.noaa.gov/about/nwm>
- Once TV México. (2013). *Sobre el agua - El desalojo de las aguas*. Once TV México. <https://www.youtube.com/watch?v=gyveMFe4i-w>
- Owens, R G, Hewson, T. D. (2018a). *ECMWF Forecast User Guide*. <https://confluence.ecmwf.int/display/FUG/Forecast+User+Guide>
- Owens, R G, Hewson, T. D. (2018b). *Forecast Ensemble (ENS) - Rationale and Construction*. <https://doi.org/10.21957/m1cs7h>
- pandas. (2022). *data analysis and manipulation tool, built on top of the Python programming language*. <https://pandas.pydata.org/>
- Pappenberger, F., Bartholmes, J., Thielen, J., Cloke, H. L., Buizza, R., & de Roo, A. (2008). New dimensions in early flood warning across the globe using grand-ensemble weather predictions. *Geophysical Research Letters*, *35*(10), 1–7. <https://doi.org/10.1029/2008GL033837>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Duborg, V., Vanderplas, J., Passos, A., & Cournapeu, D. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, *12*, 2825–2830.
- Pedrozo-Acuña, A., Breña-Naranjo, J. A., & Domínguez-Mora, R. (2014). The hydrological setting of the 2013 floods in Mexico. *Weather*, *69*(11), 295–302. <https://doi.org/10.1002/wea.2355>
- Pedrozo-Acuña, A., Rodríguez-Rincón, J. P., Arganis-Juárez, M., Domínguez-Mora, R., & González Villareal, F. (2013). Estimation of probabilistic flood inundation maps for an extreme event: Pánuco River, México. *Journal of Flood Risk Management*, *8*(2), 177–192. <https://doi.org/10.1111/jfr3.12067>

- Persson, A. (2015). User Guide to ECMWF forecast products. In ECMWF (Ed.), *User guide to ECMWF forecast Products 3.1* (ECMWF, Issue March, p. 127). ECMWF.
- Pitt, M. (2008). *Learning lessons from the 2007 floods: an independent review by Sir Michael Pitt*.  
[https://webarchive.nationalarchives.gov.uk/20100812084907/http://archive.cabinetoffice.gov.uk/pittreview/\\_/media/assets/www.cabinetoffice.gov.uk/flooding\\_review/pitt\\_review\\_full.pdf.pdf](https://webarchive.nationalarchives.gov.uk/20100812084907/http://archive.cabinetoffice.gov.uk/pittreview/_/media/assets/www.cabinetoffice.gov.uk/flooding_review/pitt_review_full.pdf.pdf)
- Plate, E. J. (2009). HESS Opinions “classification of hydrological models for flood management.” *Hydrology and Earth System Sciences*, 13(10), 1939–1951.  
<https://doi.org/10.5194/hess-13-1939-2009>
- Powers, J. G., Klemp, J. B., Skamarock, W. C., Davis, C. A., Dudhia, J., Gill, D. O., Coen, J. L., Gochis, D. J., Ahmadov, R., Peckham, S. E., Grell, G. A., Michalakes, J., Trahan, S., Benjamin, S. G., Alexander, C. R., Dimego, G. J., Wang, W., Schwartz, C. S., Romine, G. S., ... Duda, M. G. (2017). The weather research and forecasting model: Overview, system efforts, and future directions. *Bulletin of the American Meteorological Society*, 98(8), 1717–1737. <https://doi.org/10.1175/BAMS-D-15-00308.1>
- Probabilidad y Estadística. (2022). *Coefficiente de correlación de Pearson*.  
<https://www.probabilidadyestadistica.net/coeficiente-de-correlacion-de-pearson/>
- Publimetro. (2019). *Se activa alerta amarilla en 12 alcaldías por tormenta*. Publimetro.  
<https://www.publimetro.com.mx/mx/noticias/2019/07/18/tormenta-lluvia-e-inundaciones-en-la-cdmx-18-de-julio-de-2019.html>
- Quevauviller, P. (2015). *Hydrometeorological Hazards* (Philippe Q). Wiley Blackwell.
- Rayner, S., Lach, D., & Ingram, H. (2005). Weather forecasts are for wimps: Why water resource managers do not use climate forecasts. *Climatic Change*, 69(2–3), 197–227.  
<https://doi.org/10.1007/s10584-005-3148-z>
- Reinoso E., Torres M.A., Jaimes M.A., Franco V., D. R. y P. O. (2012). *Escenarios de Pérdidas por Inundación Pluvial en la Ciudad de México ante una Falla de algún Componente del Sistema de Drenaje Principal (Scenarios of losses due to rain flooding in Mexico City due to the failure of any component of the Main Drainage Syst.* Instituto de Ingeniería, UNAM. <https://doi.org/SID/677>, ISBN 978-607-02-3545-0
- Reinoso, E., Torres, M. A., Jaimes, M. Á., Franco, V., Domínguez-Mora, R., & Pozos Estrada, Ó. (2012). Escenarios de pérdidas por inundación pluvial en la ciudad de México ante la falla de algún componente del Sistema de Drenaje Principal (Scenarios of losses due to pluvial flooding in Mexico City due to the failure in the Main Drainage System). In O. Gómez Mora (Ed.), *Serie Investigación y Desarrollo* (1ra ed). Instituto de Ingeniería, Unidad de Promoción y Comunicación.
- Revilla-Romero, B., Hirpa, F. A., Pozo, J. T. del, Salamon, P., Brakenridge, R., Pappenberger, F., & de Groeve, T. (2015). On the use of global flood forecasts and satellite-derived inundation maps for flood monitoring in data-sparse regions. *Remote Sensing*, 7(11), 15702–15728. <https://doi.org/10.3390/rs71115702>

- Richardson, D., Hemri, S., Bogner, K., Gneiting, T., Haiden, T., & Pappenberger, F. (2015). *Calibration of ECMWF forecasts. February 2016*.
- Rincón, J. P. R. (2016). *Estimación Probabilística de Mapas de Inundación: Una Metodología Basada en Ensamblajes* [Universidad Nacional Autónoma de México]. <http://www.cchazc.unam.mx/wp-content/uploads/2013/03/GuiaIngles2.pdf>
- Ripberger, J. T., Bell, A., Fox, A., Forney, A., Livingston, W., Gaddie, C., Silva, C., & Jenkins-Smith, H. (2022). Communicating Probability Information in Weather Forecasts: Findings and Recommendations from a Living Systematic Review of the Research Literature. *Weather, Climate, and Society*, 14(2), 481–498. <https://doi.org/10.1175/WCAS-D-21-0034.1>
- Ripberger, J. T., Jenkins-Smith, H. C., Silva, C. L., Carlson, D. E., & Henderson, M. (2014). Social media and severe weather: Do tweets provide a valid indicator of public attention to severe weather risk communication? *Weather, Climate, and Society*, 6(4), 520–530. <https://doi.org/10.1175/WCAS-D-13-00028.1>
- Rodríguez-Rincón, J. P., Pedrozo-Acuña, A., & Breña-Naranjo, J. A. (2015). Propagation of hydro-meteorological uncertainty in a model cascade framework to inundation prediction. *Hydrology and Earth System Sciences*, 19(7), 2981–2998. <https://doi.org/10.5194/hess-19-2981-2015>
- Roulin, E. (2006). Skill and relative economic value of medium-range hydrological ensemble predictions. *Hydrology and Earth System Sciences Discussions, European G(3 (4))*, 1369–1406. <https://hal.archives-ouvertes.fr/hal-00298726>
- Salas Salinas, M. A., & Jiménez Espinoza, M. (2014). Inundaciones, Serie Fascículos. In Ó. A. Fuentes Mariles (Ed.), *Secretaría de Gobernación (Violeta Ra)*. CENAPRED. <http://www.cenapred.gob.mx/es/Publicaciones/archivos/3-FASCCULOINUNDACIONES.PDF>
- Salinas, E. M., Boer, F., Pas, B. van de, & Espínola, V. R. (2016). *Towards a Water Sensitive Mexico City*.
- Schumann, A. H. (2011). *Flood Risk Assessment and Management* (R.-U. Bochum (Ed.)). Springer Dordrecht Heidelberg.
- Schwanghart, W., & Kuhn, N. J. (2010). TopoToolbox: A set of Matlab functions for topographic analysis. *Environmental Modelling and Software*, 25(6), 770–781. <https://doi.org/10.1016/j.envsoft.2009.12.002>
- scikit-learn. (2022). 3.1. *Cross-validation: evaluating estimator performance*. [https://scikit-learn.org/stable/modules/cross\\_validation.html](https://scikit-learn.org/stable/modules/cross_validation.html)
- Secretaría de Gestión Integral de Riesgos y Protección Civil. (2019). *Atlas de riesgo - Inundaciones (Risk Atlas - Floods)*. Gobierno de La Ciudad de México. <https://datos.cdmx.gob.mx/explore/dataset/atlas-de-riesgo-inundaciones/information/?dataChart=eyJxdWVyaWVzIjpbeyJjb25maWciOnsiZGF0YXNldCI6ImF0bGFzLWRlLXJpZXNnby1pbmVuZGFjaW9uZXMiLCJvcHRpb25zIjpb7fX0sImNoYXJ0cyI6W3siYWxpZ25Nb250aCI6dHJlZSwidHlwZSI6ImNvbHVtb>
- Secretaría de Gestión Integral de Riesgos y Protección Civil. (2021). *Clasificación de los*

- Niveles de Alerta por Fenómenos Meteorológicos (Classification of Alert Levels by Meteorological Phenomena)*.  
<https://www.proteccioncivil.cdmx.gob.mx/redalertatemprana>
- Sharma, S., Siddique, R., Balderas, N., Fuentes, J. D., Reed, S., Ahnert, P., Shedd, R., Astifan, B., Cabrera, R., Laing, A., Klein, M., & Mejia, A. (2017). Eastern U.S. verification of ensemble precipitation forecasts. *Weather and Forecasting*, 32(1), 117–139. <https://doi.org/10.1175/WAF-D-16-0094.1>
- Shen, C., Laloy, E., Elshorbagy, A., Albert, A., Bales, J., Chang, F. J., Ganguly, S., Hsu, K. L., Kifer, D., Fang, Z., Fang, K., Li, D., Li, X., & Tsai, W. P. (2018). HESS Opinions: Incubating deep-learning-powered hydrologic science advances as a community. *Hydrology and Earth System Sciences*, 22(11), 5639–5656. <https://doi.org/10.5194/hess-22-5639-2018>
- Siccardi, F., Boni, G., Ferraris, L., & Rudari, R. (2005). A hydrometeorological approach for probabilistic flood forecast. *Journal of Geophysical Research D: Atmospheres*, 110(5), 1–9. <https://doi.org/10.1029/2004JD005314>
- Simarro, C. (2020). *Access MARS*.  
<https://confluence.ecmwf.int/display/WEBAPI/Access+MARS>
- Sorensen, J. H. (2000). Hazard warning systems. In *Vol. 1, Issue 2 (May 2000)* (Vol. 1, Issue 2). [https://doi.org/10.1061/\(ASCE\)1527-6988\(2000\)1:2\(119\)](https://doi.org/10.1061/(ASCE)1527-6988(2000)1:2(119))
- Swaminathan, S. (2018). *Logistic Regression — Detailed Overview*. Towards Data Science. <https://towardsdatascience.com/logistic-regression-detailed-overview-46c4da4303bc>
- Teng, J., Jakeman, A. J., Vaze, J., Croke, B. F. W., Dutta, D., & Kim, S. (2017). Flood inundation modelling: A review of methods, recent advances and uncertainty analysis. *Environmental Modelling and Software*, 90, 201–216. <https://doi.org/10.1016/j.envsoft.2017.01.006>
- Thielen, J., Bartholmes, J., Ramos, M.-H., & de Roo, A. (2008). The European Flood Alert System - Part 1: Concept and development. *Hydrology and Earth System Sciences Discussions*, 5(1), 257–287. <https://doi.org/10.5194/hessd-5-257-2008>
- Tingsanchali, T. (2012). Urban flood disaster management. *Procedia Engineering*, 32, 25–37. <https://doi.org/10.1016/j.proeng.2012.01.1233>
- Todini, E., Alberoni, P., Butts, M., Collier, C., Khabiti, R., Samuels, P., & Weerts, A. (2005). ACTIF Best practice paper - Understanding and reducing uncertainty in flood forecasting. *Proceeding of ACTIF Conference*, 1, 1–43.
- Todini, Ezio. (2004). Role and treatment of uncertainty in real-time flood forecasting. *Hydrological Processes*, 18(14), 2743–2746. <https://doi.org/10.1002/hyp.5687>
- Transmonte, J. G. de. (2015). *22 septiembre 1629 la Ciudad de México amanece anegada luego de 36 horas de lluvia*. IMER. <https://www.imer.mx/efemeride-sonora-ciudad-de-mexico-amanece-anegada/>
- United Nations, Department of Economic and Social Affairs, P. D. (2018). The World 's Cities in 2018. In *The World's Cities in 2018 - Data Booklet (ST/ESA/SER.A/417)*. [https://www.un.org/en/events/citiesday/assets/pdf/the\\_worlds\\_cities\\_in\\_2018\\_data\\_bo](https://www.un.org/en/events/citiesday/assets/pdf/the_worlds_cities_in_2018_data_bo)



oklet.pdf

- United Nations. (2018). *68% of the world population projected to live in urban areas by 2050, says UN*. Department of Economic and Social Affairs.  
<https://www.un.org/development/desa/en/news/population/2018-revision-of-world-urbanization-prospects.html#:~:text=News-,68%25 of the world population projected to live in,areas by 2050%2C says UN&text=The urban population of the,to 4.2 billion in 2018.>
- Van Der Knijff, J. M., Younis, J., & De Roo, A. P. J. (2010). LISFLOOD: a GIS-based distributed model for river basin scale water balance and flood simulation. *International Journal of Geographical Information Science*, 24(2), 189–212.  
<https://doi.org/10.1080/13658810802549154>
- Verbunt, M., Walser, A., Gurtz, J., Montani, A., & Schär, C. (2007). Probabilistic Flood Forecasting with a Limited-Area Ensemble Prediction System: Selected Case Studies. *Journal of Hydrometeorology*, 8(4), 897–909. <https://doi.org/10.1175/JHM594.1>
- Wikipedia. (2017). *Cross-validation (statistics)*. [https://en.wikipedia.org/wiki/Cross-validation\\_\(statistics\)](https://en.wikipedia.org/wiki/Cross-validation_(statistics))
- Wilks, D. S. (2001). A skill score based on economic value for probability forecasts. *Meteorological Applications*, 8(2), 209–219.  
<https://doi.org/10.1017/S1350482701002092>
- Wilks, D. S. (2006). *Statistical Methods in the Atmospheric Sciences* (R. Dmowska, D. Hartmann, & H. T. Rossby (Eds.); Second edi). ELSEVIER.
- Wilson, L. J. (2006). Verification of Probability Ensemble forecasts. *Atmospheric Science and Technology Branch Environment Canada*.
- Wilson, L. J., Burrows, W. R., & Lanzinger, A. (1999). A strategy for verification of weather element forecasts from an ensemble prediction system. *Monthly Weather Review*, 127(6 I), 956–970. [https://doi.org/10.1175/1520-0493\(1999\)127<0956:ASFVOW>2.0.CO;2](https://doi.org/10.1175/1520-0493(1999)127<0956:ASFVOW>2.0.CO;2)
- Wolfram, S. (1984). Cellular automata as models of complexity. *Nature*, 311(5985), 419–424. <https://doi.org/10.1038/311419a0>
- Wu, W., Emerton, R., Duan, Q., Wood, A. W., Wetterhall, F., & Robertson, D. E. (2020). Ensemble flood forecasting: Current status and future opportunities. *WIREs Water*, 7(3), 1–32. <https://doi.org/10.1002/wat2.1432>
- Zamarrón, I. (2020, September 20). Urge un nuevo Plan Maestro de Drenaje para CDMX. *El Sol de México*, 1. <https://www.elsoldemexico.com.mx/metropoli/cdmx/urge-un-nuevo-plan-maestro-de-drenaje-para-cdmx-5781219.html>
- Zschau, J., & Andreas N. Küppers. (2003). *Early Warning Systems for Natural Disaster Reduction*. Springer Dordrecht Heidelberg.

## Capítulo 9. Anexos

### 9.1. Ejemplo de código de Python para la petición de descarga de información en lotes del ECMWF

Simarro, (2020) describe cómo descargar e instalar el cliente api del ECMWF para la descarga externa de los productos de pronóstico. Para tener acceso al sistema MARS es necesario estar suscrito como usuario del ECMWF y contar con nombre de usuario y llave de acceso (**API key credentials**). El acceso a los datos tiene costo para usuarios e instituciones que no pertenecen a la unión europea.

Para la realización de este trabajo de investigación, el ECMWF otorgó un año de licencia de acceso al sistema MARS para la descarga de pronósticos históricos, y no en tiempo real. Lo anterior significa que la licencia otorgada solo permitió la descarga del pronóstico 72 horas después de ocurrido el evento de interés.

A continuación, se muestra un ejemplo de código en lenguaje Python para la petición de descarga del pronóstico ENS, para el mes de mayo de 2017.

```
from ecmwfapi import ECMWFService
server = ECMWFService("mars")
server.execute(
    {
        "class": "od",                #clase od: operational data
        "date": "20170501/to/20170531", #Periodo de descarga de los datos
        "area": "20.5/-100/18.5/-98",   #Coordenadas del área de descarga
                                        Norte/Oeste/Sur/Este
        "grid": "0.125/0.125",         #Resolución de la información
        "expver": "1",                 #código de versión del producto: 1 para
                                        operational data
        "levtype": "sfc",              #sfc: por Surface o nivel superficial
        "number": "1/to/50",           #Selección de miembros del ensamble. En
                                        este caso del miembro 1 al 50
    }
```

```

"param": "228.128",
"step": "0/to/90/by/6",
"stream": "enfo",
"time": "12",
"type": "pf"
},
"TP_PF_S90by6_T12_MAY_2017.grib")

```

#Identificación del parámetro tp = total precipitation (228.128)

#pasos de tiempo. De la hora cero a la 96 en pasos de tiempo de 6 horas

#Identifica el modelo de pronóstico. En este caso el acrónimo “enfo” es por ensemble forecast (ensambles de pronóstico)

#Tiempo base del pronóstico: 12 UTC

#Selección de tipo de pronóstico. “pf” (Perturbed forecast).

#Selección del nombre de salida y extensión que tendrá el archivo de descarga

## 9.2. Lista de estaciones Climatológicas

Tabla 9-1. Lista de estaciones climatológicas del Sistema CLICOM. Estaciones utilizadas para la verificación de pronósticos del ECMWF en la Cuenca del Valle de México

Num.	Clave	Nombre	Fecha Inicial	Fecha Final	Latitud	Longitud	Elevación m s. n. m.
1	9020	DESVIACION ALTA AL PEDREGAL-DF	01/01/1952	01/01/2016	19.2969	-99.1822	2608
2	9022	EL GUARDA-DF	01/01/1961	01/01/2016	19.1344	-99.1731	2365
3	9029	GRAN CANAL KM. 06 250-DF	01/01/1952	01/01/2016	19.4767	-99.0914	2395
4	9032	MILPA ALTA-DF	01/10/1929	01/01/2016	19.1906	-99.0219	2369
5	9036	PLAYA CALETA 454 COLONIA MARTE-DF	01/04/1968	01/11/2015	19.3953	-99.0978	2556
6	9041	SAN FRANCISCO TLALNEPANTLA-DF	01/01/1961	01/06/2015	19.1967	-99.1286	2458
7	9043	SAN JUAN DE ARAGON-DF	01/06/1953	01/01/2016	19.4653	-99.0792	2290
8	9045	SANTA ANA TLACOTENCO-DF	01/01/1969	01/10/2015	19.1789	-99.0028	2434
9	13002	APAN (DGE)-HGO	01/01/1986	01/10/2015	19.7072	-98.4492	2635
10	13004	ALCANTARILLAS-HGO	01/01/2013	01/08/2016	19.7997	-98.3808	2494
11	13008	EL MANANTIAL-HGO	01/12/1959	01/10/2015	19.8517	-98.9364	2456
12	13024	POTRERITO-HGO	01/11/1969	01/10/2015	19.6103	-98.6417	2380
13	13027	SAN JERONIMO-HGO	01/11/1970	01/07/2015	19.8153	-98.4842	2532
14	13029	SAN LORENZO SAYULA-HGO	01/01/1961	01/10/2015	19.9872	-98.2972	2795
15	13030	SAN RAFAEL MAZATEPEC-HGO	01/01/1966	01/10/2015	19.8647	-98.3558	2258

<b>Num.</b>	<b>Clave</b>	<b>Nombre</b>	<b>Fecha Inicial</b>	<b>Fecha Final</b>	<b>Latitud</b>	<b>Longitud</b>	<b>Elevación m s. n. m.</b>
16	13031	SANTIAGO TULANTEPEC-HGO	01/05/1966	01/06/2015	20.0444	-98.3683	2268
17	13033	SINGUILUCAN-HGO	01/01/1961	01/06/2015	19.9647	-98.5131	2258
18	13055	IROLO-HGO	01/01/2005	01/01/2016	19.7325	-98.5956	2381
19	13056	PACHUCA-HGO	01/01/1972	01/02/2016	20.0875	-98.7497	2397
20	13068	EL SALTO-HGO	01/02/1953	02/01/2017	19.9358	-99.2836	2769
21	13079	PRESA EL GIRON-HGO	01/12/1952	01/10/2016	20.0725	-98.6533	2235
22	13082	PRESA LA ESPERANZA-HGO	01/09/1956	01/01/2016	20.0561	-98.3344	2719
23	13085	PRESA TEZOYO-HGO	01/02/1953	02/03/2015	19.8542	-98.3083	2538
24	13091	TIZAYUCA (DGE)-HGO	01/03/1977	01/01/2017	19.8239	-98.9544	2470
25	13100	OMITLAN-HGO	01/04/1974	01/01/2017	20.1767	-98.6453	2413
26	13115	REAL DEL MONTE-HGO	01/02/1940	01/07/2016	20.1331	-98.6692	2761
27	13127	EL ASERRADERO-HGO	01/01/1981	01/10/2015	19.9539	-98.3258	2668
28	13128	SAN AGUSTIN TLAXIACA OCAVM-HGO	01/01/1982	01/01/2016	20.1183	-98.8853	2300
29	13129	SAN AGUSTIN ZAPOTLAN-HGO	01/01/1981	01/01/2016	19.8728	-98.7181	2999
30	13131	SANTIAGO TLAJOMULCO-HGO	01/05/1981	01/11/2015	19.9847	-98.9175	2236
31	13132	EL TEPOZAN-HGO	01/05/1981	01/03/2015	19.8108	-98.2661	2433
32	13133	SAN PEDRO TLAQUILPAN-HGO	01/01/1981	01/10/2015	19.9442	-98.7539	2237
33	13138	EMILIANO ZAPATA-HGO	01/01/1982	01/10/2015	19.6583	-98.55	2238
34	13150	EL CERESO-HGO	01/05/1986	01/04/2014	20.1583	-98.7286	2584
35	13160	TORNACUXTLA-HGO	01/10/1996	01/10/2016	20.1531	-98.87	2492
36	13162	SANTIAGO TEPEYAHUALCO-HGO	01/01/2005	01/01/2013	19.8483	-98.6708	2304
37	13165	LA TRINIDAD-HGO	01/05/2007	01/01/2016	19.9603	-98.7081	2640
38	13167	ALMOLOYA-HGO	01/01/2013	01/07/2016	19.7022	-98.4083	2534
39	13168	RANCHO NUEVO-HGO	01/11/2012	01/07/2016	19.7478	-98.2792	2360
40	15007	AMECAMECA DE JUAREZ (DGE)-MEX	01/03/1969	01/12/2015	19.1406	-98.7722	2531
41	15008	ATENCO-MEX	01/01/1961	01/01/2016	19.5439	-98.9128	2179
42	15013	CALACOAYA-MEX	01/01/1961	01/01/2016	19.5342	-99.2394	2660
43	15014	CAPULHUAC-MEX	01/01/1969	01/10/2015	19.4408	-99.5453	2177
44	15017	COATEPEC DE LOS OLIVOS-MEX	01/01/1961	01/10/2015	19.3847	-98.8461	2212
45	15019	COLONIA VICENTE GUERRERO-MEX	01/01/1971	01/10/2015	19.5956	-99.3547	2609
46	15020	CHALCO -SAN LUCAS-MEX	01/01/1961	01/01/2016	19.2583	-98.8958	2630
47	15022	CHICONAUTLA-MEX	01/03/1963	01/01/2016	19.6567	-99.0172	2374
48	15028	EL TAJO -TUNEL VIEJO-MEX	01/01/1961	01/10/2015	19.9086	-99.1264	2482
49	15032	HUEHUETOCA-MEX	01/01/1961	01/01/2016	19.8486	-99.2125	2467
50	15039	JUCHITEPEC-MEX	01/01/1969	01/01/2016	19.0869	-98.8847	2246
51	15041	GRAN CANAL KM 27 250-MEX	01/01/1961	01/05/2015	19.5617	-99.0194	2278
52	15044	LA GRANDE-MEX	01/01/1961	01/10/2015	19.5761	-98.9139	2602
53	15045	LA MARQUESA-MEX	01/01/1969	01/10/2015	19.2986	-99.3686	2419
54	15047	LAS ARBOLEDAS-MEX	01/01/1969	01/01/2016	19.5628	-99.2158	2478

<b>Num.</b>	<b>Clave</b>	<b>Nombre</b>	<b>Fecha Inicial</b>	<b>Fecha Final</b>	<b>Latitud</b>	<b>Longitud</b>	<b>Elevación m s. n. m.</b>
55	15050	LOS REYES-MEX	01/01/1961	01/09/2015	19.3578	-98.9917	2244
56	15055	MAQUIXCO-MEX	01/09/1964	01/01/2016	19.7842	-98.8322	2256
57	15057	MIMIAPAN-MEX	01/01/1961	01/04/2016	19.4431	-99.4644	2230
58	15058	MOLINITO-MEX	01/01/1969	01/01/2016	19.4536	-99.2383	2260
59	15059	MOLINO BLANCO-MEX	01/01/1961	01/01/2016	19.4775	-99.2208	2542
60	15061	NEZAHUALCOYOTL-MEX	01/07/1967	01/01/2016	19.4158	-99.0456	2233
61	15073	PRESA GUADALUPE-MEX	01/01/1961	01/10/2015	19.6233	-99.2822	2251
62	15074	PRESA LA CONCEPCION-MEX	01/01/1961	01/01/2016	19.695	-99.3017	3039
63	15075	PRESA LAS RUINAS-MEX	01/08/1969	01/10/2015	19.5811	-99.2783	2276
64	15077	PRESA TOTOLICA-MEX	01/04/1963	01/01/2016	19.4528	-99.2836	2247
65	15081	REPRESA EL ALEMAN-MEX	01/01/1961	01/10/2015	19.7044	-99.2192	2531
66	15083	SAN ANDRES-MEX	01/01/1961	01/01/2016	19.5319	-98.9106	2882
67	15090	SAN JERONIMO XONOCAHUACAN-MEX	01/01/1961	01/01/2016	19.7508	-98.9494	2290
68	15094	SAN LUIS AMECA-MEX	01/01/1961	01/01/2016	19.1903	-98.8708	2268
69	15095	SAN LUIS AYUCAN-MEX	01/01/1961	01/01/2016	19.4953	-99.3678	2234
70	15098	SAN MARTIN OBISPO-MEX	01/08/1964	01/09/2015	19.6217	-99.1928	2347
71	15099	SAN MATEO ACUITLAPILCO-MEX	01/01/1961	01/10/2015	19.7633	-99.0439	2323
72	15100	SAN MATEO TECOLOAPAN-MEX	01/01/1969	01/01/2016	19.5708	-99.2375	2351
73	15101	SAN MIGUEL TLAIXPAN-MEX	01/01/1961	01/10/2015	19.5194	-98.8125	2380
74	15106	SAN RAFAEL-MEX	01/01/1961	01/10/2015	19.2078	-98.7583	2269
75	15114	SANTIAGO TLAZALA-MEX	01/01/1961	01/01/2016	19.5581	-99.4139	2249
76	15115	SANTO TOMAS PUENTE COLGANTE-MEX	01/01/1961	01/01/2016	19.7747	-99.1669	2269
77	15125	TEXCOCO (DGE)-MEX	01/01/1961	01/01/2016	19.5056	-98.8819	2285
78	15127	TOTOLICA SAN BARTOLO-MEX	01/01/1961	01/01/2016	19.4656	-99.2456	2750
79	15129	TULTEPEC-MEX	01/01/1961	01/01/2016	19.6842	-99.1267	2263
80	15135	XOCHIHUACAN-MEX	01/01/1969	01/04/2015	19.6239	-98.6753	2251
81	15137	AMEALCO-MEX	01/10/1996	01/01/2016	19.5181	-99.1108	2287
82	15145	PLAN LAGO DE TEXCOCO-MEX	01/04/1967	01/01/2015	19.4506	-98.9317	2391
83	15150	SAN MATEO HUEXOTLA-MEX	01/01/2001	01/09/2015	19.4769	-98.8778	2541
84	15167	EL TEJOCOTE-MEX	01/01/1952	01/10/2015	19.4433	-98.9028	2807
85	15170	CHAPINGO (DGE)-MEX	01/01/1952	01/01/2016	19.4847	-98.8864	2248
86	15210	SAN JUAN TOTOLAPAN-MEX	01/01/1976	01/10/2015	19.5297	-98.7267	2253
87	15231	PRESA ITURBIDE-MEX	01/09/1977	01/10/2015	19.5294	-99.4642	2290
88	15263	ACOLMAN-MEX	01/06/1983	01/01/2016	19.64	-98.9128	2252
89	15274	NOPALA-MEX	01/01/1981	01/01/2016	19.9378	-99.0119	2766
90	15280	TLALMANALCO-MEX	01/05/1981	01/01/2016	19.2039	-98.8033	2235
91	15318	SANTA ANA JILOTZINGO-MEX	01/09/1981	01/10/2015	19.5389	-99.3969	2257

<b>Num.</b>	<b>Clave</b>	<b>Nombre</b>	<b>Fecha Inicial</b>	<b>Fecha Final</b>	<b>Latitud</b>	<b>Longitud</b>	<b>Elevación m s. n. m.</b>
92	15383	LAGO NABOR CARRILLO-MEX	01/07/1985	01/01/2016	19.4722	-98.9917	2255
93	29003	ATLANGA SAN JOSE-TLAX	01/01/1961	01/01/2014	19.5556	-98.2028	2777
94	29004	CUAMANTZINGO-TLAX	01/01/1969	01/10/2015	19.5197	-98.2692	3321
95	29010	HUEYOTLIPAN-TLAX	01/01/1961	01/04/2015	19.4719	-98.3453	2490
96	29016	NANACAMILPA (DGE)-TLAX	01/01/1985	01/10/2015	19.4925	-98.5353	2564
97	29024	SANCTORUM-TLAX	01/07/1966	01/07/2009	19.4925	-98.4719	2590
98	29025	SAN MARCOS HUAQUILPAN-TLAX	01/08/1966	01/01/2014	19.5969	-98.6319	2603
99	29034	ZOQUIAPAN-TLAX	01/04/1966	01/10/2015	19.5847	-98.4781	2530
100	29035	CALPULALPAN-TLAX	01/10/1947	01/10/2015	19.5861	-98.5639	2680
101	29047	ESPAÑA'ITA-TLAX	01/03/1977	01/01/2014	19.4578	-98.4222	2746
102	29052	EL ROSARIO-TLAX	01/01/1981	01/01/2014	19.6553	-98.2289	2588
103	29162	BENITO JUAREZ-TLAX	01/04/1933	01/01/2014	19.5867	-98.4275	2625

Tabla 9-2. Lista de estaciones del OH-IIUNAM. Estaciones utilizadas para la verificación de pronósticos del ECMWF en la Ciudad de México

<b>Num</b>	<b>Nombre</b>	<b>Longitud</b>	<b>Latitud</b>	<b>Elevación m s. n. m.</b>
1	ACOPILCO	-99.329	19.322	2956
2	AJUSCO	-99.1884	19.215	2857
3	AMC	-99.1742	19.241	2616
4	ARAGON	-99.08	19.466	2240
5	BALBUENA	-99.1028	19.423	2237
6	BONDOJITO	-99.118	19.47	2239
7	BOSQUERREAL	-99.283	19.436	2418
8	CCHOTE	-99.06	19.384	2239
9	CCHVALLEJO	-99.14	19.483	2239
10	CENTENARIO	-99.239	19.356	2514
11	COAPA	-99.134	19.288	2248
12	CONDESA	-99.171	19.407	2250
13	CONTRERAS	-99.247	19.306	2547
14	CUAJIMALPA	-99.292	19.355	2732
15	CUAUHTENCO	-99.097	19.193	2753
16	CUAUTEPEC	-99.141	19.549	2275
17	CUEMANCO	-99.1032	19.282	2239
18	CULHUACAN	-99.1051	19.323	2246
19	DHUMANOS	-99.221	19.322	2396
20	DOSRIOS	-99.344	19.37	2636

<b>Num</b>	<b>Nombre</b>	<b>Longitud</b>	<b>Latitud</b>	<b>Elevación m s. n. m.</b>
21	HERRADURA	-99.251	19.416	2366
22	IIUNAM	-99.182	19.329	2285
23	INDIOSVER	-99.119	19.496	2238
24	IZTAPALAPA	-99.07	19.349	2247
25	LAJOYA	-99.1678	19.28167	2283
26	LOSREYES	-98.979	19.358	2244
27	MADIN	-99.267	19.523	2363
28	MEXICALTZINGO	-99.1177	19.356	2242
29	MEYEHUALCO	-99.044	19.337	2247
30	MILPAALTA	-99.017	19.197	2368
31	NAUCALPAN	-99.243	19.474	2316
32	NOPALERA	-99.0448	19.302	2260
33	PADIERNA	-99.227	19.294	2508
34	PANTITLAN	-99.075	19.416	2232
35	PICACHO	-99.206	19.269	2612
36	POLANCO	-99.206	19.43628	2279
37	PREPA2	-99.0988	19.384	2237
38	PREPA3	-99.095	19.482	2242
39	PREPA4	-99.196	19.404	2303
40	PREPA5	-99.135	19.307	2246
41	PREPA8	-99.195	19.367	2309
42	SACMEX	-99.137	19.425	2250
43	SANBARTOLO	-99.28	19.326	2761
44	SANBERNABE	-99.266	19.306	2753
45	SGREGORIO	-99.0462	19.253	2260
46	TACUBA	-99.1863	19.455	2251
47	TAXQUENA	-99.142	19.344	2241
48	TLALNE	-99.195	19.539	2258
49	TLATELOLCO	-99.1371	19.45	2243
50	TOPILEJO	-99.1527	19.209	2769
51	TULYEHUALC	-99.01	19.25	2253
52	UAMAZC	-99.189	19.504	2250
53	VHERMOSA	-99.276	19.372	2629
54	XOCHIMILCO	-99.107	19.25	2248
55	ZAPATA	-99.149	19.373	2247

### 9.3. Implementación de la Regresión Logística

El modelo de regresión lineal se define por la siguiente ecuación:

$$y = \frac{1}{1 + e^{-(\alpha + \beta x)}} \quad (9.1)$$

Donde  $x$  es la variable predictora y  $\alpha, \beta$  los parámetros.

La relación entre predictores y predicciones es una relación lineal, pero con alguna transformación. En una regresión lineal las variables  $x, y$  son variables continuas que pueden adoptar valores desde menos infinito a infinito.

$$y = \alpha + \beta x \quad (9.2)$$

$$(x, y) \in [-\infty, \infty]^2$$

Mientras que en la regresión logística, al predecir una variable que es categórica, la variable "y" se vuelve discreta porque solo podrá adoptar un valor de cero o uno,  $y \in \{0,1\}$ . En consecuencia "y" se convierte en una variable binaria. Para predecir el valor de "y" es necesario establecer probabilidades con un rango de valores desde cero a uno  $P \in [0,1]$ . Entonces el punto de inicio de la regresión logística consiste en calcular la variable  $P$ :

$$X \in [-\infty, \infty]$$

$$P = \alpha + \beta X \quad (9.3)$$

$P$  es la probabilidad condicionada de éxito o fracaso en función de un evento  $X$ . Sin embargo, al tratarse de probabilidades,  $P$  debe adoptar valores entre cero y uno. Para solucionar esto, se calcula la relación de la probabilidad de que ocurra un evento versus la probabilidad de que el evento no ocurra:  $odds = \frac{P}{1-P} \in [0, +\infty]$



De acuerdo con lo anterior, la probabilidad se divide entre su complemento, por lo que la variable *odds* de una probabilidad dada varía de cero a infinito positivo. Para lograr que todos los valores posibles de la probabilidad abarquen el espectro entero de números reales, se aplica una transformación adicional de logaritmo. De esta forma es posible plantear una función de manera análoga a la regresión lineal.

Entonces, el modelo resultante de la regresión logística se conforma por una parte lineal (miembro derecho de la ecuación) y el logaritmo aplicado a la probabilidad (transformación logit), como se muestra a continuación.

$$\ln\left(\frac{P}{1-P}\right) = \alpha + \beta X$$

Al aplicar logaritmo a la variable *odds*, ambos lados de la ecuación anterior ahora pueden adoptar valores desde  $-\infty, \infty$ ; en donde se pueden presentar los casos siguientes:

$$\left[ \begin{array}{l} \frac{P}{1-P} \in [0,1] \Rightarrow \ln\left(\frac{P}{1-P}\right) \in [-\infty, 0] \\ \frac{P}{1-P} \in [1, +\infty] \Rightarrow \ln\left(\frac{P}{1-P}\right) \in [0, \infty] \end{array} \right.$$

Por último, se aplica el número de Euler "e" en ambos lados de la ecuación para despejar las probabilidades, *P*.

$$\frac{P}{1-P} = e^{\alpha+\beta X}$$

$$P = e^{\alpha+\beta X} - P e^{\alpha+\beta X}$$

$$P(1 + e^{\alpha+\beta X}) = e^{\alpha+\beta X}$$

$$P = \frac{e^{\alpha+\beta X}}{1 + e^{\alpha+\beta X}}$$

Si dividimos el termino derecho entre  $e^{\alpha+\beta X}$ , la expresión final queda:

$$P = \frac{1}{1 + e^{-(\alpha + \beta X)}} \quad (9.4)$$

La ecuación anterior permitirá calcular la probabilidad de la variable  $X$ .

En el caso de una regresión logística múltiple:

$$P = \frac{1}{1 + e^{-(\alpha + \sum_{i=1}^n \beta_i X_i)}} \quad (9.5)$$

O también se puede denotar de forma vectorial:

$$\vec{\beta} = (\beta_1, \beta_2, \beta_3, \dots, \beta_n)$$

$$\vec{X} = (X_1, X_2, X_3, \dots, X_n)$$

$$P = \frac{1}{1 + e^{-(\alpha + \vec{\beta} \vec{X})}} \quad (9.6)$$

### 9.3.1. Estimación con máxima verosimilitud

Para estimar los parámetros de la regresión logística se utiliza el método de estimador de máxima verosimilitud. Si tenemos una serie de observaciones:

$$\{(x_i, y_i)\}_{i=1}^n$$

Donde  $y$  es la variable independiente y  $x_i$  es la variable predictora; que en el caso de regresión múltiple, pueden ser dos o más variables predictoras o estimadoras. Entonces se tiene que:

$$x_i = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{ik})$$

El entorno de máxima verosimilitud  $L$  se define como la probabilidad conjunta de que se cumpla o no  $P_1$  dado si ocurre o no  $y_i$ .

$$y_i \in \{0,1\}$$

$$L = \prod_{i=1}^n P_i^{y_i} (1 - P_i)^{1-y_i} \quad (9.7)$$

Donde  $n$  es igual al total de datos (data points) y  $k$  representa a las variables estimadoras. Entonces de acuerdo con la ecuación de regresión logística en sus dos modalidades:

$$\begin{aligned} \ln\left(\frac{P}{1-P}\right) &= \alpha + \sum_{j=1}^k \beta_j x_{ij} \\ &= \alpha + \vec{\beta} x_i \end{aligned} \quad (9.8)$$

Por otro lado, de la ecuación (9.6), se tiene:

$$P_i = \frac{1}{1 + e^{-(\alpha + \beta x_i)}}$$

Adicionalmente recordamos que el valor de la categoría será 1 si la probabilidad del punto o dato estudiado es mayor al 50%, y 0 si la probabilidad es menor a 50%.

$$\left\{ \begin{array}{l} y_i = 1 \Rightarrow P(x) \geq 0.5 \Rightarrow \alpha + \beta x \geq 0 \\ y_i = 0 \Rightarrow P(x) < 0.5 \Rightarrow \alpha + \beta x < 0 \end{array} \right.$$

La función de verosimilitud (ver ecuación (9.7)) es el producto de las probabilidades y al escribirla en función de los parámetros  $\alpha$  y  $\beta$ , se tiene la siguiente ecuación:

$$L(\alpha, \beta) = \prod_{i=1}^n P_i^{y_i} (1 - P_i)^{1-y_i}$$

Donde  $P_i$  es la probabilidad del punto  $x_i$  en cuestión,  $P_i = P(x_i)$

Para despejar las incógnitas ( $\alpha$  y  $\beta$ ) de la función de verosimilitud se aplica el logaritmo natural a la izquierda y derecha de la ecuación anterior.

si  $l = \ln L(\alpha, \beta)$

$$l = \ln L(\alpha, \beta) = \ln \left( \prod_{i=1}^n P_i^{y_i} (1 - P_i)^{1-y_i} \right)$$

Por propiedades de logaritmos la expresión anterior queda:

$$\begin{aligned} &= \sum_{i=1}^n y_i \ln P_i + (1 - y_i) \ln(1 - P_i) \\ &= \sum_{i=1}^n \ln(1 - P_i) + y_i (\ln P_i - \ln(1 - P_i)) \end{aligned} \quad (9.9)$$

$$\ln P_i - \ln(1 - P_i) = \ln \left( \frac{P_i}{1 - P_i} \right)$$

De la ecuación (9.8), se sabe que:

$$\ln \left( \frac{P_i}{1 - P_i} \right) = \alpha + \sum_{j=1}^k \beta_j x_{ij}$$

Entonces, sustituyendo la ecuación anterior en la ecuación (9.9), queda la siguiente expresión:

$$= \sum_{i=1}^n \ln(1 - P_i) + y_i \left( \alpha + \sum_{j=1}^k \beta_j x_{ij} \right) \quad (9.10)$$

Adicionalmente, derivado de la ecuación (9.6):

$$1 - P_i = 1 - \frac{1}{1 + e^{-(\alpha + \beta x_i)}} = \frac{1 + e^{-(\alpha + \beta x_i)} - 1}{1 + e^{-(\alpha + \beta x_i)}} = \frac{1}{1 + e^{(\alpha + \beta x_i)}}$$

Por lo que:

$$\ln(1 - P_i) = \ln \left( \frac{1}{1 + e^{(\alpha + \beta x_i)}} \right)$$

$$\ln(1 - P_i) = \ln(1) - \ln(1 + e^{(\alpha + \beta x_i)})$$

$$\text{como } \ln(1) = 0$$

$$\ln(1 - P_i) = -\ln(1 + e^{(\alpha + \beta x_i)}) \quad (9.11)$$

Sustituyendo la ecuación (9.11) en la ecuación (9.10):

$$l = \ln L(\alpha, \beta) = \sum_{i=1}^n -\ln(1 + e^{(\alpha + \beta x_i)}) + y_i \left( \alpha + \sum_{j=1}^k \beta_j x_{ij} \right) \quad (9.12)$$

A partir de la función de máxima verosimilitud se procede entonces a buscar los mínimos igualando las derivadas de la función a cero.

$$\text{Máxima verosimilitud} \Rightarrow \frac{\partial l}{\partial \alpha} = \frac{\partial l}{\partial \beta_j} = 0$$

$$\frac{\partial l}{\partial \alpha} = \sum_{i=1}^n -\frac{e^{(\alpha + \beta x_i)}}{1 + e^{(\alpha + \beta x_i)}} + y_i = \sum_{i=1}^n (y_i - P_i) \quad (9.13)$$

$$\frac{\partial l}{\partial \beta_j} = \sum_{i=1}^n -\frac{x_{ij} e^{(\alpha + \beta x_i)}}{1 + e^{(\alpha + \beta x_i)}} + y_i x_{ij} = \sum_{i=1}^n x_{ij} (y_i - P_i) \quad (9.14)$$

Si se hace un cambio de variable  $\alpha = \beta_0$  y  $x_{i0} = 1 \forall i = 1, \dots, n$

$$\frac{\partial l}{\partial \beta_j} = \sum_{i=1}^n x_{ij} (y_i - P_i) \quad (9.15)$$

Entonces la derivada parcial de  $l$  respecto a  $\beta_j$  puede escribirse como un producto escalar de la columna  $j$ -ésima de los datos por  $(y_i - P_i)$ .

$$\frac{\partial l}{\partial \beta_j} = X_j \cdot (y_i - P_i) \quad (9.16)$$

En notación vectorial la expresión anterior queda:

$$\frac{\partial l}{\partial \beta} = X \cdot (y_i - P_i)$$

Calculando la segunda derivada:

$$\frac{\partial^2 l}{\partial \beta_j^2} = \sum_{i=1}^n -x_{ij} \frac{\partial P_i}{\partial \beta_j} \quad (9.17)$$

De la ecuación (9.6) tenemos:

$$P_i = \frac{1}{1 + e^{-(\alpha + \beta x_i)}} \Rightarrow \frac{\partial P_i}{\partial \beta_j} = \frac{-x_{ij} e^{-(\alpha + \beta x_i)}}{(1 + e^{-(\alpha + \beta x_i)})^2}$$

$$\frac{\partial P_i}{\partial \beta_j} = \frac{-1}{1 + e^{-(\alpha + \beta x_i)}} \frac{e^{-(\alpha + \beta x_i)}}{1 + e^{-(\alpha + \beta x_i)}} x_{ij}$$

$$P_i = \frac{1}{1 + e^{-(\alpha + \beta x_i)}} ; 1 - P_i = \frac{e^{-(\alpha + \beta x_i)}}{1 + e^{-(\alpha + \beta x_i)}}$$

Entonces

$$\frac{\partial P_i}{\partial \beta_j} = -P_i(1 - P_i)x_{ij}$$

Sustituyendo la expresión anterior en la ecuación (9.17):

$$\frac{\partial^2 l}{\partial \beta_j^2} = \sum_{i=1}^n x_{ij} P_i (1 - P_i) x_{ij}$$

En notación vectorial:

$$\frac{\partial^2 l}{\partial \beta^2} = \sum_{i=1}^n x_i P_i (1 - P_i) x_i^t$$

Donde  $x_i$  es el vector de datos  $i$ -ésimo con todas las columnas de datos. En forma matricial la expresión anterior se denota por:

$$\frac{\partial^2 l}{\partial \beta_j^2} = X \cdot W \cdot X^T$$

Donde la matriz diagonal  $W$  contiene la información de los parámetros  $\beta$

$$W(\beta) = \text{diag}(P_i(1 - P_i))_{i=1}^n$$

Para resolver la ecuación (9.15) se emplea el método de Newton-Raphson

### 9.3.2. Parámetros del modelo de Regresión Logística para Cuenca del Valle de México

Tabla 9-3. Coeficientes beta del modelo de Regresión Logística para distintos umbrales de lluvia en la Cuenca del Valle de México

Miembro	< 5 mm	> 5 mm	> 10 mm	> 20 mm
e0	0.001171	-0.00117	-0.00537	0.003231
e1	0.000245	-0.00025	0.003109	0.00183
e2	-0.00779	0.007791	0.004811	-0.00743
e3	0.009774	-0.00977	-0.01164	-0.01289
e4	-0.01598	0.015983	0.012531	0.007261
e5	-0.00233	0.002329	0.008347	0.000603
e6	0.009491	-0.00949	-0.00122	0.000103
e7	-4.44E-05	4.44E-05	0.00191	0.013247
e8	-0.01439	0.014389	0.015213	0.013629
e9	-0.01039	0.010394	0.013829	0.017199
e10	-0.00478	0.004776	0.000643	0.000383
e11	-0.00843	0.008429	0.010092	0.018395
e12	-0.00232	0.002316	0.002862	0.005511
e13	0.004054	-0.00405	-0.00852	-0.01472
e14	0.010352	-0.01035	-0.00513	0.002359

<b>Miembro</b>	<b>&lt; 5 mm</b>	<b>&gt; 5 mm</b>	<b>&gt; 10 mm</b>	<b>&gt; 20 mm</b>
e15	-0.00644	0.006443	0.00829	0.011756
e16	0.002944	-0.00294	-0.00713	-0.01019
e17	-0.00685	0.006847	0.007419	0.012185
e18	-0.00021	0.000213	-0.00875	-0.0123
e19	0.000189	-0.00019	-0.00271	-0.00142
e20	-0.01075	0.010745	0.014674	0.010001
e21	0.006354	-0.00635	-0.00308	-0.001
e22	0.014664	-0.01466	-0.01682	-0.01856
e23	-0.0115	0.011496	0.011157	0.020911
e24	-0.00663	0.006626	0.003234	-0.00141
e25	-0.01921	0.019213	0.015237	0.011025
e26	-0.00969	0.009687	0.011421	0.019156
e27	0.000551	-0.00055	0.001799	0.000155
e28	-0.01	0.010002	0.004623	0.006097
e29	-0.01056	0.010559	0.012754	0.01097
e30	-0.00732	0.007325	0.008239	0.003813
e31	0.000783	-0.00078	0.002592	0.002036
e32	-0.00626	0.006255	0.003759	0.00484
e33	-0.01349	0.013494	0.011544	0.014982
e34	-0.01367	0.013674	0.009747	0.008379
e35	-0.00296	0.002955	0.001924	-0.001
e36	-0.00903	0.009035	0.005129	0.002536
e37	0.006155	-0.00615	-0.00835	-0.00652
e38	-0.00504	0.005039	-0.00024	0.00083
e39	-0.00056	0.000565	-0.00027	0.00087
e40	0.003624	-0.00362	-0.00081	-0.00662
e41	0.005402	-0.0054	-0.00412	0.001361
e42	-0.01352	0.013523	0.012471	0.008712
e43	-0.00186	0.001861	-0.00276	-0.02179
e44	0.009091	-0.00909	-0.0182	-0.02403
e45	0.00146	-0.00146	-0.00522	-0.01237
e46	0.002406	-0.00241	0.001315	0.003563
e47	0.011504	-0.0115	-0.00777	-0.00565
e48	-0.00458	0.004582	0.00331	0.005463
e49	-0.00048	0.000479	1.98E-05	-0.00382
<b>HRES</b>	<b>-0.06707</b>	<b>0.067071</b>	<b>0.06443</b>	<b>0.0567</b>



### 9.3.3. Parámetros del modelo de Regresión Logística para CDMX. Lluvia acumulada cada 6 horas para $t = 0 + 90$ h.

Tabla 9-4 Coeficientes beta del modelo de Regresión Logística para distintos umbrales de lluvia en CDMX

Miembro	< 0.5 mm	> 0.5 mm	> 1 mm
e0	0.001929	-0.00193	-0.00122
e1	0.009196	-0.0092	-0.00851
e2	-0.00649	0.00649	0.002538
e3	-0.02278	0.022778	0.02435
e4	-0.02027	0.020269	0.023195
e5	0.005628	-0.00563	-0.0091
e6	-0.00703	0.007029	0.003953
e7	-0.00043	0.000431	0.001181
e8	0.006827	-0.00683	-0.00828
e9	-0.01213	0.012135	0.00978
e10	-0.00306	0.003058	0.001884
e11	-0.01712	0.017124	0.015238
e12	-0.01424	0.014244	0.009761
e13	-0.0132	0.013197	0.012522
e14	-0.01648	0.01648	0.015074
e15	0.013722	-0.01372	-0.01585
e16	-0.01137	0.01137	0.010176
e17	-0.00147	0.001469	0.00154
e18	-0.01284	0.012835	0.007439
e19	-0.00379	0.003792	0.007521
e20	-0.01037	0.010367	0.005239
e21	0.00324	-0.00324	-0.00104
e22	-0.00587	0.005865	0.009783
e23	0.003359	-0.00336	-0.00321
e24	-0.0138	0.0138	0.008193
e25	0.001721	-0.00172	0.001516
e26	-0.00864	0.00864	0.013292
e27	0.002778	-0.00278	-0.0008
e28	0.005229	-0.00523	-0.00701
e29	0.012415	-0.01241	-0.01629
e30	-0.0256	0.025601	0.029278
e31	-0.01721	0.017206	0.009902
e32	0.008797	-0.0088	-0.00168

Miembro	< 0.5 mm	> 0.5 mm	> 1 mm
e33	-9.50E-05	9.50E-05	0.003949
e34	-0.00987	0.009867	0.011449
e35	-0.00759	0.007591	0.01187
e36	-0.00074	0.000738	-0.00028
e37	-0.01434	0.014336	0.014738
e38	-0.01695	0.016951	0.015526
e39	0.003228	-0.00323	-0.00365
e40	0.008816	-0.00882	-0.01066
e41	-0.02375	0.023745	0.023888
e42	-0.00738	0.007384	0.007222
e43	-0.0052	0.005201	0.005058
e44	-0.01502	0.015022	0.020575
e45	-0.02284	0.022837	0.026564
e46	-0.0043	0.004304	0.003855
e47	0.005498	-0.0055	-0.00806
e48	-0.01381	0.013806	0.012024
e49	-0.00832	0.008319	0.004047
HRES	-0.0349	0.034904	0.028757

### 9.3.4. Parámetros del modelo de Regresión Logística para el Modelo 1. Lluvia acumulada en 24 horas para $It = 0 + 72$ h.

Tabla 9-5. Coeficientes beta del modelo de Regresión Logística para el Modelo 1 descrito en el Capítulo 5.4

Num.	Miembro	Beta
1	e0	0.006008878
2	e1	-0.008418647
3	e2	-0.012780952
4	e3	0.007563407
5	e4	0.002595111
6	e10	-0.009573836
7	e11	0.023058914
8	e13	0.020111561
9	e14	0.003680532
10	e16	0.006696779

Num.	Miembro	Beta
11	e17	0.001678983
12	e19	-0.002038067
13	e21	-0.005010895
14	e24	0.017013772
15	e25	0.015551262
16	e28	0.007093175
17	e29	0.001115084
18	e30	0.027407123
19	e31	0.008000557
20	e34	-0.003252306
21	e39	-0.00959186
22	e43	0.002480348
23	e44	0.001543329
24	e45	0.02996799
25	e47	0.006093825
26	e49	-0.00211687
27	HRES	0.017127678

## 9.4. Parámetros del modelo WCA2D CADDIES\_caflood

A continuación, se muestra la configuración de parámetros para el modelo hidrodinámico. Esta información debe estar en formato de texto separado por comas para que pueda ser leído por CADDIES\_caflood. Para más detalles consultar (Michele Guidolin et al., 2015)

```
Simulation Name           ,Mexico City
Short Name (for outputs) ,CDMX
Version                   ,1,0,0
Model Type                ,WCA2Dv2
Time Start (seconds)     ,0
Time End (seconds)       ,86400
Max DT (seconds)         ,60
Min DT (seconds)         ,0.01
Update DT (seconds)      ,60
Alpha (Fraction DT 0.0-1.0) ,0.1
Max Iterations           ,4000000
```

Roughness Global	,0.019
Ignore WD (meter)	,0.005
Tolerance (meter)	,0.0025
Slope Tolerance (%)	,0.2
Boundary Ele (Hi/Closed-Lo/Open),	-9000
Elevation ASCII	,dem.asc
Rain Event CSV	,box5.csv,box6.csv,box9.csv,box10.csv,box14.csv,box15.csv
Water Level Event CSV	
Inflow Event CSV	
Time Plot CSV	
Raster Grid CSV	,WDraster.csv,VELraster.csv
Output Console	,true
Output Period (s)	,300
Output Computation Time	,true
Check Volumes	,true
Remove Proc Data (No Pre-Proc)	,true
Remove Pre-Proc Data	,true
Raster VEL Vector Field	,true
Raster WD Tolerance (meter)	,0.01
Update Peak Every DT	,false
Expand Domain	,true
Ignore Upstream	,true
Upstream Reduction (meter)	,1