



UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA

**Análisis bayesiano para el pronóstico de
intensidad de ciclones tropicales en el
mar Caribe**

TESIS

Que como parte de los requisitos para obtener el Grado de

**MAESTRA EN CIENCIAS
(HIDROLOGÍA AMBIENTAL)**

Presenta:

Lic. Daylin Perdigón Cuellar

Dirigido por:

Dr. M. Alfonso Gutiérrez López

C.U., Querétaro, Qro. a: diciembre de 2025

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



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

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

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

Bajo los siguientes términos:



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



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



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

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

Avisos:

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

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



Universidad Autónoma de Querétaro
Facultad de Ingeniería
Maestría en Ciencias (Hidrología Ambiental)

Análisis bayesiano para el pronóstico de intensidad de ciclones tropicales en el mar Caribe

TESIS

Que como parte de los requisitos para obtener el Grado de
Maestro en Ciencias (Hidrología Ambiental)

Presenta:

Daylin Perdigón Cuellar

Dirigido por:

Dr. Martín Alfonso Gutiérrez López

Dr. Martín Alfonso Gutiérrez López

Presidente

M.C. Iván González García

Secretario

M.C. Sebastián Fuentes Castro

Vocal

M.C. Luis Ángel Miranda Sánchez

Suplente

Dr. Víctor Kevin Contreras Tereza

Suplente

Centro Universitario, Querétaro, Qro.

Fecha de Aprobación por el consejo (diciembre /2025)

México

DEDICATORIA

A mi hija Ana Isabella, por ser mi mayor fuente de amor, fortaleza e inspiración. Educarla mientras avanzaba en este camino académico ha sido el mayor reto y, a la vez, el motor más poderoso para no rendirme. Su ternura, su compañía y su sonrisa me sostuvieron en cada momento en que parecía imposible continuar.

A mis padres, por impulsarme siempre a superarme, por confiar en mis capacidades y por enseñarme, con su ejemplo, que el esfuerzo y la dedicación abren caminos. Su amor y apoyo incondicional han estado presentes en cada paso de este logro.

A ellos les dedico este sueño cumplido, con la certeza de que vale la pena luchar por aquello que en verdad nos hace crecer.

AGRADECIMIENTOS

Agradezco a la Universidad Autónoma de Querétaro por brindarme la oportunidad de formarme académicamente y por el respaldo institucional recibido durante mi formación de posgrado. Asimismo, expreso mi reconocimiento a la Facultad de Ingeniería y a su División de Posgrado, por los conocimientos transmitidos, los recursos académicos proporcionados y el acompañamiento recibido a lo largo de este proceso.

Mi más sincero agradecimiento al Dr. Martín Alfonso Gutiérrez López, excoordinador de la Maestría en Ciencias con Línea Terminal en Hidrología Ambiental y asesor de esta tesis, por su guía, confianza y acompañamiento académico. Desde nuestro primer encuentro en Cuba, su orientación fue determinante al presentarme las oportunidades que ofrece esta universidad y el programa de maestría, lo cual resultó fundamental para mi incorporación a este espacio académico y para el desarrollo de mi trayectoria profesional y personal.

Agradezco al sínodo de esta tesis: M.C. Sebastián Fuentes Castro, M.C. Iván González García, M.C. Luis Ángel Miranda Sánchez y Dr. Víctor Kevin Contreras Tereza, por su disposición, tiempo y valiosas observaciones durante la revisión y evaluación de este trabajo, las cuales contribuyeron significativamente al fortalecimiento de su calidad académica.

Expreso mi agradecimiento a la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI) por el otorgamiento de la beca nacional que hizo posible el desarrollo y culminación de esta investigación, así como por la oportunidad brindada como estudiante extranjera y el apoyo al impulso de las investigaciones de posgrado en México.

Extiendo mi agradecimiento al cuerpo académico de la Maestría y a los docentes que contribuyeron con sus conocimientos durante mi formación, en especial a la M.C. Verónica Leyva Picazo, la Dra. María del Carmen Cabrera Hernández y el Dr. Eusebio Jr. Ventura Ramos.

Agradezco profundamente a mis padres, Barbara y Pastor, por su apoyo constante aun a la distancia; a mi hermano Daniel, por su ayuda incondicional; y a mi hija, quien es mi mayor motivación y fortaleza en cada paso de este camino.

A mis amigas de toda la vida: Diana, Lidiana, Yisel y Yanet, gracias por su apoyo económico y emocional, su comprensión y sus palabras de ánimo. Asimismo, agradezco a los compañeros y amigos que gané en esta etapa, en especial a mis “Pepes Grillos”, Adrianis León y Jesús García Gallego, por sus consejos y apoyo constante.

Finalmente, expreso mi gratitud a todas las personas que, de manera directa o indirecta, contribuyeron con su compañía y estímulo a la culminación de este trabajo y al fortalecimiento de mi formación académica y personal.

RESUMEN

Los ciclones tropicales (CTs) constituyen una de las amenazas hidrometeorológicas más relevantes para la región del Caribe, con implicaciones críticas para la planificación climática y la gestión del riesgo. Esta tesis desarrolla un análisis bayesiano orientado al pronóstico de la intensidad ciclónica, centrado en el dominio comprendido entre 15°-34° N y 65°-98° O. A partir de datos históricos del repositorio IBTrACS v04 (1950-2021), se analizan en conjunto dos variables físicas clave: la velocidad máxima del viento y la presión mínima central, con el objetivo de capturar de forma probabilística la intensidad de los CTs y su variabilidad espacio-temporal. La metodología integra estadística de extremos, modelación jerárquica bayesiana y estimaciones locales Beta-Binomiales por nodo geográfico, permitiendo generar probabilidades conjuntas de alcanzar distintas categorías Saffir-Simpson y mapas regionales de riesgo. Las estimaciones se construyen por periodos climáticos y revelan patrones robustos de intensificación, con valores predictivos elevados, incluso en las categorías más severas. Los resultados muestran zonas de mayor probabilidad en el sur del Golfo de México, el Caribe occidental y áreas próximas a la península de Yucatán, así como desplazamientos recientes en los núcleos de riesgo. En conjunto, el enfoque bayesiano propuesto permite representar de forma realista la incertidumbre asociada a eventos extremos y ofrece herramientas operativas aplicables a la alerta temprana, la evaluación del riesgo y la planificación climática, contribuyendo a una gestión más eficaz del riesgo ciclónico en el contexto del cambio climático.

(Palabras Clave: modelación bayesiana, ciclones tropicales, intensidad, distribución GEV, probabilidad condicional)

ABSTRACT

Tropical cyclones (TCs) represent one of the most significant hydro-meteorological threats to the Caribbean region, with critical implications for climate planning and risk management. This thesis develops a Bayesian framework for forecasting TC intensity, focused on the domain between 15°-34° N and 65°-98° W. Based on historical data from the IBTrACS v04 repository (1950-2021), two key physical variables: maximum sustained wind speed and minimum central pressure, are jointly analyzed to probabilistically capture TC intensity and its spatio-temporal variability.

The methodology integrates extreme value statistics, Bayesian hierarchical modeling, and local Beta-Binomial estimations by geographic node, enabling the generation of joint probabilities of reaching different Saffir-Simpson categories and regional risk maps. Estimates are computed across climatic periods and reveal robust intensification patterns, with high predictive skill, even in the most severe categories.

Results highlight high-probability zones in the southern Gulf of Mexico, the western Caribbean, and areas near the Yucatán Peninsula, as well as recent spatial shifts in the most intense risk cores. Overall, the proposed Bayesian approach offers a realistic representation of the uncertainty associated with extreme events and provides operational tools applicable to early warning systems, risk assessment, and climate planning. This contributes to a more effective management of cyclone risk in the context of climate change.

(Key words: Bayesian modeling, tropical cyclones, intensity, GEV distribution, conditional probability)

INDICE	pág.
RESUMEN.....	v
ABSTRACT.....	vi
Índice de Figuras	x
Índice de Tablas	xiv
INTRODUCCIÓN	1
I. MARCO TEÓRICO	7
1.1 <i>Fundamentos físicos de los ciclones tropicales</i>	7
1.1.1 <i>Definición y clasificación operativa</i>	7
1.1.2 <i>Estructura interna y dinámica del sistema</i>	8
1.1.3 <i>Condiciones de génesis e intensificación</i>	10
1.1.4 <i>Intensidad e impactos hidrometeorológicos</i>	12
1.1.5 <i>Relación viento-presión y aproximaciones empíricas</i>	14
1.2 <i>Pronóstico de trayectoria e intensidad</i>	17
1.2.1 <i>Forzamientos sinópticos y guías de trayectoria</i>	17
1.2.2 <i>Representación visual del pronóstico: “cono de incertidumbre”</i>	20
1.2.3 <i>Sistemas de observación en tiempo real</i>	21
1.2.4 <i>Modelos de predicción ciclónica</i>	22
1.3 <i>Estadística de extremos</i>	28
1.3.1 <i>Distribución Generalizada de Valores Extremos (GEV)</i>	29
1.3.2 <i>Estimación de parámetros: máxima verosimilitud</i>	30
1.3.3 <i>Niveles de retorno e incertidumbre</i>	31
1.3.4 <i>Aplicaciones en el análisis de intensidad ciclónica</i>	32
1.4 <i>Enfoque bayesiano aplicado a ciclones tropicales</i>	34
1.4.1 <i>Teorema de Bayes y fundamentos de inferencia</i>	34
1.4.2 <i>Modelos jerárquicos y probabilidad condicional</i>	35
1.4.3 <i>Aplicaciones a la predicción de intensidad</i>	36
II. METODOLOGÍA.....	40
2.1 <i>Área de estudio</i>	40
2.2 <i>Base de datos</i>	40

2.2.1	<i>Procesamiento de los datos para el área de estudio</i>	41
2.3	<i>Análisis de extremos mediante modelo GEV</i>	45
2.3.1	<i>Evaluación y validación del ajuste GEV</i>	45
2.4	<i>Modelado jerárquico bayesiano de la intensidad ciclónica</i>	46
2.4.1	<i>Probabilidades condicionadas por periodo</i>	48
2.4.2	<i>Diagnóstico de convergencia y validación</i>	50
2.5	<i>Mapas de probabilidad de intensidad ciclónica</i>	51
2.5.1	<i>Estimación bayesiana local de probabilidades condicionadas por nodo geográfico</i>	51
2.5.2	<i>Validación geoespacial de la estimación probabilística</i>	55
2.6	<i>Síntesis metodológica</i>	57
III.	RESULTADOS Y DISCUSIÓN	59
3.1	<i>Análisis de frecuencias de ciclones tropicales</i>	59
3.2	<i>Relación entre presión mínima central y velocidad del viento</i>	60
3.3	<i>Análisis de intensidad ciclónica por periodos</i>	61
3.3.1	<i>Distribución de velocidad máxima del viento y presión mínima central</i>	61
3.3.2	<i>Cambios anuales en la intensidad ciclónica extrema</i>	63
3.3.3	<i>Tendencias temporales de las variables</i>	66
3.4	<i>Modelado de extremos mediante distribución GEV</i>	68
3.4.1	<i>Evaluación del ajuste del modelo GEV</i>	69
3.4.2	<i>Niveles de retorno e incertidumbre asociada</i>	77
3.5	<i>Inferencias del modelo bayesiano jerárquico para viento y presión mínima</i>	80
3.5.1	<i>Probabilidades condicionadas por categoría de intensidad</i>	82
3.5.2	<i>Convergencia y validación</i>	87
3.6	<i>Mapas de probabilidad condicional de intensidad ciclónica por estimación Beta-Binomial</i>	96
3.6.1	<i>Validación espacial de las estimaciones anuales del modelo</i>	105
	CONCLUSIONES	111
	RECOMENDACIONES	113
	REFERENCIAS BIBLIOGRÁFICAS	114
	ANEXOS	130

<i>Anexo A. Mapas de probabilidad condicional acumulada por categoría y periodo</i>	<i>130</i>
<i>Anexo B. Intervalos de credibilidad de estimaciones anuales</i>	<i>135</i>
<i>Anexo C. Soporte observacional local</i>	<i>136</i>

Índice de Figuras

Figura 1: Zonas ciclogénicas del planeta	8
Figura 2: Estructura de un huracán a partir de vista superior	9
Figura 3: Influencia del Anticiclón de Bermudas-Azores en las trayectorias típicas de los ciclones tropicales en el Atlántico.....	18
Figura 4: Mapa de cono de trayectoria y simbología asociada para un ciclón tropical potencial.....	21
Figura 5: Área de estudio.....	40
Figura 6: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 1950-1979	43
Figura 7: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 1980-2009	44
Figura 8: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 2010-2021	44
Figura 9: Diagrama de pasos metodológicos	57
Figura 10: Frecuencia de CTs por periodos de estudio	59
Figura 11: Relación entre velocidad del viento (kt) y presión mínima central (hPa) por periodo	60
Figura 12: Diagrama de caja y bigotes de velocidades máximas del viento por periodo	61
Figura 13: Diagrama de caja y bigotes de presiones mínimas centrales por periodo ..	62
Figura 14: Serie temporal de la velocidad máxima anual del viento (kt).....	67
Figura 15: Serie temporal de la presión mínima anual (hPa)	67
Figura 16: Densidad observada y ajuste GEV para la velocidad máxima del viento (1950-1979).....	70
Figura 17: Densidad observada y ajuste GEV para la presión mínima central (1950-1979)	71
Figura 18: Densidad observada y ajuste GEV para la velocidad máxima del viento (1980-2009).....	71
Figura 19: Densidad observada y ajuste GEV para la presión mínima central (1980–2009)	72

Figura 20: Densidad observada y ajuste GEV para la velocidad máxima del viento (2010-2021).....	73
Figura 21: Densidad observada y ajuste GEV para la presión mínima central (2010-2021)	73
Figura 22: Velocidad máxima del viento (1950-1979) bajo el modelo GEV.....	74
Figura 23: Presión mínima central (1950-1979) bajo el modelo GEV.....	74
Figura 24: Velocidad máxima del viento (1980-2009) bajo el modelo GEV.....	75
Figura 25: Presión mínima central (1980-2009) bajo el modelo GEV.....	75
Figura 26: Velocidad máxima del viento (2010-2021) bajo el modelo GEV.....	76
Figura 27: Presión mínima central (201-2021) bajo el modelo GEV.....	76
Figura 28: Niveles de retorno con intervalos de confianza al 95% estimados de velocidad máxima del viento (en nudos) para ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)	79
Figura 29: Niveles de retorno con intervalos de confianza al 95% estimados de presión mínima central (en hPa) para ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)	80
Figura 30: Probabilidades conjuntas por categoría de intensidad ciclónica (TS–Cat5) estimadas a partir de distribuciones GEV para viento y presión, por periodo histórico.	85
Figura 31: Probabilidades acumuladas de intensidad ciclónica para $\geq$ Cat 3, $\geq$ Cat 4 y $\geq$ Cat 5	86
Figura 32: Evolución de las probabilidades acumuladas por umbral de intensidad ciclónica (de $\geq$ Cat1 a $\geq$ Cat5) entre 1950-2021	87
Figura 33: Gráficos de trazas de los parámetros del modelo GEV para la variable velocidad máxima del viento.....	88
Figura 34: Gráficos de trazas de los parámetros del modelo GEV para la variable presión mínima central	89
Figura 35: Gráficos de autocorrelación para los parámetros μ , σ y ξ del modelo GEV aplicado a la velocidad máxima del viento, agrupados por periodo.....	90
Figura 36: Gráficos de autocorrelación para los parámetros μ , σ y ξ del modelo GEV aplicado a la presión mínima central, agrupados por periodo	90

Figura 37: Comparación entre la distribución observada y las distribuciones generadas por el modelo bayesiano para la velocidad máxima del viento	92
Figura 38: Comparación entre la distribución observada y las distribuciones generadas por el modelo bayesiano para la presión mínima central.....	93
Figura 39: Distribución de la media simulada del viento máximo frente a la media observada	94
Figura 40: Distribución de la media simulada de la presión mínima central frente a la media observada	94
Figura 41: Distribución de los valores máximos simulados del viento frente al valor máximo observado	95
Figura 42: Distribución de los valores máximos simulados de la presión mínima central frente al valor máximo observado	95
Figura 43: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 3 (1950-1979).....	97
Figura 44: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 3 (1980-2009).....	98
Figura 45: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 3 (2010-2021).....	98
Figura 46: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 4 (1950-1979).....	99
Figura 47: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 4 (1980-2009).....	100
Figura 48: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 4 (2010-2021).....	100
Figura 49: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 5 (1950-1979).....	101
Figura 50: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 5 (1980-2009).....	102
Figura 51: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 5 (2010-2021).....	102
Figura 52: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 3 (1950-2009).....	103

Figura 53: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 4 (1950-2009).....	104
Figura 54: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 5 (1950-2009).....	104
Figura 55: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq$ Cat3	106
Figura 56: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq$ Cat4	106
Figura 57: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq$ Cat5	107
Figura 58: Curva de calibración del modelo para la categoría $\geq$ Cat3	107
Figura 59: Curva de calibración del modelo para la categoría $\geq$ Cat4.....	108
Figura 60: Curva de calibración del modelo para las categorías $\geq$ Cat5.....	108
Figura 61: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (1950-1979)	130
Figura 62: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (1980-2009)	131
Figura 63: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (2010-2021)	131
Figura 64: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (1950-1979)	132
Figura 65: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (1980-2009)	132
Figura 66: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (2010-2021)	133
Figura 67: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (1950-1979)	133
Figura 68: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (1980-2009)	134
Figura 69: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (2010-2021)	134

Índice de Tablas

Tabla 1: Clasificación de ciclones tropicales según la Escala de Saffir–Simpson y sus valores promedio de presión mínima central en el Atlántico occidental.....	17
Tabla 2: Categorías y umbrales simultáneos utilizados en el modelo Beta-Binomial...	53
Tabla 3: Máximos anuales de viento y presión (1950-1979)	63
Tabla 4: Máximos anuales de viento y presión (1980-2009)	64
Tabla 5: Máximos anuales de viento y presión (2010-2021)	65
Tabla 6: Comparación estadística de la intensidad ciclónica anual por periodo	66
Tabla 7: Parámetros estimados del modelo GEV para velocidad del viento y presión mínima central ($\pm$ error estándar)	68
Tabla 8: Niveles de retorno estimados (en nudos) con Intervalos de Confianza (IC 95%) para viento máximo de ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)	78
Tabla 9: Niveles de retorno estimados (hPa) con Intervalos de Confianza (IC 95%) para presión mínima central de ciclones tropicales según periodo (1950–1979, 1980–2009 y 2010–2021).....	79
Tabla 10: Estimaciones posteriores del modelo bayesiano jerárquico para velocidad máxima del viento y presión mínima central	81
Tabla 11: Estimaciones posteriores de los parámetros GEV de viento máximo y presión mínima por periodo (modelo bayesiano)	82
Tabla 12: Probabilidades conjuntas por categoría e IC 95%, Periodo 1950-1979	83
Tabla 13: Probabilidades conjuntas por categoría e IC 95%, Periodo 1980-2009	83
Tabla 14: Probabilidades conjuntas por categoría e IC 95%, Periodo 2010-2021	84
Tabla 15: Métricas de validación espacial del modelo Beta-Binomial local para las estimaciones anuales de probabilidad condicional de intensificación ciclónica (2010–2021).	110
Tabla 16: Intervalos de credibilidad (95 %) de las probabilidades anuales	135
Tabla 17: Resumen del soporte observacional local (nlocal) por período.....	136

INTRODUCCIÓN

Los ciclones tropicales (CTs) intensos constituyen uno de los fenómenos hidrometeorológicos más devastadores que afectan las regiones tropicales, con impactos socioeconómicos que trascienden el evento inmediato. Investigaciones recientes del Instituto de Potsdam para la Investigación del Impacto Climático (Krichene et al., 2023) revelan que estos eventos extremos tienen la capacidad de frenar el desarrollo económico de un país durante más de una década, mientras que los modelos climáticos proyectan un aumento en su frecuencia e intensidad como consecuencia del calentamiento global. Esta tendencia sugiere que los períodos de recuperación entre eventos se reducirán progresivamente, generando costos acumulativos que superarán con creces los daños económicos directos.

En la cuenca del Atlántico Norte, que incluye el mar Caribe, el Golfo de México y la costa este de Estados Unidos, los datos resultan especialmente alarmantes. Según Klotzbach et al. (2023), esta región aporta aproximadamente el 20–25% de la energía ciclónica global (ACE), lo que subraya su relevancia en el contexto climático mundial. Estudios recientes han documentado un incremento del 40% en la ocurrencia de CTs intensos desde 1980 (Knutson et al., 2020). Las proyecciones del Sexto Reporte de Evaluación del Panel Intergubernamental sobre el Cambio Climático, particularmente del Grupo de Trabajo I sobre Bases Físicas, indican que esta tendencia se intensificará, con un aumento estimado del 20-30% en la intensidad de estos fenómenos para el año 2050, lo que plantea desafíos sin precedentes para los sistemas de alerta temprana en la región (Intergovernmental Panel on Climate Change [IPCC], 2023).

Dada esta realidad, el desarrollo de herramientas predictivas más precisas y confiables resulta siempre necesario. Una predicción acertada de la trayectoria y la intensidad de los CTs es un elemento clave para mitigar sus impactos. Los sistemas de pronóstico mejorados ofrecen beneficios sustanciales a los tomadores de decisiones y a los gestores de emergencias, al optimizar los tiempos de alerta temprana, delimitar con mayor precisión las zonas de evacuación, asignar recursos de forma más eficiente e incrementar la confianza pública en los sistemas oficiales de alerta. Estas capacidades fortalecen la institucionalidad y la credibilidad de los organismos responsables de la protección civil,

facilitando una respuesta más rápida y coordinada ante eventos ciclónicos, con el consecuente resguardo de vidas humanas y la reducción de pérdidas materiales.

El estudio de los CTs ha evolucionado significativamente desde los trabajos pioneros de Holland (1980), que establecieron las bases físicas para relacionar la presión mínima central con la velocidad del viento. Sin embargo, los enfoques deterministas tradicionales presentan limitaciones notables en la cuantificación de la incertidumbre (Emanuel, 2018), particularmente en el Caribe, donde factores locales, como la Corriente del Caribe y la cizalladura vertical del viento, modifican sustancialmente los patrones de intensificación (Valderá et al., 2021). Esta complejidad subraya la necesidad de desarrollar herramientas más robustas para el pronóstico y la comunicación de riesgos.

En este sentido, Conroy et al. (2023) evidencian limitaciones en los sistemas actuales de pronóstico de CTs, especialmente en la estandarización de metodologías probabilísticas y en la efectividad comunicacional de los productos generados. La representación gráfica tradicional mediante el cono de trayectoria, pese a su amplia adopción como herramienta de comunicación, presenta deficiencias para transmitir adecuadamente la naturaleza probabilística del pronóstico. Como señalan Kossin et al. (2020), su interpretación errónea puede llevar a subestimar el riesgo en zonas cercanas al cono o a sobrestimar la seguridad en áreas centrales. Esta representación unidimensional de la incertidumbre, limitada solo a la trayectoria, omite información sobre intensidad esperada y amenazas asociadas, lo que distorsiona la percepción del riesgo (Rappaport, 2014).

Superar estas deficiencias requiere un enfoque sistémico que integre modelización probabilística avanzada con estrategias de comunicación basadas en evidencia psicológica y social, asegurando que la información técnica se traduzca en acciones de preparación efectivas. En este contexto, el análisis estadístico bayesiano surge como un marco metodológico prometedor. A diferencia de los enfoques frecuentistas, el paradigma bayesiano modela los parámetros como variables aleatorias, permitiendo cuantificar de forma intuitiva la incertidumbre e incorporar conocimiento previo (priors) junto con datos observados (Gelman et al., 2013).

Aunque su adopción en hidrometeorología es todavía limitada, debido a la complejidad interpretativa y a la escasa formación especializada, estudios recientes han demostrado su potencial. Chu y Zhao (2007, 2011) y Song et al. (2018) aplicaron modelos bayesianos

en otras regiones ciclogénicas con resultados alentadores, mientras que Dietz et al. (2022) validaron su poder predictivo para mejorar la estimación de intensidad de CTs. En el Pacífico mexicano, Gutierrez-Lopez et al. (2025) combinaron el análisis de valores extremos con un enfoque bayesiano para producir mapas de probabilidad, identificando zonas críticas de vulnerabilidad costera. En particular, el uso de distribuciones extremas como Gumbel y GEV ha resultado adecuado para estimar la probabilidad de eventos poco frecuentes, pero de gran impacto.

En el análisis de eventos binarios y conteos acotados, distintos autores han resaltado la utilidad del marco Beta-Binomial. Por ejemplo, Bartoš et al. (2023) muestran que los priors empíricos mejoran la estabilidad inferencial al incorporar información previa moderada, mientras que Otto y Castelo (2025) evidencian que el modelo Beta-Binomial y sus extensiones ofrecen una representación flexible y robusta de la sobredispersión y los valores extremos en datos ambientales.

La base de datos IBTrACS (Knapp et al., 2010), en su versión v04 (2022), con importantes mejoras en la homogenización de los registros históricos, constituye un recurso fundamental para implementar análisis de intensidad ciclónica en el Caribe. No obstante, persiste la necesidad de avanzar en la comprensión y aplicación de conceptos como la probabilidad condicional, así como en la traducción de la incertidumbre estadística en herramientas operativas útiles para la gestión de riesgos.

Por tanto, el propósito central de esta investigación es contribuir al perfeccionamiento de las estimaciones probabilísticas de intensidad ciclónica dentro del dominio comprendido entre $15^{\circ} - 34^{\circ}N$ y $65^{\circ} - 98^{\circ}O$, en adelante referido como mar Caribe. Para ello, se emplean exclusivamente datos del repositorio IBTrACS v04 y se adopta un enfoque metodológico que combina la estadística de extremos, la inferencia bayesiana jerárquica y un modelo Beta-Binomial. A partir del análisis conjunto de dos variables físicas clave, la velocidad del viento y la presión atmosférica mínima central, se desarrolla una modelación que busca capturar adecuadamente la variabilidad inherente a los CTs y generar productos cartográficos aplicables a la planificación climática y la reducción del riesgo.

En este contexto, la ***pregunta central*** que orienta la investigación es la siguiente:

¿De qué manera pueden la velocidad del viento y la presión atmosférica ser utilizadas en un análisis bayesiano para pronosticar con probabilidades condicionadas la intensidad de los ciclones tropicales en el mar Caribe?

A partir de esta interrogante, se formula la siguiente ***hipótesis de investigación***:

“El análisis bayesiano con probabilidades condicionadas por la velocidad del viento y la presión atmosférica, pronostica en más de un 85 % la intensidad de los ciclones tropicales en el mar Caribe”.

Este umbral del 85 % corresponde al percentil 90 de la distribución de precisión obtenida en pruebas piloto preliminares (intervalo creíble 95 %: 82–88 %).

En consecuencia, esta tesis plantea como ***objetivo general***:

Desarrollar un análisis bayesiano que utilice probabilidades condicionadas por la velocidad del viento y la presión atmosférica para predecir la intensidad de los ciclones tropicales en el mar Caribe.

Los ***objetivos específicos*** que guían el desarrollo del estudio son:

1. Caracterizar la variabilidad espacio-temporal de los registros de ciclones tropicales en el mar Caribe.
2. Determinar probabilidades condicionadas por la velocidad del viento y la presión atmosférica para el pronóstico de la intensidad de los ciclones tropicales en el mar Caribe.
3. Validar el análisis bayesiano para el pronóstico de intensidad de ciclones tropicales en el mar Caribe.
4. Estimar mapas de pronóstico de intensidad de los ciclones tropicales en el mar Caribe, fundamentados en las probabilidades condicionadas determinadas.

Este estudio constituye un avance significativo en la predicción de CTs, superando las limitaciones de los enfoques deterministas tradicionales, mediante un protocolo de análisis probabilístico innovador. Integra de manera sistemática probabilidades condicionadas con series históricas del repositorio IBTrACS, generando nuevo conocimiento sobre los mecanismos de intensificación ciclónica en el Caribe y zonas adyacentes. Las contribuciones abarcan tres campos fundamentales:

- Modelación de eventos hidrometeorológicos extremos, mediante la cuantificación rigurosa de incertidumbre en las predicciones, mejorando la evaluación de riesgos mediante distribuciones probabilísticas específicas para la región.
- Meteorología tropical aplicada, al establecer relaciones estadísticas robustas entre variables físicas clave (velocidad del viento y presión atmosférica mínima central).
- Estadística aplicada, mediante la implementación de inferencia bayesiana para el pronóstico de CTs.

Más allá de mejorar la precisión predictiva, este enfoque ofrece herramientas metodológicas transferibles para el estudio de CTs en otras regiones tropicales, con aplicaciones directas en la gestión de riesgos y la planificación climática.

En el plano económico, los mapas de riesgo probabilísticos facilitan una planificación más eficiente de los recursos destinados a la gestión de desastres, al optimizar la asignación de fondos para acciones de prevención y mitigación en una región donde las pérdidas anuales superan los 270 mil millones de dólares (United Nations Office for Disaster Risk Reduction [UNDRR], 2021). Aunque el presente estudio no incluye un protocolo operativo, los productos cartográficos generados constituyen un insumo estratégico para que las autoridades locales ajusten y fortalezcan sus planes de contingencia.

En el ámbito social, la investigación beneficia a más de 40 millones de habitantes que residen en zonas costeras vulnerables. Los mapas de riesgo permiten una mejor comprensión de las amenazas ciclónicas, facilitando la toma de decisiones tanto a nivel institucional como comunitario. Al proporcionar estimaciones probabilísticas más precisas, este estudio contribuye a reducir la vulnerabilidad de la población y a salvar vidas durante la temporada de huracanes.

Los resultados obtenidos tienen implicaciones directas para la gestión del riesgo en América Latina y el Caribe, donde aún persisten importantes brechas en la capacidad operativa de los servicios meteorológicos. Según la Organización Meteorológica Mundial (OMM), el 47 % de los países miembros en la región únicamente proveen servicios meteorológicos básicos o esenciales, mientras que solo el 6 % cuentan con servicios

completos o avanzados, capaces de respaldar decisiones en sectores sensibles al clima y desarrollar pronósticos probabilísticos robustos (World Meteorological Organization [WMO], 2024).

Esta tesis se estructura en tres capítulos principales. El Capítulo 1 presenta el marco teórico y conceptual que sustenta la investigación, así como los estudios antecedentes. El Capítulo 2 describe detalladamente la metodología empleada, incluyendo el procesamiento de datos, el ajuste del modelo GEV, la implementación bayesiana y los procesos de validación. El Capítulo 3 expone los resultados obtenidos, su análisis e interpretación. Finalmente, se presentan las conclusiones generales y las recomendaciones derivadas del estudio.

I. MARCO TEÓRICO

1.1 Fundamentos físicos de los ciclones tropicales

1.1.1 Definición y clasificación operativa

En el mar Caribe, los ciclones tropicales (CTs) constituyen una de las amenazas hidrometeorológicas más severas por su capacidad de generar lluvias intensas, marejadas ciclónicas y vientos destructivos, con impactos sustanciales sobre comunidades vulnerables, infraestructura y medios de vida (WMO, 2022; Emanuel, 2005).

De acuerdo con la Organización Meteorológica Mundial (OMM), los CTs se definen como sistemas no frontales de escala sinóptica y núcleo caliente que se originan sobre aguas tropicales o subtropicales, con una convección profunda organizada y circulación cerrada de los vientos en superficie alrededor de un centro bien definido (WMO, 2022).

En el Atlántico Norte, el National Hurricane Center (NHC, 2012) establece que la clasificación de CTs se fundamenta en la velocidad del viento sostenido promedio a 1 minuto, medida a una altura estándar de 10 metros. Esta clasificación incluye tres etapas principales:

- *Depresión tropical*, sistema con vientos sostenidos de hasta 62 km/h.
- *Tormenta tropical*, ciclón bien organizado con vientos sostenidos entre 63 y 118 km/h.
- *Huracán*, sistema con vientos sostenidos iguales o superiores a 119 km/h.

Dentro del estadio de *Huracán*, se definen 5 categorías de acuerdo con la Escala de Vientos Huracanados Saffir-Simpson, que clasifica los CTs exclusivamente en función de la velocidad del viento sostenido (NOAA Hurricane Research Division, 2023).

La temporada oficial de CTs en la cuenca ciclogénica del Atlántico Norte, establecida por consenso entre el NHC y la OMM, se extiende del 1 de junio al 30 de noviembre, con un pico de actividad entre agosto y octubre (WMO, 2020; NHC, s.f.-b). Esta región es una de las más activas a nivel global (Klotzbach et al., 2023). En la Figura 1 extraída de la National Oceanic and Atmospheric Administration [NOAA] (s.f.), se muestran las principales zonas generadoras de estos sistemas alrededor del planeta.




Figura 1: Zonas ciclogénicas del planeta

1.1.2 Estructura interna y dinámica del sistema

Los CTs exhiben una estructura interna compleja y altamente organizada, centrada en un núcleo de baja presión atmosférica [ver Figura 2 extraída de BBC Mundo (2024)]. Esta organización obedece a principios dinámicos y termodinámicos que regulan el intercambio de energía entre la superficie oceánica y la atmósfera, siendo determinante en su intensidad y evolución temporal (Emanuel, 2005; Houze, 2010). En su configuración típica, el sistema presenta varios componentes bien definidos:

- *Ojo*: Se trata del centro del ciclón, una región de relativa calma caracterizada por nubosidad escasa, vientos débiles y la presión atmosférica más baja de todo el sistema. Su diámetro puede variar significativamente, oscilando entre 20 y 60 kilómetros, aunque en huracanes intensos puede superar esta dimensión. El ojo es el resultado de procesos de subsidencia en el núcleo cálido del ciclón, que estabilizan la columna de aire en esa zona (WMO, 2022; Emanuel, 2018).
- *Pared del ojo*: Rodeando al ojo se encuentra una región de intensa convección denominada pared del ojo, donde se concentran los vientos máximos sostenidos, las precipitaciones más intensas y los mayores gradientes de presión. Esta zona actúa como el motor energético del ciclón, ya que aquí ocurre la mayor liberación de calor latente proveniente de la condensación de humedad oceánica (Frank, 1977; Rogers et al., 2013).

- *Bandas espirales de lluvia:* Estas bandas se extienden desde las regiones externas hacia el centro del sistema en una configuración helicoidal. Son estructuras convectivas que transportan calor y humedad desde el océano hacia el núcleo del ciclón, alimentando la convección interna. Su presencia y organización determinan el grado de simetría y la capacidad del sistema para intensificarse rápidamente (Emanuel, 2018; WMO, 2022).

La eficiencia del sistema en el mantenimiento e intensificación de su estructura depende en gran medida de la simetría horizontal de sus componentes y de la alineación vertical del eje convectivo. Un ciclón tropical bien organizado muestra una correspondencia vertical entre las capas bajas y altas de la troposfera, lo cual facilita la retroalimentación positiva entre la convección profunda, la caída de presión central y el incremento del viento en superficie (Emanuel, 2005; Houze, 2010). Por el contrario, CTs inclinados o asimétricos tienden a debilitarse debido a la pérdida de eficiencia en la conversión energética.



Figura 2: Estructura de un huracán a partir de vista superior

1.1.3 Condiciones de génesis e intensificación

La formación de un ciclón tropical requiere la concurrencia de condiciones atmosféricas y oceanográficas específicas, que permiten la evolución de una perturbación preexistente como una onda tropical generada en la costa occidental del continente africano hacia un sistema organizado, con circulación ciclónica cerrada y convección profunda (Emanuel, 2003; Gray, 1968). Este proceso se sustenta en el aporte energético del océano y en la interacción sinérgica de factores dinámicos y termodinámicos, bien documentados por décadas de estudios (Frank & Ritchie, 1999; Camargo et al., 2007).

Uno de los requisitos fundamentales es que la temperatura de la superficie del mar (TSM) supere los 26 °C en los primeros 50 a 100 metros de profundidad, lo que garantiza una transferencia eficiente de calor y humedad hacia la atmósfera. Este calor almacenado alimenta la formación de convección profunda, liberando calor latente de condensación, que fortalece la estructura del sistema desde su núcleo (Vecchi & Soden, 2007; Trenberth & Fasullo, 2007).

Simultáneamente, la atmósfera debe presentar altos niveles de humedad relativa en la troposfera media, lo que favorece el ascenso sostenido del aire cálido y húmedo sin ser limitado por capas secas. Por otro lado, la cizalladura vertical del viento, definida como la diferencia en velocidad y dirección entre niveles bajos y altos, debe ser débil. Si la cizalladura es fuerte, puede desorganizar la convección, inclinar la columna del sistema y dificultar la intensificación (Frank & Ritchie, 2001; Tang & Emanuel, 2012).

Se requiere la ocurrencia de una presión atmosférica relativamente baja, tanto en superficie como en niveles medios, lo cual favorece el establecimiento de una circulación ciclónica cerrada. Esta circulación solo puede desarrollarse cuando el sistema se encuentra a más de cinco grados de latitud del ecuador, ya que se necesita la acción del efecto de Coriolis para inducir rotación (Gray, 1968).

Además, la presencia de aerosoles inhibidores de convección, como el polvo del Sahara, puede limitar el desarrollo ciclónico al introducir aire seco en la atmósfera media y estabilizar el perfil térmico, reduciendo la actividad convectiva (Dunion & Velden, 2004; Braun, 2010).

Estas condiciones de formación también se ven moduladas por fenómenos de variabilidad climática natural, tales como el El Niño-Oscilación del Sur (ENSO), la Oscilación de Madden-Julian (MJO) y la Oscilación del Atlántico Norte (NAO). En particular, ENSO desempeña un papel clave: durante eventos de El Niño, se intensifica la cizalladura vertical en el Atlántico tropical, lo que tiende a reducir la frecuencia de huracanes, mientras que en condiciones de La Niña ocurre lo contrario (Wang et al., 2025). La MJO, por su parte, modula la convección y la humedad a escala intraestacional, facilitando o suprimiendo la formación ciclónica dependiendo de su fase (Camargo et al., 2007; Klotzbach, 2023).

Cuando estas condiciones se combinan de forma favorable, el sistema puede entrar en un ciclo de retroalimentación positiva: la convección profunda organizada induce una disminución de la presión central, lo cual intensifica el gradiente de presión y acelera los vientos, reforzando así la circulación ciclónica. Este proceso puede derivar en fases de intensificación rápida, particularmente si el ciclón se desplaza sobre aguas cálidas y en un entorno con baja cizalladura vertical del viento (Kaplan & DeMaria, 2003).

Por otro lado, múltiples estudios han demostrado que el cambio climático de origen antropogénico influye de manera significativa en la génesis e intensificación de los CTs. El aumento sostenido de las temperaturas oceánicas, derivado del calentamiento global, ha favorecido el incremento en la frecuencia de huracanes de alta categoría e intensificado los episodios de rápida intensificación en las últimas décadas (Emanuel, 2017; Knutson et al., 2020; Méndez-Tejeda & Hernández-Ayala, 2023). Estimaciones actuales de atribución climática sugieren que la velocidad máxima de los huracanes del Atlántico ha aumentado, en promedio, un 10 % en los últimos decenios, como consecuencia, al menos parcial, del calentamiento global (Kossin et al., 2020).

Un estudio reciente de Bhatia et al. (2022), aporta evidencia de un aumento estadístico de velocidades de intensificación rápida en CTs en múltiples cuencas. Los autores identifican que ambientes termodinámicos más cálidos, mayor contenido de calor oceánico y humedad relativa contribuyen a que estos episodios extremos se vuelvan más probables, respaldados por modelos climáticos que muestran una clara influencia del forzamiento antropogénico.

En el contexto del Atlántico Norte, diversas investigaciones contemporáneas documentan un aumento sustancial en las tasas de intensificación de CTs, en paralelo con condiciones oceánicas más cálidas y anomalías térmicas en capas subsuperficiales. Por ejemplo, Garner (2023) encontró que las velocidades máximas de intensificación observadas en la base de datos HURDAT2 durante el periodo moderno (2001–2020) son entre un 28 % y un 29 % superiores a las registradas entre 1971 y 1990, en ventanas de 24 y 36 horas, lo cual sugiere que los huracanes actuales se intensifican más rápidamente que en décadas anteriores. De forma complementaria, Liu et al. (2025) demostraron que el huracán Ian de 2022 experimentó intensificación rápida sobre una plataforma continental donde las aguas subsuperficiales estaban entre 2 y 3 °C por encima de lo normal, lo que proporcionó al sistema un aporte térmico adicional clave para su fortalecimiento. Por su parte, Majumdar et al. (2023) reportan que, aunque la tendencia de intensificación rápida en la cuenca del Atlántico Norte ha aumentado en general entre los periodos 1980-2000 y 2001-2021 (~36 %), este aumento es espacialmente heterogéneo. Los mayores incrementos se observan al sur de aproximadamente 22° N, lo que sugiere que el calentamiento oceánico ejerce una influencia particularmente fuerte en las latitudes tropicales bajas.

Todas estas variables son consideradas en los modelos de simulación numérica y estadística, los cuales permiten proyectar trayectorias, estimar el potencial de intensificación y construir escenarios probabilísticos de riesgo, fundamentales para el diseño de sistemas de alerta temprana y la gestión del riesgo hidrometeorológico (Camargo & Wing, 2016; Knutson et al., 2020).

1.1.4 Intensidad e impactos hidrometeorológicos

Comprender qué tan intensos pueden llegar a ser los CTs es fundamental para anticipar los riesgos que representan, tanto en términos de daños estructurales como de afectaciones a la población. Este tipo de sistemas meteorológicos no solo genera fuertes vientos, sino que también puede provocar lluvias torrenciales, marejadas ciclónicas, inundaciones extensas y otros fenómenos de gran impacto (NHC, s.f.-a).

Desde un punto de vista físico, la intensidad de un ciclón se relaciona principalmente con dos variables: la velocidad máxima del viento sostenido y la presión atmosférica mínima

en el centro del sistema. La primera suele usarse como parámetro operativo para clasificar al ciclón, mientras que la segunda actúa como un buen predictor de su potencia, ya que, a menor presión central, mayor suele ser el gradiente de presión que impulsa los vientos periféricos (Kossin et al., 2020; Blake et al., 2011).

Estas características no se presentan de forma aislada. Por ejemplo, una presión central especialmente baja suele asociarse con una intensa convección profunda, y ésta, a su vez, depende de factores como la temperatura del océano, la disponibilidad de humedad en la atmósfera media y una cizalladura vertical del viento suficientemente débil para que el sistema no se desorganice (Emanuel, 2005). Este equilibrio energético, en el que interviene también el flujo de calor latente desde la superficie del mar, es lo que permite que un ciclón se fortalezca rápidamente o, por el contrario, se debilite si las condiciones cambian.

Entre los efectos más peligrosos de estos sistemas se encuentran las lluvias intensas, que pueden provocar desbordamientos repentinos de ríos, deslaves o inundaciones prolongadas, así como vientos que superan fácilmente los 150 km/h y tienen el potencial de colapsar estructuras, derribar árboles o causar interrupciones severas en los servicios esenciales (WMO, 2022). También pueden generarse marejadas que penetran tierra adentro, especialmente si coinciden con la marea alta.

La intensidad no siempre determina la magnitud de la lluvia que puede generar; CTs de baja categoría o incluso tormentas tropicales pueden ocasionar precipitaciones devastadoras si se mueven lentamente o interactúan con terrenos montañosos o sistemas frontales estacionarios. Ejemplos de este comportamiento han sido documentados en diversos estudios, donde se destaca cómo la combinación de factores orográficos y una atmósfera saturada puede dar lugar a acumulados extremos de lluvia, con independencia del nivel de viento (Lonfat et al., 2004; Instituto de Meteorología de Cuba [INSMET], 2019).

Si bien es imposible eliminar por completo los impactos que genera el paso de un ciclón tropical, la experiencia documentada en distintas regiones indica que la implementación de planes de emergencia actualizados, la existencia de sistemas de alerta temprana eficaces y la promoción de estrategias de preparación comunitaria son factores

determinantes para reducir de manera significativa tanto las pérdidas humanas como los daños económicos asociados (Rappaport, 2014; WMO, 2022).

La planificación y los sistemas de alerta temprana son decisivos en la región. Autores como Pielke et al. (2008); Peduzzi et al. (2009); Nordhaus (2010) y Strobl (2012) ofrecen diferentes enfoques y estudios sobre los impactos económicos y sociales de los ciclones tropicales, abarcando desde análisis de daños históricos hasta evaluaciones de vulnerabilidad y repercusiones económicas. La Comisión Económica para América Latina y el Caribe (CEPAL) durante los últimos 20 años ha reconocido y alertado sobre el riesgo que representan estos fenómenos y principalmente por el aumento de su frecuencia e intensidad debido al cambio climático (Alatorre et al., 2020).

1.1.5 Relación viento-presión y aproximaciones empíricas

En los CTs, la intensidad de los vientos está directamente asociada al gradiente de presión entre el centro del sistema y su entorno. Este gradiente impulsa la aceleración del viento, conforme lo establece el *balance ciclostrófico*, el cual describe el equilibrio entre la fuerza centrífuga, la fuerza de Coriolis y el gradiente de presión. La siguiente expresión resume esta interacción:

$$\frac{V^2}{r} + fV \approx \frac{1}{\rho} \frac{\Delta P}{\Delta r} \quad (1)$$

donde:

- V = velocidad del viento,
- r = distancia desde el centro,
- f = parámetro de Coriolis,
- ΔP = diferencia de presión (presión ambiental menos presión central),
- ρ = densidad del aire.

Una presión mínima central más baja implica un gradiente de presión más agudo, lo cual intensifica los vientos y, por ende, la severidad del CTs (Emanuel, 2003). No obstante, debido a la complejidad dinámica y estructural de estos sistemas, se han formulado diversas relaciones empíricas para estimar una variable a partir de la otra (viento o

presión), con base en observaciones satelitales, aeronaves de reconocimiento o registros históricos.

Una de las relaciones más utilizadas es la propuesta por Dvorak (1984), derivada de la técnica operativa homónima para estimar la intensidad ciclónica a partir de imágenes satelitales. Esta fórmula vincula la presión mínima central con la velocidad máxima del viento sostenido mediante una expresión empírica:

$$V_{max} \approx k \cdot \sqrt{P_{amb} - P_{min}} \quad (2)$$

donde:

- V_{max} = velocidad del viento máximo sostenido (en nudos, $1 \text{ kt} \approx 1.85 \text{ km/h}$).
- P_{amb} = presión ambiental ($\sim 1010 \text{ hPa}$)
- P_{min} = presión central del ciclón
- $k \approx 6.3$ (constante empírica)

Esta relación ha sido ampliamente empleada en análisis operacionales cuando no se dispone de datos directos, y constituye la base de técnicas satelitales modernas como el Advanced Dvorak Technique (ADT) (Velden et al., 2006).

Basada en prácticas operativas del NHC y en la síntesis metodológica presentada por Knaff y Zehr (2007), en la cuenca del Atlántico Norte se ha adoptado una fórmula empírica ajustada que vincula la presión mínima central con la intensidad del viento máximo. Aunque no atribuible a una única fuente formal, esta expresión ha sido utilizada ampliamente en reanálisis retrospectivos y en estudios de modelación climatológica, especialmente cuando se dispone únicamente de registros de presión central. La ecuación emplea un coeficiente mayor y una presión ambiental promedio de 1013 hPa :

$$V_{max} \approx 6.7 \cdot \sqrt{1013 - P_{min}} \quad (3)$$

donde V_{max} representa la velocidad del viento sostenido a 1 minuto (en kt) y P_{min} corresponde a la presión mínima central (en hPa). Esta forma simplificada permite obtener estimaciones razonables de intensidad ciclónica en contextos históricos u operacionales con datos limitados, como ocurre frecuentemente en bases como HURDAT2.

En un estudio más reciente, Knaff y Zehr (2007) reexaminaron la relación presión–viento utilizando un conjunto ampliado de datos de CTs y técnicas de regresión no lineal. A diferencia de las aproximaciones anteriores basadas en relaciones cuadráticas, su propuesta incorpora ajustes específicos por cuenca.

Para el Atlántico Norte, la relación propuesta es:

$$V_{max} = 6.7 \times (1010 - P_{min})^{0.644} \quad (4)$$

- V_{max} : velocidad máxima del viento sostenido (en nudos),
- P_{min} : presión mínima central del ciclón (en hPa),
- 1010: presión ambiental de referencia para la cuenca del Atlántico,
- 6.7 y 0.644: coeficientes derivados empíricamente.

Esta formulación ha demostrado un mejor ajuste a los datos de reconocimiento en comparación con las relaciones clásicas cuadráticas, y se considera especialmente útil en aplicaciones de reanálisis climatológico, modelos de intensidad y estudios históricos donde los datos instrumentales son limitados o indirectos.

Basada en información del NHC y adaptada específicamente al dominio de estudio comprendido entre $15^\circ - 34^\circ N$ y $65^\circ - 98^\circ O$, se presenta una clasificación que permite categorizar los CTs según su velocidad del viento sostenido y, de forma complementaria, su presión atmosférica mínima central promedio observada en el Atlántico occidental.

Aunque la Escala de Vientos Huracanados de Saffir–Simpson se define formalmente únicamente por la velocidad del viento sostenido a 1 minuto (NHC, 2012), la inclusión de rangos típicos de presión mínima resulta útil como referencia adicional de intensidad, especialmente en estudios de reanálisis y modelación estadística.

En la Tabla 1 se detallan las categorías que conforman dicha escala, expresadas en tres unidades comunes de velocidad del viento (km/h, nudos [kt] y millas por hora [mph]), junto con los intervalos aproximados de presión mínima típicamente asociados en la región de estudio y una descripción cualitativa de los daños potenciales esperados por categoría. Esta tabla sirve como referencia para interpretar los niveles de intensidad

utilizados en los análisis que se desarrollan en las secciones posteriores del presente trabajo.

Tabla 1: Clasificación de ciclones tropicales según la Escala de Saffir–Simpson y sus valores promedio de presión mínima central en el Atlántico occidental

Categoría	Velocidad del viento (km/h, nudos, mph)	Presión mínima típica (hPa)	Daños potenciales
Tormenta Tropical (TS)	63 – 118 km/h	> 990 hPa	Árboles pequeños dañados, techos menores.
	34 – 63 kt		
	39 – 73 mph		
Categoría 1	119 – 153 km/h	980 – 989 hPa	Daños mínimos; árboles y postes dañados.
	64 – 82 kt		
	74 – 95 mph		
Categoría 2	154 – 177 km/h	965 – 979 hPa	Daños moderados; techos y ventanas afectados.
	83 – 95 kt		
	96 – 110 mph		
Categoría 3	178 – 208 km/h	945 – 964 hPa	Daños extensos; casas sin techo, corte de energía prolongado.
	96 – 112 kt		
	111 – 129 mph		
Categoría 4	209 – 251 km/h	920 – 944 hPa	Daños catastróficos; colapso de estructuras.
	113 – 136 kt		
	130 – 156 mph		
Categoría 5	≥ 252 km/h	< 920 hPa	Daños devastadores; destrucción total en zonas impactadas.
	≥ 137 kt		
	≥ 157 mph		

1.2 Pronóstico de trayectoria e intensidad

1.2.1 Forzamientos sinópticos y guías de trayectoria

La trayectoria de los CTs en el Atlántico Norte está fuertemente determinada por patrones de circulación atmosférica a gran escala, principalmente por el campo de viento medio en

niveles de 500 *hPa*, que actúa como una guía de desplazamiento. Estos forzamientos sinópticos son esenciales para comprender y predecir la dirección y velocidad del desplazamiento de los ciclones, ya que su interacción con el entorno determina si el sistema mantiene una trayectoria zonal, se curva hacia latitudes medias o se desvía por forzamientos locales.

Dentro de estos forzamientos sinópticos, uno de los sistemas más influyentes es el anticiclón subtropical del Atlántico, comúnmente denominado anticiclón de las Bermudas-Azores, cuya localización y extensión modulan la dirección general del movimiento ciclónico (Kossin et al., 2010).

Durante los meses de verano y principios del otoño, este anticiclón puede adoptar configuraciones variables que influyen decisivamente en las trayectorias. Cuando el sistema de altas presiones se expande hacia el oeste, suele canalizar los CTs hacia el Caribe, el golfo de México y la costa mexicana, favoreciendo trayectorias más zonales. En contraste, si el anticiclón se desplaza hacia el este o se debilita, se habilita la recurvatura de los ciclones hacia el norte o noreste, dirigiéndolos hacia la costa este de Estados Unidos o mar abierto.




Figura 3: *Influencia del Anticiclón de Bermudas-Azores en las trayectorias típicas de los ciclones tropicales en el Atlántico*

Estas interacciones se esquematizan en la Figura 3, donde se ilustra la influencia dinámica del anticiclón sobre el trayecto esperado de un ciclón tropical en función de su ubicación estacional (BBC Mundo, 2024). Este conocimiento resulta esencial tanto para los modelos numéricos de predicción operativa como para la evaluación del riesgo hidrometeorológico en regiones vulnerables de la cuenca atlántica.

No obstante, el anticiclón subtropical no actúa de forma aislada. Existen otros forzamientos sinópticos y guías de trayectoria complementarias que influyen según la posición del ciclón, su intensidad y el estado general de la atmósfera como son:

- *Corriente en chorro subtropical y polar*: en etapas maduras o durante fases de recurvatura, la interacción con el jet subtropical puede acelerar el movimiento del ciclón hacia el noreste. Además, el chorro puede generar cizalladura vertical, afectando indirectamente su estructura e intensidad (Zhou et al., 2023).
- *Vaguadas en niveles medios*: depresiones amplias en el campo de 500 hPa pueden producir canales de debilidad en el flujo ambiente, permitiendo desvíos de trayectoria del ciclón, particularmente en latitudes medias. Estudios muestran que huracanes al interactuar con *upper-level troughs* tienden a virar hacia el noreste durante la transición extratropical. (Studholme, et al., 2015; Sato et al., 2020).
- *Topografía y forzamientos de baja altitud*: Estudios idealizados han demostrado que, al aproximarse un ciclón tropical a una cadena montañosa alargada, tanto la ubicación del impacto en tierra (*landfall*) como el ángulo de aproximación son factores determinantes en la desviación de su trayectoria. Estas condiciones pueden inducir un desvío inicial hacia el sur (*upstream*), seguido por efectos de bloqueo orográfico sobre el relieve, y una posterior modificación del desplazamiento en dirección opuesta (*downstream*), dependiendo de la interacción entre el ciclón y la topografía circundante (Liu et al., 2016).
- *Distribución térmica oceánica*: la temperatura superficial del mar (TSM) y los gradientes oceánicos son determinantes del potencial de intensidad de los CTs (Ren et al., 2014), y condicionan asimismo dónde pueden desarrollarse y mantenerse con fuerza, lo que puede influir indirectamente en sus trayectorias preferentes (Emanuel, 2005).

- *Moduladores climáticos de gran escala*: oscilaciones como El Niño–Oscilación del Sur (ENSO), la Madden-Julian Oscillation (MJO) o la Oscilación del Atlántico Norte (NAO) modifican el patrón general de circulación, alterando la posición del anticiclón subtropical, la cizalladura vertical y la configuración de vientos guía en la cuenca atlántica (Aiyyer & Thorncroft, 2006; Camargo et al., 2007).

El análisis conjunto de estos elementos permite una comprensión más robusta del entorno sinóptico en el que se desarrollan los CTs y resulta fundamental para mejorar la precisión en los modelos de pronóstico de trayectoria.

1.2.2 Representación visual del pronóstico: “cono de incertidumbre”

Uno de los productos visuales más difundidos y operativamente relevantes en el seguimiento de CTs es el denominado cono de incertidumbre. Este gráfico probabilístico, generado por centros meteorológicos como el NHC, representa la trayectoria proyectada del centro del sistema ciclónico y el área promedio de error asociada a dicha predicción, basada en datos históricos recientes de desempeño de modelos (NHC, 2023; Rappaport, 2009).

El cono no indica directamente el área afectada por los vientos, lluvias o marejadas, sino que delimita la región dentro de la cual es probable que se ubique el centro del ciclón en momentos futuros, generalmente hasta cinco días. Su diseño reconoce que el pronóstico del tiempo conlleva incertidumbre, y por ello busca comunicar de forma clara el rango de posibles trayectorias a medida que aumenta el horizonte temporal del pronóstico.

En la Figura 4 se ejemplifica este producto gráfico aplicado a un ciclón tropical potencial, es decir, un sistema aún en desarrollo, pero con alta probabilidad de convertirse en ciclón (NHC, 2017).

El mapa muestra los puntos de posición estimada del sistema en intervalos de tiempo (día y hora), acompañados de letras que identifican el tipo previsto de sistema en cada etapa:

- D: Depresión tropical
- S: Tormenta tropical
- H: Huracán de categoría 1 o 2
- M: Huracán mayor (categoría 3 o superior)



Figura 4: Mapa de cono de trayectoria y simbología asociada para un ciclón tropical potencial

Además del cono, el gráfico incorpora un sistema de colores de vigilancia y aviso. Las zonas bajo vigilancia de tormenta tropical se destacan en amarillo, y las de vigilancia de huracán en rosa; mientras que los avisos activos se representan en azul (tormenta) o rojo (huracán), en función del grado de inminencia del evento. Esta simbología estandarizada facilita la interpretación pública y técnica del riesgo proyectado en tiempo real.

La representación del cono no solo es una herramienta de comunicación operativa, sino también un elemento clave en la toma de decisiones para evacuación, activación de protocolos de emergencia y planificación de respuesta rápida ante desastres (Dormady et al., 2021).

1.2.3 Sistemas de observación en tiempo real

Los sistemas de observación, tanto in situ como remotos, cumplen un rol esencial en la detección, caracterización y seguimiento de los CTs. La calidad y frecuencia de estos datos inciden directamente en la confiabilidad de los pronósticos y la capacidad de respuesta ante eventos de alto impacto.

Una de las fuentes más confiables de datos es el reconocimiento aéreo realizado por aeronaves especializadas, conocidos como *Hurricane Hunters*, operadas por la NOAA y la Fuerza Aérea de Estados Unidos (USAF, por sus siglas en inglés). Estos vuelos penetran directamente el sistema ciclónico, recolectando datos en tiempo real de presión central, vientos sostenidos, ráfagas, temperatura, humedad relativa y campos de precipitación, mediante sondas de caída (*dropsondes*) y radares Doppler a bordo. Esta información permite caracterizar con alta precisión la estructura interna del ciclón y alimentar modelos de alta resolución (NOAA, 2023; USAF, s. f.; UCAR, s. f.; Hurricane Science, s. f.).

Los satélites geoestacionarios y polares representan otra fuente esencial de observación de CTs. Por ejemplo, GOES-16 proporciona imágenes infrarrojas que han sido utilizadas para investigar la intensificación rápida de ciclones, permitiendo seguir la evolución de la convección y estructura nubosa en tiempo casi continuo, admitiendo resoluciones temporales bastante altas en los canales infrarrojo. Además, misiones satelitales con sensores de microondas como GMI (en GPM) y SMAP permiten estimar indirectamente variables críticas como precipitación, viento de superficie oceánico, cobertura de nubes y humedad atmosférica, lo que contribuye a mejorar los modelos de predicción (Munsell et al., 2021; Meissner et al., 2017; NASA/GPM, 2020).

Estos datos son procesados mediante algoritmos de estimación como la técnica ADT, que permite derivar la intensidad del sistema a partir de firmas satelitales, especialmente en ausencia de datos in situ (Dvorak, 1984). La combinación de observaciones satelitales y aéreas mejora significativamente la capacidad de los modelos numéricos para reproducir la estructura inicial de los CTs, lo cual es crucial para la calidad del pronóstico.

1.2.4 Modelos de predicción ciclónica

El pronóstico de CTs ha evolucionado significativamente desde enfoques deterministas, fundamentados en la simulación física del sistema atmosférico, hacia modelos estadísticos y probabilísticos que incorporan la incertidumbre inherente a los fenómenos no lineales y extremos. Esta transición responde tanto al avance en la capacidad computacional como a la necesidad de mejorar la representación del riesgo y la toma de decisiones en escenarios inciertos.

a) Modelos numéricos deterministas: fundamentos y limitaciones

Los modelos deterministas constituyen la base tradicional del pronóstico de ciclones tropicales (CTs), al simular el comportamiento atmosférico mediante la resolución numérica de las ecuaciones de la dinámica de fluidos y los principios de la termodinámica. Estos modelos incorporan condiciones iniciales observadas (temperatura, humedad, presión, viento, etc.) y parametrizaciones físicas que representan procesos subresueltos, como la convección o la fricción superficial. Las simulaciones se actualizan típicamente cada 6 o 12 horas y permiten anticipar la evolución de la trayectoria e intensidad de los CTs en distintas escalas temporales.

Entre los modelos numéricos más relevantes para el seguimiento de estos fenómenos meteorológicos en la cuenca del Atlántico Norte se encuentran:

- *GFS (Global Forecast System)*: Modelo global desarrollado por la NOAA, con capacidad de pronóstico hasta 16 días, actualizado cada 6 horas (NOAA, 2022).
- *HWRF (Hurricane Weather Research and Forecasting)*: Específicamente diseñado para CTs; integra datos satelitales y oceanográficos para mejorar la predicción de trayectoria e intensidad (Tallapragada, 2016).
- *GFDL (Geophysical Fluid Dynamics Laboratory)*: Reproduce la dinámica interna de los ciclones, considerando la temperatura superficial del mar y la cizalladura vertical del viento (Murakami et al., 2025).
- *ECMWF (European Centre for Medium-Range Weather Forecasts)*: Reconocido por su precisión y resolución, aunque con acceso restringido en algunos países (ECMWF, 2023; Magnusson et al., 2014).
- *NAM (North American Mesoscale Model)*: Adecuado para pronósticos de corto plazo en América del Norte, incluyendo eventos asociados a sistemas tropicales (NOAA/NCEI, s. f.).
- *UKMET (UK Met Office Model)*: Combina simulaciones globales y regionales para mejorar la interacción entre ciclones y sistemas sinópticos (Met Office, 2023).
- *RSM (Regional Spectral Model)*: Ideal para pronósticos de alta resolución en el Caribe y el Atlántico occidental (Misra & Jayasankar, 2022).

- *WRF (Weather Research and Forecasting Model)*: Modelo ampliamente utilizado en investigación y operaciones, por su flexibilidad y capacidad de configuración regional (Skamarock et al., 2019).

A pesar de sus avances, estos modelos enfrentan limitaciones relevantes, particularmente en la predicción de eventos extremos como la intensificación rápida o la caída súbita de presión central, en parte debido a su dependencia de condiciones iniciales precisas. Además, existen restricciones operativas como la escasez de datos in situ sobre regiones oceánicas remotas y la representación limitada de procesos subgrid, es decir, aquellos que ocurren a escalas menores que el tamaño de celda del modelo (DeMaria et al. 2021; Zhang, 2025).

Estos procesos, que incluyen la convección profunda, la turbulencia submesoescala y las interacciones microfísicas en nubes, deben ser representados mediante parametrizaciones, lo que introduce incertidumbre en la simulación del desarrollo e intensificación ciclónica (Wu & Duan, 2023; Emanuel, 2018). Esta incertidumbre es particularmente crítica en el pronóstico de fenómenos intensos de corta duración, donde pequeñas diferencias en las condiciones iniciales pueden amplificarse rápidamente.

Estudios como los de Li et al. (2020) y Ogata et al. (2016) subrayan la importancia de mejorar la resolución vertical y emplear modelos acoplados océano-atmósfera de alta resolución, para representar con mayor realismo los procesos físicos que gobiernan la génesis, intensidad y evolución de los CTs.

b) Modelos probabilísticos

Ante las limitaciones inherentes de los modelos deterministas, los enfoques probabilísticos se han consolidado como herramientas fundamentales para el pronóstico de CTs. A diferencia de los modelos tradicionales que generan una única trayectoria o intensidad prevista, los métodos probabilísticos entregan distribuciones de probabilidad que reflejan un conjunto de escenarios posibles, incorporando de manera explícita la incertidumbre asociada a la predicción.

Una de las estrategias más comunes es el uso de sistemas de ensamble (ensembles, en inglés), en los que se ejecutan múltiples simulaciones del mismo modelo con

perturbaciones controladas en las condiciones iniciales o en los parámetros físicos. Este enfoque permite evaluar la sensibilidad del pronóstico y cuantificar la dispersión de resultados, lo que es esencial para sistemas no lineales como los CTs. Un ejemplo destacado es el *GEFS (Global Ensemble Forecast System)*, que proporciona pronósticos probabilísticos de trayectoria e intensidad ampliamente utilizados por agencias meteorológicas operativas (Zhou et al., 2023).

Para mejorar la calibración y la utilidad práctica de estos ensambles, se han desarrollado técnicas estadísticas de posprocesamiento como el *Bayesian Model Averaging (BMA)* y el *Ensemble Model Output Statistics (EMOS)*. Estas herramientas combinan múltiples salidas modeladas bajo un marco estadístico coherente, optimizando así la representación de la incertidumbre y ajustando la dispersión del ensamble al comportamiento observado del sistema (Gneiting & Raftery, 2005).

Un producto emblemático de los enfoques probabilísticos es el cono de incertidumbre del NHC. Este gráfico delimita el área dentro de la cual es probable que se ubique el centro del ciclón en diferentes horizontes temporales, con base en errores históricos de predicción. Sin embargo, no debe interpretarse como un indicador directo de la extensión del sistema o del área de impacto, advertencia destacada por estudios como el de Rappaport (2009), que señalan la necesidad de comunicar claramente los límites de estos productos para una gestión eficaz del riesgo.

A su vez, la inferencia bayesiana ha sido incorporada como técnica de posprocesamiento para actualizar distribuciones de probabilidad a partir de datos observados, integrando *priors* históricos y evidencia reciente. Este enfoque permite capturar la incertidumbre epistemológica y generar pronósticos probabilísticos más robustos (Emanuel, 2018).

En conjunto, los modelos probabilísticos permiten estimar la probabilidad de alcanzar umbrales críticos de intensidad (por ejemplo, $\geq$ *Categoría 3* en la escala Saffir–Simpson), generar mapas de incertidumbre espacial, y respaldar decisiones en sistemas de alerta temprana, planificación territorial y evaluación de riesgos climáticos. Su integración en marcos operativos y de investigación es cada vez más indispensable, particularmente en regiones expuestas como el Caribe, donde el margen de error puede tener implicaciones significativas en vidas humanas y daños materiales.

A pesar de estos avances, persisten desafíos metodológicos en la detección y seguimiento de CTs dentro de modelos climáticos globales de alta resolución. Wu y Duan (2023) advierten que los esquemas aplicados en los modelos CMIP6 emplean múltiples detectores y umbrales fijos sobre cuadrículas, lo que incrementa el costo computacional y puede reducir la consistencia entre modelos. Además, la escasa evaluación cuantitativa de su desempeño, especialmente en cuencas tropicales menos monitoreadas, limita su aplicabilidad en contextos operativos. Estas limitaciones refuerzan la necesidad de marcos probabilísticos calibrados que sean tanto estadísticamente sólidos como computacionalmente eficientes.

c) *Modelos estadísticos tradicionales*

Desde la década de 1970, se han desarrollado diversos modelos estadísticos clásicos que actúan como herramientas base para el pronóstico de trayectoria e intensidad de CTs. Estos enfoques han sido fundamentales en la transición desde esquemas puramente deterministas hacia métodos más adaptativos, especialmente cuando se cuenta con series históricas extensas y observaciones ambientales confiables.

Entre los métodos más representativos se encuentran:

- *Modelos de regresión lineal y múltiple*, los cuales permiten estimar variables clave como la velocidad máxima del viento (V_{max}) o la presión mínima central (P_{min}) en función de predictores ambientales tales como la temperatura superficial del mar, la cizalladura vertical del viento y la humedad relativa. Estos modelos fueron ampliamente utilizados en desarrollos pioneros como SHIFOR y SHIPS (DeMaria & Kaplan, 1994).
- *Modelos de regresión logística*, que han sido empleados para estimar la probabilidad de formación ciclónica o de intensificación rápida, basados en umbrales críticos de variables oceanográficas y atmosféricas (Kaplan et al., 2015).
- *Modelos climatológicos y de persistencia*, como el tradicional *CLIPER* (*Climate and Persistence Model*), que combina promedios históricos de trayectoria con la tendencia reciente observada del sistema. Aunque útil como referencia base para la evaluación de otros modelos, el CLIPER presenta limitaciones para predecir cambios abruptos en intensidad o trayectoria (Rappaport et al., 2009).

Además, estos modelos estadísticos pueden ser mejorados mediante el uso de técnicas de posprocesamiento probabilístico. Por ejemplo, el BMA y el EMOS se aplican para calibrar salidas de pronóstico, ajustando la dispersión y mejorando la representatividad probabilística del sistema (Gneiting & Raftery, 2005).

En conjunto, estos modelos estadísticos clásicos han demostrado ser herramientas útiles tanto en la operación meteorológica como en el análisis de tendencias climatológicas. Su aplicabilidad se ha mantenido en el tiempo debido a su bajo costo computacional, facilidad de interpretación y su utilidad como punto de comparación frente a modelos dinámicos más complejos (Elsberry et al., 2014; Rappaport et al., 2009). Además, su integración con modelos numéricos y probabilísticos ha contribuido a reducir errores sistemáticos y mejorar la representación de la incertidumbre inherente al comportamiento de los CTs, especialmente en esquemas de predicción conjunta y posprocesamiento estadístico (Gneiting & Raftery, 2005; Majumdar & Torn, 2014).

d) Aprendizaje automático y métodos modernos

Los avances recientes en inteligencia artificial han permitido implementar modelos de *aprendizaje automático* (*Machine Learning*, ML) para mejorar la predicción de la trayectoria e intensidad de los CTs. Estos enfoques aprovechan grandes volúmenes de datos históricos y satelitales para identificar patrones complejos no lineales, que a menudo escapan a los modelos estadísticos o físicos tradicionales.

Entre los enfoques más destacados se encuentran:

- *Random Forest y Gradient Boosting*: Algoritmos de clasificación supervisada que permiten categorizar CTs según su intensidad a partir de conjuntos de características extraídas de datos satelitales, ambientales y dinámicos. Estos métodos han demostrado ser útiles para capturar relaciones no lineales y evaluar la importancia relativa de diferentes predictores (Liou et al., 2024; Zhang et al., 2025).
- *Redes neuronales recurrentes (RNN) y de memoria a largo plazo (LSTM)*: Especialmente útiles para capturar dependencias temporales en series de tiempo, han sido aplicadas con éxito a la predicción de trayectorias y evolución de intensidad de CTs. Su capacidad para aprender secuencias las hace idóneas para

modelar la dinámica progresiva de un sistema ciclónico. (Kapoor et al. 2023; Kumar et al., 2021)

- *Redes convolucionales (CNN)*: Utilizadas principalmente en el análisis de imágenes satelitales, estas redes son capaces de identificar estructuras espaciales relevantes, como bandas nubosas o patrones convectivos, que están directamente relacionados con la intensidad del sistema (Chen et al., 2024).

Estudios recientes han explorado enfoques híbridos que combinan modelos físicos con aprendizaje automático. Eusebi et al. (2024) demostraron que los modelos de *deep learning* informados por principios físicos (*physics-informed neural networks*) pueden reconstruir campos de presión y viento con alta fidelidad, lo cual abre nuevas oportunidades para mejorar la representación de la intensidad ciclónica y su evolución.

La inferencia bayesiana ha comenzado a utilizarse como herramienta de posprocesamiento, permitiendo actualizar las distribuciones de probabilidad generadas por modelos de ML o deterministas a partir de evidencia observacional reciente. Este enfoque combina la información histórica (priors) con los nuevos datos (likelihood) para obtener predicciones probabilísticas más realistas y con intervalos de credibilidad (Emanuel, 2018).

1.3 Estadística de extremos

A pesar del desarrollo de modelos deterministas, probabilísticos y de aprendizaje automático aplicados al pronóstico de ciclones tropicales (CTs), persisten limitaciones importantes para representar con precisión eventos de alta intensidad, como la rápida intensificación o los huracanes de categoría 4 y 5. Estas limitaciones se agravan en regiones con alta incertidumbre, registros escasos y elevada vulnerabilidad, como el Caribe y el golfo de México.

En este contexto, la estadística de extremos emerge como un enfoque necesario para caracterizar fenómenos poco frecuentes, pero de gran impacto. A diferencia de los modelos centrados en promedios, este enfoque se focaliza en el comportamiento de las colas de las distribuciones de variables críticas, como la velocidad máxima del viento o la presión mínima central. Ello permite estimar niveles de retorno y cuantificar la

probabilidad de ocurrencia de eventos severos, aportando así insumos fundamentales para la gestión del riesgo.

En el ámbito hidrometeorológico, ha sido ampliamente utilizado para evaluar precipitaciones intensas, vientos huracanados, oleaje severo y niveles extremos del mar. Dado que estos fenómenos suelen situarse fuera del rango de comportamiento normal, no pueden describirse adecuadamente mediante estadísticas convencionales. Su estudio requiere modelos especializados, capaces de representar adecuadamente los máximos o mínimos observados en series temporales climáticas (Coles, 2001; Katz et al., 2002).

El fundamento teórico del análisis de extremos se basa en los teoremas límite para máximos, los cuales establecen que, bajo ciertas condiciones generales, los valores extremos convergen a una de tres distribuciones canónicas: Gumbel, Fréchet o Weibull (Leadbetter et al., 1983). Estas pueden unificarse en una sola formulación flexible: la Distribución Generalizada de Valores Extremos (GEV), ampliamente aplicada en climatología, hidrología y evaluación de riesgos (Martins & Stedinger, 2000).

1.3.1 Distribución Generalizada de Valores Extremos (GEV)

La distribución GEV representa el modelo teórico fundamental para representar el comportamiento de los valores máximos (o mínimos transformados) de una variable aleatoria observada en bloques temporales, como años o temporadas.

La distribución GEV unifica estos tres casos en una sola expresión paramétrica, definida por su función de distribución acumulada (CDF) como:

$$G(z) = \exp \left\{ - \left[1 + \xi \left(\frac{z - \mu}{\sigma} \right) \right]^{-1/\xi} \right\}, \quad \text{para } 1 + \xi \left(\frac{z - \mu}{\sigma} \right) > 0 \quad (5)$$

donde:

- $\mu \in R$ es el parámetro de localización, que indica el valor central de los extremos;
- $\sigma > 0$ es el parámetro de escala, que controla la dispersión de los datos extremos;
- $\xi \in R$ es el parámetro de forma, que determina la forma de la cola de la distribución.

Según el valor de ξ , se obtienen los tres tipos de comportamiento extremo:

- $\xi > 0$: Distribución Fréchet, con cola pesada. Apropriada para modelar eventos extremos sin cota superior, como vientos de huracanes categoría 4 o 5.
- $\xi \approx 0$: Distribución Gumbel, con cola exponencial. Se interpreta como el límite de la GEV cuando $\xi \rightarrow 0$.
- $\xi < 0$: Distribución Weibull, con cola acotada superior. Útil para variables que tienen un límite físico superior, como la presión mínima central en CTs.

El modelo GEV ha sido aplicado en numerosos estudios para analizar precipitaciones intensas (Koutsoyiannis, 2004), temperaturas extremas, caudales fluviales máximos (Martins & Stedinger, 2000) y, de forma creciente, la intensidad ciclónica mediante la velocidad del viento o la presión mínima central transformada (Renard et al., 2006; Coles, 2001). Su flexibilidad lo convierte en una herramienta fundamental para estimar valores extremos en contextos con observaciones limitadas, y constituye un insumo clave para la estimación de niveles de retorno y el desarrollo de priors informativos en modelos bayesianos.

1.3.2 Estimación de parámetros: máxima verosimilitud

La estimación de los parámetros μ , σ y ξ puede realizarse mediante diferentes técnicas: método de los momentos, método de cuantiles, inferencia bayesiana o, con mayor frecuencia, mediante el enfoque de máxima verosimilitud (*Maximum Likelihood Estimation, MLE*).

Este método consiste en encontrar el conjunto de parámetros que maximiza la probabilidad de observar los datos extremos registrados. La función de verosimilitud correspondiente se expresa como:

$$L(\mu, \sigma, \xi) = \prod_{i=1}^n g(z_i | \mu, \sigma, \xi) \quad (6)$$

donde $g(z_i)$ representa la *función de densidad de probabilidad* (PDF) de la distribución GEV:

$$g(z) = \frac{1}{\sigma} \left[1 + \xi \left(\frac{z - \mu}{\sigma} \right) \right]^{-\frac{1}{\xi - 1}} \exp \left\{ - \left[1 + \xi \left(\frac{z - \mu}{\sigma} \right) \right]^{-1/\xi} \right\}, \quad \text{para } 1 + \xi \left(\frac{z - \mu}{\sigma} \right) > 0 \quad (7)$$

Este procedimiento se realiza usualmente mediante algoritmos numéricos de optimización no lineal o técnicas de gradiente estocástico, disponibles en paquetes estadísticos como R (p. ej., extRemes, ismev, evd)

Entre las principales ventajas del MLE destacan:

- Eficiencia asintótica: los estimadores son insesgados para muestras grandes y alcanzan la varianza mínima posible (Cramér–Rao).
- Flexibilidad: se adapta a datos no transformados y permite comparar modelos con distintos supuestos.
- Facilidad de inferencia posterior: los estimadores pueden ser usados como punto de partida en métodos de remuestreo (bootstrap) o inferencia bayesiana.

El uso conjunto de GEV y MLE se ha consolidado como metodología de referencia en la caracterización de extremos hidrometeorológicos, incluyendo ciclones tropicales, lluvias intensas, olas de calor, caudales extremos y niveles máximos del mar (Hosking & Wallis, 1987; Renard et al., 2006; Katz et al., 2002).

1.3.3 Niveles de retorno e incertidumbre

Uno de los principales aportes del modelo GEV es la estimación de niveles de retorno, definidos como el valor esperado de una variable extrema que se excede, en promedio, una vez cada T años.

A partir de la distribución GEV, el nivel de retorno z_T asociado a un periodo de retorno $T = 1/p$, donde p es la probabilidad de excedencia anual, se calcula mediante la siguiente expresión (para $\xi \neq 0$):

$$z_p = \mu + \frac{\sigma}{\xi} [(-\log(1 - p))^{-\xi} - 1] \quad (8)$$

donde z_p corresponde al valor de la variable que se espera exceder, en promedio, una vez cada T años, μ es el parámetro de localización, σ el parámetro de escala y ξ el parámetro de forma de la GEV,

Estas estimaciones permiten proyectar, por ejemplo, la velocidad máxima del viento o la presión mínima central esperadas para periodos de 10, 20, 50 o 100 años, lo cual resulta

esencial para el diseño de obras de protección costera, normas de construcción, seguros paramétricos y planes de adaptación.

Para incorporar la incertidumbre, se emplean métodos como el bootstrap paramétrico (Douglas et al., 2000), que permite construir intervalos de confianza no paramétricos, o la inferencia bayesiana, que utiliza las distribuciones posteriores de μ , σ y ξ para generar intervalos de credibilidad y actualizar resultados con nueva evidencia (Coles & Tawn, 1996; Chavez-Demoulin & Davison, 2005).

Este marco resulta especialmente pertinente en regiones como el Caribe y el golfo de México, donde los registros históricos de eventos extremos son limitados, pero la exposición social y económica es elevada. En estos contextos, la combinación del modelo GEV con técnicas de remuestreo o inferencia bayesiana proporciona una herramienta sólida para caracterizar extremos, estimar riesgos y diseñar medidas preventivas basadas en evidencia estadística.

1.3.4 Aplicaciones en el análisis de intensidad ciclónica

La estadística de extremos ha demostrado ser una herramienta metodológicamente sólida y operacionalmente versátil para evaluar y proyectar la intensidad de CTs, tanto en entornos oceánicos como costeros. Su aplicabilidad abarca desde la modelación de oleaje extremo y marea ciclónica hasta la estimación de viento máximo sostenido y presión mínima central.

A escala global, Wang et al. (2022) identificaron un aumento sistemático en la intensidad de CTs débiles entre 1991 y 2020, a partir del análisis de corrientes oceánicas superficiales. Grossmann-Matheson et al. (2024) desarrollaron un atlas global de olas extremas, utilizando simulaciones sintéticas y ajuste GEV para estimar niveles de retorno de hasta 100 años.

Naseef y Sanil Kumar (2020), en la bahía de Bengala, mostraron que la exclusión de solo dos ciclones extremos puede reducir en 30 % los niveles de retorno de altura significativa de ola, resaltando la sensibilidad del modelo a eventos raros. En el Caribe, Wada et al. (2022) validaron el modelo STM-E para estimar oleaje inducido por CTs, usando series

sintéticas de más de 3000 años. O’Grady et al. (2022) propusieron una distribución mixta para niveles de marea, que mejoró sustancialmente las estimaciones frente al modelo GEV convencional.

Otros enfoques combinan simulaciones de alta resolución con modelado estadístico. Stern et al. (2021) integraron simulaciones LES y modelos estadístico-dinámicos para estimar el riesgo de ráfagas extremas de viento en huracanes intensos, encontrando probabilidades superiores al 50 % de experimentar ráfagas $> 70 \text{ m/s}$ en zonas cercanas al ojo.

Desde el punto de vista metodológico, estudios como los de Matear y Reddy (2025) analizan el tamaño muestral necesario para estimaciones confiables bajo colas pesadas. En México, Gutierrez-Lopez et al. (2025) propusieron un enfoque mixto Gumbel-Bayesiano para estimar la probabilidad conjunta de viento extremo y presión mínima en Acapulco, aplicado a eventos como los huracanes Pauline y Otis.

Otros trabajos incluyen la tesis de Meza-Padilla et al. (2015), quienes estimaron la marea de tormenta y oleaje inducidos por ciclones tropicales en mares mexicanos utilizando huracanes sintéticos y distribuciones extremas (GEV, Weibull) en las costas del Pacífico, Golfo y Caribe. Por otra parte, Sánchez-Rivera et al. (2021) realizaron un análisis histórico (1851-2019) de huracanes extremos en Quintana Roo, evaluando la frecuencia, trayectoria e impactos de estos eventos, lo que aporta una base importante para estudios de vulnerabilidad regional.

Desde una perspectiva técnica, Payez et al. (2025) introdujeron una metodología basada en percentiles suavizados y bootstrap por bloques para estimar viento máximo con series cortas, mejorando la confiabilidad de intervalos de retorno para uso operativo.

En conjunto, los estudios revisados evidencian que la estadística de extremos no solo permite caracterizar rigurosamente los valores máximos observados, sino que también constituye una herramienta clave para construir escenarios de riesgo bajo incertidumbre (Landsea y Franklin, 2013). Esta capacidad es esencial en regiones de alta exposición ciclónica como el Caribe y el golfo de México. A su vez, la combinación con métodos bayesianos ofrece un marco más flexible para representar la incertidumbre estructural y mejorar la estimación de probabilidades condicionales.

1.4 Enfoque bayesiano aplicado a ciclones tropicales

1.4.1 Teorema de Bayes y fundamentos de inferencia

El teorema de Bayes es la piedra angular de la inferencia bayesiana y establece una relación entre la probabilidad de un evento, dado un conjunto de datos y la probabilidad de esos datos dado el evento (Bayes, 1763). Su formulación matemática es:

$$P(H | D) = \frac{P(D/H) \cdot P(H)}{P(D)} \quad (9)$$

Donde:

- $P(H | D)$: Probabilidad posterior de la hipótesis H dado los datos D .
- $P(D | H)$: Probabilidad de observar los datos D bajo la hipótesis H .
- $P(H)$: Probabilidad previa de la hipótesis H (creencia inicial antes de ver los datos).
- $P(D)$: Probabilidad total de los datos D (puede calcularse como la suma de todas las probabilidades de D bajo todas las hipótesis posibles).

Este teorema permite actualizar de forma coherente una creencia inicial (prior) al incorporar nueva evidencia, obteniendo así una distribución posterior más informada. A diferencia del enfoque frecuentista, que asume parámetros fijos y se basa exclusivamente en la verosimilitud, la inferencia bayesiana considera que los parámetros son variables aleatorias, lo que habilita la integración explícita de conocimiento previo y la actualización iterativa de la incertidumbre (Gelman et al., 2013; Rendón-Macías et al., 2018).

Este marco resulta particularmente valioso en el análisis y pronóstico de ciclones tropicales, donde la disponibilidad de datos en tiempo real es limitada y la incertidumbre es elevada. Además, los modelos bayesianos permiten capturar relaciones no lineales, propagar incertidumbre estructurada y realizar inferencias robustas incluso con muestras pequeñas, condiciones habituales en el estudio de eventos extremos.

Una de las ventajas fundamentales de este enfoque es su capacidad para combinar fuentes de información heterogéneas. Por ejemplo, es posible integrar registros históricos de ciclones, reanálisis climáticos, observaciones satelitales y mediciones in situ. En particular, modelos de regresión bayesiana han demostrado su utilidad para relacionar la

intensidad de los ciclones con variables predictoras como la temperatura de la superficie del mar, la cizalladura vertical del viento o la presión a nivel del mar, lo que ha sido documentado por estudios como el de Huang et al. (2021).

La incorporación de estas variables mejora tanto la comprensión física de los procesos que rigen la intensificación ciclónica como la capacidad de anticipar escenarios de riesgo. De esta manera, el enfoque bayesiano contribuye directamente al fortalecimiento de los sistemas de monitoreo y mitigación, permitiendo generar pronósticos más realistas y útiles para la gestión operativa del riesgo.

1.4.2 Modelos jerárquicos y probabilidad condicional

Los modelos jerárquicos bayesianos, también denominados modelos multinivel, constituyen una extensión natural del enfoque bayesiano clásico. Estos modelos permiten representar estructuras de variación complejas, en las que los parámetros del modelo pueden depender de factores agrupados en distintos niveles jerárquicos, como periodos temporales, regiones geográficas o categorías de intensidad ciclónica (Gelman et al., 2013).

Esta estructura resulta especialmente útil en contextos hidrometeorológicos, donde los datos observados presentan dependencias espaciales y temporales, efectos latentes y heterogeneidad entre subgrupos. El modelo jerárquico capta esta complejidad mediante una construcción probabilística anidada. Por ejemplo, si se desea modelar la intensidad ciclónica en función de variables como la velocidad del viento (V), la presión mínima central (P), la latitud (lat) y la longitud (lon), una formulación jerárquica típica se expresa como:

$$P(\theta, \alpha | D) \propto P(D | \theta) \cdot P(\theta | \alpha) \cdot P(\alpha) \quad (10)$$

donde:

- D representa los datos observados (viento, presión, ubicación, categoría observada),
- θ son los parámetros específicos por grupo (como μ_t, σ_t, ξ_t por periodo t),
- α son los hiperparámetros globales que gobiernan la distribución de θ ,

Este marco probabilístico permite propagar la incertidumbre entre niveles jerárquicos, lo que resulta crucial cuando se trabaja con subconjuntos de datos reducidos o desbalanceados. Además, favorece la transferencia de información entre grupos relacionados, mejorando la estabilidad de las estimaciones y reduciendo el sesgo en contextos con evidencia limitada, como los huracanes intensos poco frecuentes (McElreath, R., 2020).

Desde un punto de vista práctico, los modelos jerárquicos bayesianos proporcionan una base sólida para la predicción probabilística condicional de intensidad ciclónica. A diferencia de los modelos deterministas tradicionales, que producen estimaciones puntuales, los modelos bayesianos generan distribuciones posteriores completas para las variables de interés. Esto permite calcular directamente probabilidades acumuladas por categoría Saffir–Simpson, como:

$$P(\text{Intensidad} \geq \text{Cat 3} \mid V, P, \text{lat}, \text{lon}) \quad (11)$$

y construir intervalos de credibilidad que reflejan la incertidumbre inherente a cada predicción. Asimismo, estos modelos facilitan la generación de mapas de vulnerabilidad condicional espacializados, integrando datos físicos, observaciones históricas y predictores geográficos dentro de un marco coherente.

En consecuencia, los modelos jerárquicos bayesianos se configuran como herramientas robustas y flexibles para la gestión del riesgo ciclónico, especialmente en regiones vulnerables. Su capacidad para combinar conocimiento previo, modelar incertidumbre estructural y generar pronósticos personalizados los hace particularmente valiosos en el diseño de sistemas de alerta temprana, planificación territorial y evaluación de escenarios bajo cambio climático.

1.4.3 Aplicaciones a la predicción de intensidad

En los últimos años, los modelos de predicción de intensidad ciclónica basados en inferencia bayesiana han adquirido creciente relevancia debido a su capacidad para integrar múltiples fuentes de información y proporcionar estimaciones explícitas de incertidumbre. Esta aproximación resulta particularmente valiosa en escenarios donde los

registros observacionales son limitados o donde la variabilidad climática impone retos sustanciales a los modelos deterministas tradicionales.

Un ejemplo pionero es el trabajo de Chu y Zhao (2007), quienes aplicaron un modelo de regresión lineal generalizada de Poisson, formulado dentro del marco bayesiano, para pronosticar la actividad de ciclones tropicales en el Pacífico Norte central durante la temporada alta (julio-septiembre). Este modelo incorporó variables ambientales a gran escala como la temperatura superficial del mar, la presión a nivel del mar, la cizalladura vertical del viento, la vorticidad relativa y el contenido de agua precipitable. Posteriormente, en 2011, los mismos autores llevaron a cabo una revisión metodológica sobre el uso de modelos bayesianos en climatología extrema, incluyendo aplicaciones a la detección de cambios de régimen, la clasificación de trayectorias y el pronóstico estacional de ciclones.

En la misma línea, Song et al. (2018) propusieron un esquema de promedio bayesiano de modelos (BMA) con el objetivo de mejorar la predicción de la presión mínima central, una variable determinante en la estimación de la intensidad de los ciclones. Este enfoque permitió combinar múltiples modelos y ponderar sus contribuciones según su desempeño, mejorando así la robustez predictiva.

Investigaciones recientes han reforzado la aplicabilidad del enfoque bayesiano en diversos contextos climáticos. Loridan y Bruneau (2025) propusieron el modelo *UTC (Unified Tropical Cyclone)*, un marco de modelado que genera catálogos sintéticos de ciclones tropicales globales condicionados por variables oceánicas y atmosféricas, diferenciados espacialmente por regiones climáticas, lo que permite incorporar variabilidad climática al riesgo de ciclones extremos. Ragab (2025) integró inferencia bayesiana con técnicas de aprendizaje automático para mejorar la predicción de intensidad bajo condiciones climáticas cambiantes.

Zhu et al. (2022) aplicaron técnicas de optimización bayesiana para calibrar modelos de *Gradient Boosted Regression Trees* que predicen los cambios de intensidad ciclónica en el Pacífico Noroccidental. Este enfoque evidencia la adaptabilidad del método bayesiano (no solo en la estimación de parámetros de distribución extrema, sino también en la

optimización de modelos predictivos) a diferentes horizontes de predicción y entornos geográficos con variabilidad operacional.

En el ámbito atlántico, estudios como los de Wentd (2017) y Cummings (2018) aplicaron modelos jerárquicos bayesianos multivariados para reducir errores en el pronóstico de intensidad y trayectoria. Dietz et al. (2022) desarrollaron un modelo jerárquico bayesiano para caracterizar la estructura interna de los ciclones y predecir su potencial destructivo, integrando información estructural, climatológica y económica. Este estudio demostró que los enfoques jerárquicos permiten obtener estimaciones más precisas bajo condiciones de incertidumbre y escasez de datos. De forma similar, Walsh et al. (2022) utilizaron un enfoque jerárquico bayesiano para cuantificar la incertidumbre en las predicciones de precipitación ciclónica, integrando errores históricos y correlaciones espaciales. Boumis et al. (2023) aplicaron un modelo bayesiano jerárquico para estimar la frecuencia de marejadas ciclónicas (storm surges) en la región del golfo de Estados Unidos. El enfoque metodológico, aunque centrado en niveles extremos del mar, es directamente transferible a la predicción de intensidad ciclónica bajo incertidumbre estructurada, especialmente en zonas costeras vulnerables como el golfo de México. Más recientemente, Yang y Xu (2024) desarrollaron un modelo jerárquico con red neuronal para reconstruir campos de viento en ciclones tropicales, lo cual mejora la evaluación del riesgo extremo en áreas costeras.

En el contexto latinoamericano, Gutierrez Lopez et al. (2025) desarrollaron un modelo estadístico que integra distribuciones de valores extremos (Gumbel y GEV) con un modelo bayesiano para estimar la probabilidad conjunta de vientos extremos y presiones mínimas en la costa del Pacífico mexicano. Este modelo se aplicó a eventos históricos como los huracanes Pauline (1997) y Otis (2023), generando mapas espaciales de riesgo probabilístico útiles para la planificación territorial y la gestión de emergencias. Esta aproximación demuestra la sinergia entre la estadística de extremos y la inferencia bayesiana para anticipar escenarios de alta severidad.

De acuerdo con Bartoš et al. (2023), el uso de priors empíricos en modelos bayesianos para eventos binarios permite estabilizar la inferencia cuando los datos locales son escasos, incorporando información previa equivalente a un número moderado de observaciones virtuales.

Otto y Castelo (2025) destacan que el modelo Beta-Binomial constituye un enfoque robusto para analizar conteos acotados en aplicaciones ambientales, ya que captura adecuadamente la sobredispersión y la variabilidad extrema presente en datos reales.

En conjunto, estas investigaciones respaldan la pertinencia del uso de inferencia bayesiana, especialmente en su formulación jerárquica, para modelar la intensidad ciclónica, incorporar incertidumbre de forma estructurada y generar pronósticos probabilísticos espacialmente explícitos. La combinación de modelos GEV para caracterizar valores extremos con estructuras bayesianas multinivel permite estimar la probabilidad condicional. Este tipo de aproximación representa un avance metodológico sustantivo frente a modelos deterministas tradicionales, al ofrecer una base más realista para la gestión del riesgo ante eventos extremos en entornos vulnerables como el Caribe y el golfo de México.

II. METODOLOGÍA

2.1 Área de estudio

El área de estudio se delimita entre 15°–34° N y 98°–65° O (Figura 5). Esta región abarca sectores clave del Atlántico Norte occidental y el Golfo de México, incluyendo el Caribe, Florida y la costa oriental de México. En este dominio son frecuentes trayectorias que ingresan desde el Caribe hacia el Golfo y episodios de intensificación rápida sobre aguas cálidas del Caribe occidental.




Figura 5: Área de estudio

2.2 Base de datos

Se empleó la base de datos IBTrACS v04r00 (International Best Track Archive for Climate Stewardship), considerada el archivo global más completo y estandarizado de ciclones tropicales (CTs) (Knapp et al., 2010). Este conjunto, compilado por la NOAA, integra registros históricos de múltiples agencias meteorológicas, entre ellas: JTWC (Joint Typhoon Warning Center); JMA (Japan Meteorological Agency); IMD (India Meteorological Department); y NHC (National Hurricane Center), principal fuente para el Atlántico Norte y el Golfo de México.

Los datos, disponibles en formato CSV (ibtracs.ALL.list.v04r00.csv), abarcan desde 1851 hasta la actualidad y contienen variables clave homogenizadas, tales como:

- Trayectoria: Latitud, longitud y velocidad de desplazamiento (en intervalos de 3 horas).
- Intensidad: Vientos máximos sostenidos (en nudos) y presión central mínima (en hPa).
- Clasificación: Según escalas estandarizadas (ej. Saffir-Simpson).
- Metadatos: Identificador único (SID), nombre del ciclón, cuenca de origen (BASIN) y agencia reportante.

Aunque IBTrACS unifica criterios metodológicos entre agencias, se ha documentado que los registros previos a 1950 presentan limitaciones de precisión y cobertura espacial (Knapp et al., 2010; Landsea et al., 2004).

2.2.1 Procesamiento de los datos para el área de estudio

Se seleccionaron las siguientes variables para el análisis:

- SID (identificador único)
- NAME (nombre del ciclón)
- ISO_TIME (fecha y hora en UTC)
- LAT/LON (coordenadas geográficas)
- WMO_WIND (viento máximo en nudos)
- WMO_PRES (presión mínima en hPa)
- BASIN (cuenca ciclónica)

Se realizó un proceso de filtrado dentro de $15^{\circ} - 34^{\circ} N$, $98^{\circ} - 65^{\circ} O$. Se excluyeron los registros con valores faltantes de WMO_WIND o WMO_PRES; vientos $< 35 kt$ (por debajo de tormenta tropical); vientos $> 200 kt$ (atípicos no físicos); y presiones $> 1010 hPa$ (no ciclónicas).

El período de estudio se fijó entre 1950 y 2021, descartando los registros previos a 1950 disponibles en la base IBTrACS (que se remontan a 1851), con el objetivo de maximizar

la homogeneidad instrumental y la cobertura espacial. Los datos anteriores a 1950 presentan mayores errores sistemáticos debido a la falta de estandarización en las mediciones, los cambios en la instrumentación y la escasa densidad de observaciones, especialmente en regiones tropicales y oceánicas (WMO, 2020). Asimismo, las series antiguas presentan una alta heterogeneidad temporal, ya que requieren ajustes complejos por discontinuidades estructurales, por ejemplo, relocalización de estaciones o cambios en los métodos de observación), lo que introduce sesgos no corregibles en ausencia de metadatos completos (Venema et al., 2012).

Esta decisión también garantiza la coherencia metodológica con las referencias climáticas internacionales, dado que el período posterior a 1950 coincide con la consolidación de redes globales de observación sistematizada, como el *Global Climate Observing System* (GCOS), y con el inicio del intervalo reconocido por la comunidad científica como representativo para el análisis del cambio climático de origen antropogénico. De hecho, este umbral temporal ha sido adoptado como estándar por el IPCC para establecer comparaciones históricas y evaluar la influencia humana sobre el sistema climático (IPCC, 2021). Así, la delimitación temporal seleccionada optimiza el equilibrio entre la longitud de la serie y la calidad de los datos, lo cual resulta fundamental para garantizar la robustez estadística en el análisis confiable de tendencias a largo plazo.

Con el propósito de asegurar una media climática representativa, los datos se subdividieron en períodos de 30 años, en concordancia con la convención establecida por la Organización Meteorológica Mundial (WMO, 1967). Esta duración constituye el intervalo mínimo recomendado para minimizar la influencia de la variabilidad interanual, incluyendo eventos extremos aislados y ciclos naturales como el El Niño-Oscilación del Sur (ENOS), permitiendo así una caracterización más estable de las condiciones climáticas subyacentes. En consecuencia, se definieron tres períodos de estudio:

- Período 1 (1950–1979): etapa previa al acelerado calentamiento global.
- Período 2 (1980–2009): era satelital moderna, asociada al incremento postindustrial de gases de efecto invernadero.

- Período 3 (2010–2021): fase parcial para captar posibles efectos recientes del cambio climático sobre la intensidad ciclónica.

Según la WMO (1967), series más cortas (< 30 años) pueden estar sesgadas por anomalías decádicas transitorias, mientras que períodos excesivamente largos pueden diluir señales recientes, como el calentamiento global acelerado posterior a 1980. Por tanto, el uso de bloques climáticos de tres décadas optimiza el equilibrio entre estabilidad estadística y sensibilidad a tendencias de cambio climático.

Las Figuras 6 a 8 presentan las trayectorias geográficas de los CTs registrados en cada período, lo que permite visualizar comparativamente los patrones espaciales y temporales de ocurrencia.

Esta representación facilita la identificación de cambios en rutas preferenciales, áreas de formación e intensificación potencial, sentando las bases para el análisis extremo posterior y la modelación probabilística de la intensidad ciclónica.




Figura 6: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 1950-1979




Figura 7: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 1980-2009




Figura 8: Puntos de ocurrencia y trayectoria de los ciclones tropicales del periodo 2010-2021

Se llevó a cabo un análisis exploratorio preliminar enfocado en la frecuencia de ciclones tropicales (CTs) durante los tres períodos seleccionados, complementado con pruebas estadísticas no paramétricas para detectar tendencias temporales. En particular, se aplicaron la prueba de Mann–Kendall, la pendiente de Sen y el coeficiente Tau de Kendall, técnicas ampliamente utilizadas en análisis climáticos por su robustez frente a distribuciones no normales y su sensibilidad a tendencias monótonas.

2.3 Análisis de extremos mediante modelo GEV

El análisis de extremos se empleó para modelar los máximos anuales de velocidad del viento y los mínimos anuales de presión atmosférica central en CTs, con el propósito de caracterizar el comportamiento estadístico de las colas y de aportar priors informativos al modelado bayesiano posterior.

Este análisis, basado en la distribución Generalizada de Valores Extremos (GEV), permite estimar la probabilidad de ocurrencia de huracanes de gran intensidad en la cuenca Caribe, calcular periodos de retorno y validar estadísticamente el ajuste de las colas.

Los datos requeridos, extraídos de IBTrACS para el área $15^{\circ} - 34^{\circ} N, 98^{\circ} - 65^{\circ} O$, en el periodo 1950–2021 son:

- Velocidad del viento (WMO_WIND): Extraer máximos anuales (valor más alto por año).
- Presión atmosférica (WMO_PRES): Extraer mínimos anuales y transformar a valores negativos (para compatibilidad con GEV).

2.3.1 Evaluación y validación del ajuste GEV

Para garantizar que el modelo GEV ajustado describa adecuadamente el comportamiento de los extremos (vientos y presión), se emplearon herramientas gráficas de diagnóstico y pruebas estadísticas formales, así como el Criterio de Información de Akaike (AIC) y el Criterio de Información Bayesiano (BIC), los cuales informan el equilibrio ajuste-complejidad dentro de cada periodo.

Los gráficos de diagnóstico permitieron una evaluación visual preliminar del ajuste del modelo. Se utilizaron dos tipos principales la densidad ajustada vs. observada,

comparando la distribución empírica de los datos extremos con la densidad teórica de la GEV; y QQ-plot (cuantil–cuantil), que muestra la correspondencia entre cuantiles empíricos y teóricos; una alineación cercana a la diagonal indica buen ajuste.

Para la validación cuantitativa del ajuste del modelo, se utilizó la prueba estadística Anderson–Darling (AD), más sensible a diferencias en las colas que la prueba de Kolmogórov–Smirnov, al ponderar con mayor peso observaciones en extremos (Stephens, 1976). La prueba contrasta la hipótesis nula H_0 : “los datos siguen la distribución GEV ajustada”, frente a la alternativa H_1 : “los datos no siguen dicha distribución”. El estadístico A^2 se interpreta en función de valores críticos que han sido adaptados o extrapolados de estudios como el de Choulakian y Stephens (2001), originalmente desarrollado para la distribución Generalizada de Pareto (GPD). Si el valor $-p < 0.05$, se rechaza H_0 , lo que indicaría un mal ajuste. Valores elevados de A^2 son indicativos de mayores discrepancias, especialmente en las colas de la distribución, lo cual es crítico en el análisis de eventos extremos.

El cálculo de los períodos de retorno típicos (2, 5, 10, 20, 50 años) se realizó a los parámetros estimados para predecir eventos extremos futuros, lo que es indispensable para la gestión de riesgos y el análisis climático.

Para cuantificar la incertidumbre en (μ, σ, ξ) se aplicó bootstrap no paramétrico con 1000 replicaciones. Esta técnica permite construir intervalos de confianza al 95% sin supuestos fuertes sobre la forma de la distribución subyacente, fortaleciendo así la robustez del análisis extremo. Además, estos intervalos constituyen insumos clave para la modelación bayesiana posterior, al aportar priors empíricamente fundamentados. En el contexto de CTs intensos, como los que afectan el Caribe y el Golfo de México, una validación rigurosa de los extremos es esencial, dado que errores en las colas pueden conducir a una subestimación significativa del riesgo asociado.

2.4 Modelado jerárquico bayesiano de la intensidad ciclónica

Con base en el análisis de extremos, se implementó un modelo jerárquico bayesiano orientado a estimar probabilidades condicionadas de intensidad ciclónica para los tres períodos definidos (1950-1979, 1980-2009 y 2010-2021). En una primera fase, se modelaron jerárquicamente los parámetros de localización (μ), escala (σ) y forma (ξ) de

la GEV para las variables viento máximo y presión mínima central. A nivel superior, se incorporaron priors informativos construidos a partir de los valores obtenidos por máxima verosimilitud (MLE) en el ajuste inicial de la distribución GEV.

Este enfoque permite fortalecer la inferencia en periodos con menor cantidad de datos, como el más reciente (2010-2021), y formaliza la inclusión de conocimiento previo dentro del proceso de estimación.

Una vez definida la estructura jerárquica, el objetivo fue obtener la distribución posterior de los parámetros $\theta = \{\mu, \sigma, \xi\}$, dados los datos observados D . Este procedimiento, denominado inferencia bayesiana, se basa en el Teorema de Bayes:

$$P(\mu, \sigma, \xi | D) = \frac{P(D|\mu, \sigma, \xi) \cdot P(\mu, \sigma, \xi)}{P(D)} \quad (12)$$

Donde $P(D | \mu, \sigma, \xi)$ es la verosimilitud, $P(\mu, \sigma, \xi)$ las distribuciones a priors y $P(D)$ la evidencia o probabilidad marginal de los datos observados, esta última a menudo no manejable analíticamente.

Dado que calcular $P(D)$ implica integrar sobre todos los posibles valores de los parámetros (μ, σ, ξ) , lo cual es computacionalmente costoso en modelos complejos, se recurrió al uso de algoritmos de muestreo MCMC (Markov Chain Monte Carlo), que permiten obtener muestras de la distribución posterior sin necesidad de conocer explícitamente la evidencia $P(D)$, generando muestras de la posterior $P(\mu, \sigma, \xi | D)$.

La implementación se realizó en la plataforma Stan, a través de su interfaz en R (RStan). Stan es un lenguaje de modelado probabilístico de código abierto, diseñado para ejecutar algoritmos de inferencia bayesiana de manera eficiente. Se empleó el algoritmo NUTS (No-U-Turn Sampler), una extensión adaptativa de HMC (Hamiltonian Monte Carlo) que optimiza automáticamente la trayectoria de muestreo, mejorando la eficiencia en espacios de parámetros de alta dimensión.

Los insumos del modelo se organizaron en una lista *stan_data* con la siguiente estructura:

- N : número total de observaciones
- K : número de periodos (grupos jerárquicos)

- periodo: vector de pertenencia por observación
- viento: vector de velocidades máximas
- presión: vector de presiones mínimas (en negativo)
- priors: distribuciones previas informativas para μ , σ y ξ , por variable y por periodo

Adicionalmente, se definió una función de inicialización aleatoria para facilitar la convergencia del algoritmo NUTS, asegurando que los valores iniciales se mantuvieran dentro del soporte válido de la distribución GEV. El modelo fue ejecutado con los siguientes parámetros:

- Cadenas: 4
- Iteraciones por cadena: 5000
- Warmup: 1500 iteraciones
- Control: $adapt_delta = 0.9995$, $max_treedepth = 20$

2.4.1 Probabilidades condicionadas por periodo

A partir de las muestras generadas para los parámetros (μ, σ, ξ) de la distribución GEV, se procedió a estimar la probabilidad de que un ciclón tropical alcance una determinada categoría de intensidad, definida según los umbrales de la escala Saffir-Simpson, tanto en términos de viento como de presión.

Para cada periodo, se generaron 4000 combinaciones simuladas de los parámetros μ , σ y ξ a partir de sus respectivas medias y desviaciones estándar posteriores, asegurando la positividad de la escala ($\sigma > 0$) y una cola acotada ($\xi < 0$).

Para cada combinación, se calculó la probabilidad marginal de que el viento se encuentre dentro del intervalo correspondiente a la categoría específica y, de forma análoga, la probabilidad marginal de que la presión estuviera dentro de su intervalo.

Asumiendo independencia condicional entre viento máximo y presión mínima central (como línea base), se estimó la probabilidad conjunta por categoría como el producto de ambas:

$$p_j^{(s)} = p_V^{(s)} \cdot p_P^{(s)} \quad (13)$$

donde $p_j^{(s)}$ es la probabilidad conjunta de la categoría j en la simulación s , $p_V^{(s)}$ y $p_P^{(s)}$ son las probabilidades marginales de viento y presión respectivamente.

Este supuesto se justifica en primera instancia por la fuerte correlación física entre ambas variables, que ya es capturada de forma indirecta en el modelo mediante su codificación conjunta en los parámetros de la distribución GEV. Sin embargo, al utilizar las muestras posteriores de forma separada para calcular probabilidades marginales por variable y luego multiplicarlas, se asume que cualquier dependencia residual entre viento y presión, dada la información de los parámetros, es despreciable. Este enfoque simplifica el análisis y reduce la dimensionalidad computacional, permitiendo estimar probabilidades conjuntas de forma eficiente y estable.

Las probabilidades exactas por categoría se calcularon como la media de las 4000 simulaciones, y los intervalos de credibilidad del 95 % ($IC95\%$) como los percentiles 2.5 y 97.5 de la distribución simulada para cada categoría.

Para obtener las probabilidades acumuladas (por ejemplo, $Pr(Intensidad \geq Cat\ k)$), se realizó, en cada simulación, la suma de las probabilidades conjuntas de todas las categorías iguales o superiores al umbral de interés:

$$p_{\geq k}^{(s)} = \sum_{i \geq k} p_{j=i}^{(s)} \quad \text{con } j = i \quad (14)$$

Esta suma se efectuó previo al cálculo de los intervalos de credibilidad, dado que el cuantil de una suma no es igual a la suma de cuantiles. De esta manera, las medias e $IC95\%$ de las acumuladas reflejan la variabilidad total de la suma conjunta y preservan la coherencia probabilística entre categorías.

Este procedimiento garantiza que las probabilidades acumuladas sean consistentes con las probabilidades exactas por categoría y que los intervalos de credibilidad capturen correctamente la incertidumbre asociada a la estimación conjunta.

2.4.2 Diagnóstico de convergencia y validación

La evaluación del modelo se realizó en dos niveles complementarios: (i) el diagnóstico de convergencia de las cadenas MCMC y (ii) la validación de las probabilidades de intensidad derivadas.

Para la estimación bayesiana de los parámetros extremos (μ, σ, ξ) mediante la distribución GEV, se verificó la convergencia generada por el algoritmo NUTS utilizando los siguientes criterios:

- El estadístico $\hat{R}$ (Gelman-Rubin): para comparar la varianza entre cadenas frente a la varianza dentro de cada cadena. Se consideró convergencia aceptable si $\hat{R} \leq 1.01$ para todos los parámetros y periodos.
- El tamaño de muestra efectivo (ESS): para estimar el número de muestras independientes equivalentes. Se consideró adecuado si $ESS > 400$ por cadena (cuantiles de cola e $IC95\%$ estables).
- Gráficos de traza y autocorrelación (ACF): para evaluar visualmente la estabilidad y eficiencia del muestreo.
- Ausencia de divergencias durante HMC.

Se adoptó el umbral conservador $\hat{R} \leq 1.01$ siguiendo recomendaciones modernas basadas en $\hat{R} - \text{hat}$ dividido y normalizado por rangos, que muestran mayor sensibilidad a no-convergencias sutiles que los umbrales históricos (1.05 – 1.10). Este criterio se complementó con ESS elevado, ausencia de divergencias, conforme a las guías actuales (Gelman et al., 2013; Vehtari et al., 2021).

La validación de las probabilidades estimadas se realizó mediante:

- Coherencia probabilística: verificación de que, en cada simulación, la suma de probabilidades por categoría fuera aproximadamente igual a 1, lo que confirma consistencia interna del cálculo.
- Cobertura de intervalos creíbles ($IC\ 95\%$): las frecuencias históricas observadas en cada periodo se compararon con los intervalos creíbles estimados para las probabilidades acumuladas ($\geq Cat1$, $\geq Cat3$, $\geq Cat5$), verificando que la cobertura fuera superior al 85% en los casos clave.

- Comparación con frecuencias históricas: concordancia entre las probabilidades acumuladas estimadas y las proporciones empíricas de eventos en 2010-2021.
- Posterior Predictive Checks (PPC): para cada simulación de la distribución posterior de los parámetros (μ, σ, ξ) , se generaron réplicas sintéticas y_{rep} de la variable respuesta (viento máximo o presión mínima transformada) de acuerdo con la formulación del modelo. Estas réplicas representan valores plausibles según el modelo y fueron comparadas con los datos observados, evaluando tanto el rango como la forma de la distribución. Se consideró que el ajuste era adecuado cuando la mayoría de las observaciones se ubicaron dentro del $IC95\%$ de las réplicas y cuando las distribuciones simuladas reprodujeron razonablemente las características empíricas.

2.5 Mapas de probabilidad de intensidad ciclónica

2.5.1 Estimación bayesiana local de probabilidades condicionadas por nodo geográfico

Con el objetivo de representar la variabilidad espacial del riesgo de intensificación ciclónica, se implementó un enfoque de inferencia bayesiana local aplicado individualmente a cada nodo georreferenciado dentro del dominio de estudio. Esta estrategia permitió traducir estimaciones probabilísticas de intensidad en mapas operativos a partir de datos históricos observacionales, sin necesidad de recurrir a modelos espacialmente explícitos de alta complejidad.

Aunque existen alternativas que incorporan explícitamente la latitud y la longitud dentro de modelos jerárquicos bayesianos, por ejemplo: a través de regresiones espaciales, bases spline bivariadas o procesos gaussianos, estas aproximaciones suelen implicar elevados costos computacionales y una complejidad técnica considerable, especialmente cuando el volumen de datos es heterogéneo y está espacialmente concentrado. Por esta razón, se adoptó un enfoque más flexible y eficiente que permite capturar la variabilidad espacial local sin imponer estructuras paramétricas rígidas: un modelo Beta-Binomial conjugado aplicado de manera local por nodo geográfico.

En este marco, los eventos extremos (por ejemplo, que un ciclón tropical alcance intensidad $\geq$ Categoría 3) se modelan como procesos binarios. Para cada nodo, el número de “éxitos” observados dentro de un vecindario espacial se asume distribuido como:

$$y \sim \text{Binomial}(n, \theta) \quad (15)$$

donde n es el total de observaciones disponibles en el entorno inmediato y θ representa la probabilidad subyacente del evento extremo. Dado que θ es desconocida, se le asigna un prior conjugado de tipo Beta:

$$\theta \sim \text{Beta}(\alpha_0, \beta_0) \quad (16)$$

La elección de este prior permite obtener de manera analítica el posterior de θ , que también sigue una distribución Beta. Este comportamiento conjugado evita la necesidad de ejecutar cadenas MCMC en cada nodo, lo que resulta especialmente ventajoso en contextos de alta resolución espacial.

a) Construcción de la malla geográfica y vecindarios espaciales

Para estimar la probabilidad local θ en toda la región de estudio, se generó una malla regular con resolución $\Delta = 0.25^\circ$. El dominio se definió mediante un recuadro envolvente extendido 1° más allá del conjunto total de observaciones, con la finalidad de evitar bordes artificiales y garantizar cobertura espacial uniforme. Cada nodo de esta grilla fue asociado a un vecindario circular centrado en su ubicación y definido por un radio fijo de $R = 2.5^\circ \approx 275$ km.

Dentro de cada vecindario se contabilizaron los eventos históricos de intensidades extremas correspondientes al periodo en análisis. Con el fin de asegurar estabilidad inferencial y evitar estimaciones basadas en muestras demasiado pequeñas, se estableció un umbral mínimo de observaciones locales $n_{\min} = 15$. Los nodos que no alcanzaron este requisito fueron descartados, evitando sesgos derivados de regiones con datos insuficientes.

b) Definición de categorías y priors empíricos

Las categorías de intensidad ciclónica consideradas fueron *Cat 3 +*, *Cat 4 +* y *Cat 5 +*, definidas mediante umbrales simultáneos de velocidad del viento y presión mínima central asociados a las categorías Saffir-Simpson, como se muestra a continuación:

Tabla 2: *Categorías y umbrales simultáneos utilizados en el modelo Beta-Binomial*

<i>Categoría</i>	<i>Umbral de viento (kt)</i>	<i>Umbral de presión (hPa)</i>
<i>Cat 3+</i>	≥ 96	≤ 965
<i>Cat 4+</i>	≥ 113	≤ 945
<i>Cat 5+</i>	≥ 137	≤ 920

A partir de los conteos globales por periodo, se construyeron priors empíricos para cada categoría mediante la distribución Beta, con una fuerza informativa previa de $\tau = 50$, equivalente a 50 observaciones virtuales. Entonces:

$$\alpha_0 = p_0 \cdot \tau, \quad \beta_0 = (1 - p_0) \cdot \tau \quad (17)$$

La elección de una fuerza informativa previa de $\tau = 50$ en los priors Beta responde a un compromiso entre estabilidad inferencial y respeto por la evidencia local. Valores demasiado pequeños ($\tau < 20$) tienden a generar posteriori inestables en nodos con conteos reducidos, mientras que valores excesivamente grandes ($\tau > 100$) pueden dominar los datos y homogeneizar artificialmente el patrón espacial de probabilidades. El valor intermedio $\tau = 50$ proporciona un nivel de suavización adecuado para regiones con baja densidad observacional, evitando estimaciones extremas basadas en muy pocas observaciones, pero sin imponer una estructura rígida sobre nodos con información suficiente. Además, este valor se encuentra dentro del rango usualmente empleado en aplicaciones hidrometeorológicas y climatológicas que utilizan modelos Beta-Binomial para eventos raros, donde se busca un equilibrio entre regularización y sensibilidad a los patrones empíricos observados. En conjunto, $\tau = 50$ contribuye a estimaciones estables, moderadamente informativas y coherentes con la literatura especializada.

c) Estimación posterior local

Para cada nodo, los conteos locales de excedencia se utilizaron para actualizar los priors mediante un esquema conjugado Beta-Binomial:

$$\theta \mid \text{datos} \sim \text{Beta}(\alpha_0 + y, \beta_0 + n - y) \quad (18),$$

donde y representa el número de eventos extremos locales, n el tamaño del vecindario, y α_0, β_0 los parámetros del prior. Bajo el supuesto de independencia condicional entre viento y presión, se estimó la probabilidad conjunta de alcanzar una determinada categoría como el producto de las medias posteriores:

$$P(\text{Cat}X+) = E[\theta_v] \cdot E[\theta_p] \quad (19)$$

Para capturar la incertidumbre asociada a estas estimaciones, se generaron 3000 muestras conjuntas mediante simulación Monte Carlo, a partir de las distribuciones Beta posteriores de viento y presión. Los intervalos de credibilidad al 95% ($IC95\%$) se calcularon como los percentiles 2.5% y 97.5% de las muestras conjuntas.

d) Estructura de salida y visualización

Las capas resultantes por nodo geográfico incluyeron las siguientes variables: latitud (Lat), longitud (Lon), periodo ($Periodo$), probabilidad anual estimada ($P_CatXplus_ann$), que constituye la salida central del modelo bayesiano implementado. Estas probabilidades fueron posteriormente interpoladas en QGIS (Quantum GIS) mediante el método IDW (Inverse Distance Weighting), manteniendo constante la resolución espacial y la simbología entre periodos y categorías, con el fin de garantizar la comparabilidad geográfica de los mapas generados.

Adicionalmente, se calcularon:

- los intervalos de credibilidad al 95% para las estimaciones anuales ($P_CatXplus_l_ann, P_CatXplus_u_ann$),
- las probabilidades condicionales acumuladas por periodo ($P_CatXplus_acum$), definidas como la probabilidad integrada de que un ciclón tropical alcanzara al menos una categoría determinada (Cat3+, Cat4+, Cat5+) dentro de cada intervalo histórico analizado
- sus correspondientes intervalos de credibilidad del 95% ($P_CatXplus_l_acum, P_CatXplus_u_acum$), y
- el número de observaciones locales (n_local) utilizadas en cada nodo geográfico.

Las probabilidades acumuladas se obtuvieron mediante una transformación no lineal de las muestras posteriores de probabilidad anual, bajo la formulación:

$$P_{acum} = 1 - (1 - p_{ann})^T \quad (20)$$

donde T representa la duración del periodo en años. Esta transformación preserva la estructura probabilística del modelo bayesiano y permite generar un indicador de frecuencia condicional acumulada sobre la malla espacial.

Por su carácter complementario, estas variables no fueron incluidas en el cuerpo principal del análisis cartográfico. Los resultados correspondientes a dichas estimaciones se presentan en los Anexos A, B y C, donde se ilustran sus valores por nodo geográfico, con énfasis en la validación espacial y la densidad observacional. Entre ellas, solo las probabilidades acumuladas ($P_CatXplus_acum$) fueron interpoladas para facilitar su visualización comparativa; en cambio, variables como n_local o los intervalos de credibilidad (l_ann , u_ann , l_acum , u_acum) se presentan sin interpolación, ya que su naturaleza discreta o límite probabilístico no permite su estimación entre nodos sin distorsionar el significado estadístico original.

Este enfoque permitió obtener productos cartográficos probabilísticos que representan espacialmente la probabilidad condicional de que un ciclón tropical alcance o supere determinada categoría de intensidad. Matemáticamente, esta formulación puede expresarse como:

$$P_{ij} = P(Intensidad \geq i \mid Viento = x, Presión = y, Lat = \varphi_i, Lon = \lambda_j) \quad (21),$$

donde la estimación se realiza de forma localizada por nodo, integrando tanto las variables físicas observadas como la ubicación geográfica como condicionantes directos del nivel de intensidad ciclónica.

2.5.2 Validación geoespacial de la estimación probabilística

La validez geoespacial del enfoque bayesiano local fue evaluada mediante una combinación de técnicas visuales, empíricas y cuantitativas, con el objetivo de verificar la correspondencia espacial entre las probabilidades estimadas y la ocurrencia real de CTs intensos. Dado que el modelo estima, para cada nodo geográfico, la probabilidad de que un evento alcance o supere una determinada categoría de intensidad, se contrastaron

dichas estimaciones con la distribución observada de CTs de Categoría 3 o superior ($\geq Cat\ 3$) durante el periodo 2010-2021.

a) Cobertura espacial observada

Se definió que un evento observado pertenecía a un nodo si ocurría dentro de su vecindario circular de radio R . Para cada categoría y periodo, se calcularon las coberturas $top-q$, es decir, la proporción de eventos observados que ocurrieron en nodos cuya probabilidad estimada se encuentra por encima del percentil q (se usaron $q = 0.90, 0.80, 0.70$):

$$Cobertura_{top-q} = \frac{Eventos\ en\ nodos\ con\ P \geq Q_q}{Total\ de\ eventos\ observados} \quad (22)$$

b) Validación cruzada temporal

Se aplicó el mismo cálculo de cobertura utilizando los mapas generados con datos del periodo 1950-2009, comparándolos con los eventos reales de 2010-2021. Esta validación cruzada permitió evaluar la estabilidad estructural del modelo y detectar posibles desplazamientos geográficos del riesgo en décadas recientes.

c) Evaluación ROC y AUC

Para cada nodo en 2010-2021, se asignó una etiqueta binaria $y = 1$ si hubo al menos un evento $\geq CatX$ dentro de su vecindario. Con estas etiquetas y las probabilidades $PCatX +$, se construyeron curvas ROC y se calculó el área bajo la curva (AUC) como medida resumen del poder discriminante espacial. Se estimaron intervalos de confianza al 95 % mediante el método de DeLong.

d) Métricas adicionales: Brier, LIFT y calibración

Se calcularon otras métricas relevantes:

- Brier score: error cuadrático medio entre $PCatX +$ y y .
- Curvas de calibración por deciles: relación entre la media de P y la tasa observada en cada decil.
- LIFT (top 20%): medida de ganancia relativa frente a un clasificador aleatorio:

$$LIFT_{20\%} = \frac{Cobertura_{20\%}}{0.20} \quad (23)$$

2.6 Síntesis metodológica

La Figura 9 resume gráficamente la secuencia metodológica desarrollada en este estudio, la cual está estrechamente alineada con los objetivos específicos y la hipótesis de investigación planteados en la introducción.




Figura 9: Diagrama de pasos metodológicos

Desde la delimitación geográfica del dominio de análisis hasta la validación cuantitativa y geoespacial de los resultados, cada etapa fue concebida para responder al problema central: estimar probabilidades condicionadas de intensidad ciclónica en la cuenca del Caribe y el Golfo de México, integrando un enfoque bayesiano jerárquico y una representación espacial explícita basada en las variables físicas clave de viento máximo y presión mínima central.

III. RESULTADOS Y DISCUSIÓN

3.1 Análisis de frecuencias de ciclones tropicales

A continuación, se presenta un análisis comparativo de la frecuencia de ciclones tropicales (CTs) en los tres periodos de estudio: 1950-1979, 1980-2009 y 2010-2021, a partir de los datos del repositorio IBTrACS (v04r00) (Figura 10).




Figura 10: Frecuencia de CTs por periodos de estudio

El análisis histórico muestra variaciones significativas en la frecuencia de CTs a lo largo de las últimas siete décadas. Entre 1950-1979 y 1980-2009 se registró un incremento moderado, pasando de 208 a 220 eventos en periodos de igual duración (30 años), lo que supone un aumento del 5.8 % en el total de casos. Este cambio se reflejó también en la frecuencia anual promedio, que pasó de 6.93 a 7.33 CTs por año. La comparación entre 1980-2009 y 2010-2021, aun considerando que el último periodo abarca únicamente 12 años, reveló un aumento sustancial en la tasa anual, de 7.33 a 9.92 CTs por año. Ajustando por la diferencia en la duración de los periodos, esta cifra representa un incremento relativo de aproximadamente el 35 %, equivalente a 1.59 ciclones adicionales por año respecto al promedio del periodo anterior. En términos generales, la frecuencia anual del último periodo supera en un 43 % la observada entre 1950 y 1979, lo que equivale a casi tres ciclones más por año.

Con el fin de reforzar estos resultados, se aplicaron pruebas estadísticas no paramétricas. La prueba de Mann-Kendall detectó una tendencia ascendente estadísticamente significativa ($p < 0.05$), lo que permitió rechazar la hipótesis nula de ausencia de tendencia. El coeficiente Tau de Kendall, con un valor de 0.80, puso de manifiesto una correlación positiva elevada entre el paso del tiempo y la frecuencia de CTs, evidenciando una tendencia monótona sostenida. De forma complementaria, la pendiente de Sen estimó una tasa de cambio de 0.012 CTs por año ($IC\ 95\%: 0.010 - 0.015$), equivalente a un incremento medio de entre 0.12 y 0.15 CTs por década. El uso de las series anuales completas, en lugar de promedios por bloques, permitió a ambas pruebas corregir el sesgo derivado de la desigual extensión de los periodos analizados.

3.2 Relación entre presión mínima central y velocidad del viento

La Figura 11 muestra la relación entre la velocidad máxima del viento y la presión mínima central de los CTs en los tres periodos estudiados. En todos los casos se observa una marcada correlación negativa: los CTs con vientos más intensos presentan presiones centrales más bajas, en concordancia con la dinámica física de estos sistemas.




Figura 11: Relación entre velocidad del viento (kt) y presión mínima central (hPa) por periodo

La mayor parte de las observaciones se concentra en valores intermedios, con vientos entre 50 y 90 kt y presiones de 970 a 990 hPa, aunque también se registran eventos

extremos con vientos superiores a 130 *kt* y presiones por debajo de 920 *hPa*, particularmente frecuentes en el periodo 1980-2009.

Esta relación persistente respalda la inclusión de ambas variables en la modelación bayesiana, ya que su complementariedad puede mejorar la estimación de la intensidad ciclónica frente a enfoques basados en una sola variable. A partir de esta evidencia, el análisis se centra ahora en evaluar directamente la intensidad de los CTs en cada periodo mediante técnicas de valores extremos, con el fin de caracterizar los eventos más severos registrados en la cuenca.

3.3 Análisis de intensidad ciclónica por periodos

3.3.1 Distribución de velocidad máxima del viento y presión mínima central

Las Figuras 12 y 13 presentan diagramas de caja y bigotes que resumen la distribución de las velocidades máximas del viento (*kt*) y las presiones mínimas centrales (*hPa*) asociadas a los ciclones tropicales (CTs) en los tres periodos de estudio: 1950-1979, 1980-2009 y 2010-2021.




Figura 12: Diagrama de caja y bigotes de velocidades máximas del viento por periodo

En el caso del viento, entre 1950 y 1979 la mediana alcanza los 65 *kt*, con un rango intercuartílico (IQR) de 40 *kt*, delimitado entre 45 y 85 *kt*, y un número reducido de valores extremos (8 casos) que superan ampliamente el límite superior. En el segundo periodo, la mediana desciende a 55 *kt* y el IQR se contrae a 35 *kt* (45 – 80 *kt*), aunque se registra un aumento significativo de eventos atípicos (69 casos), varios de ellos con

velocidades superiores a 140 kt. En la etapa más reciente, la mediana se mantiene en 55 kt, el IQR disminuye a 30 kt (40 – 70kt) y persiste un elevado número de valores extremos (60 casos), lo que evidencia que, pese a cierta estabilidad en la intensidad central, continúan produciéndose ciclones muy intensos.




Figura 13: Diagrama de caja y bigotes de presiones mínimas centrales por periodo

En lo referente a la presión mínima central, el primer periodo presenta una mediana de 990 hPa y un IQR de 28 hPa (972 – 1000 hPa), con 26 valores extremos que incluyen CTs por debajo de 960 hPa. Entre 1980 y 2009, la mediana aumenta ligeramente a 993 hPa, el IQR se mantiene en 27 hPa (974 – 1001 hPa) y el número de valores atípicos crece de forma notable (123 casos), destacando algunos con presiones cercanas a 900 hPa. En 2010-2021, la mediana sube a 994 hPa, la dispersión disminuye a 22 hPa (980 – 1002 hPa) y se registran 101 valores extremos, muchos con presiones inferiores a 940 hPa, indicativas de sistemas de gran intensidad.

Estas distribuciones evidencian que, aunque las medianas sugieren una ligera disminución en la intensidad media, la persistencia de valores extremos tanto en la velocidad máxima del viento como en la presión mínima central confirma la ocurrencia recurrente de CTs severos en la región. Esto coincide con los resultados de investigaciones recientes que relacionan la intensificación de los CTs del Atlántico Norte con factores climáticos de gran escala, tales como el calentamiento de la superficie oceánica y variaciones multidecadales (Balaguru et al., 2024; Bhatia et al., 2022; Garner et al., 2023; Kossin et al., 2020; Liu et al., 2025). En este contexto, se requiere evaluar

cómo las características extremas se han manifestado y modificado a lo largo del tiempo, con el fin de identificar patrones temporales de cambio en la intensidad ciclónica.

3.3.2 Cambios anuales en la intensidad ciclónica extrema

Las Tablas 2 a 4 presentan los valores máximos anuales de velocidad del viento (*kt*) y mínimos de presión central (*hPa*) registrados en los tres periodos de análisis: 1950-1979, 1980-2009 y 2010-2021. Esta información permite evaluar los cambios temporales en la intensidad extrema de los ciclones tropicales (CTs).

Tabla 3: Máximos anuales de viento y presión (1950-1979)

<i>Año</i>	<i>Max_Viento</i>	<i>Min_Presión</i>
<i>1950</i>	115	953
<i>1951</i>	125	937
<i>1952</i>	125	934
<i>1953</i>	110	945
<i>1954</i>	115	938
<i>1955</i>	150	914
<i>1956</i>	105	954
<i>1957</i>	110	946
<i>1958</i>	130	930
<i>1959</i>	115	951
<i>1960</i>	125	930
<i>1961</i>	145	914
<i>1962</i>	95	960
<i>1963</i>	130	933
<i>1964</i>	130	938
<i>1965</i>	120	942
<i>1966</i>	140	927
<i>1967</i>	140	923
<i>1968</i>	85	977
<i>1969</i>	150	900
<i>1970</i>	120	944
<i>1971</i>	90	969
<i>1972</i>	75	978
<i>1973</i>	80	977
<i>1974</i>	130	928
<i>1975</i>	110	942
<i>1976</i>	105	957
<i>1977</i>	150	926
<i>1978</i>	115	947
<i>1979</i>	150	924

Durante 1950-1979, los ciclones más intensos alcanzaron velocidades de hasta 150 *kt* en cuatro ocasiones (1955, 1969, 1977 y 1979), con un valor mínimo de presión de 900 *hPa* en 1969. El promedio anual de viento máximo fue de 118.5 *kt*, mientras que la presión mínima promedio fue de 942.8 *hPa*.

Tabla 4: *Máximos anuales de viento y presión (1980-2009)*

<i>Año</i>	<i>Max_Viento</i>	<i>Min_Presión</i>
1980	165	899
1981	100	975
1982	95	966
1983	100	962
1984	115	949
1985	125	920
1986	75	990
1987	110	958
1988	160	888
1989	120	934
1990	85	980
1991	85	965
1992	150	922
1993	95	965
1994	75	980
1995	130	916
1996	120	934
1997	70	984
1998	155	905
1999	135	921
2000	120	939
2001	125	933
2002	125	934
2003	140	933
2004	145	910
2005	160	882
2006	80	974
2007	150	905
2008	135	941
2009	100	954

En el periodo 1980-2009 se observaron algunos de los eventos más extremos registrados, incluyendo una velocidad máxima de 165 *kt* en 1980 y una presión mínima de 882 *hPa* en 2005. El promedio de velocidad máxima anual fue de 117.3 *kt*, con un 33% de los años alcanzando vientos iguales o superiores a 130 *kt*. La presión mínima promedio se ubicó en 941 *hPa*.

Tabla 5: *Máximos anuales de viento y presión (2010-2021)*

<i>Año</i>	<i>Max_Viento</i>	<i>Min_Presión</i>
2010	125	927
2011	105	942
2012	100	950
2013	75	983
2014	125	940
2015	135	931
2016	130	934
2017	150	913
2018	140	919
2019	160	910
2020	130	937
2021	130	929

Durante el periodo más reciente (2010–2021), se evidenció un incremento en la intensidad media: la velocidad del viento alcanzó un promedio anual de 123.3 *kt*, el valor más alto entre los tres periodos. El 50% de los años presentó ciclones con vientos ≥ 130 *kt*, y el valor mínimo de presión fue de 910 *hPa* en 2019. La presión mínima promedio disminuyó a 932.6 *hPa*, lo que refuerza que las variaciones anuales observadas no son aleatorias, sino que responden a un proceso de intensificación progresiva de los CTs.

En conjunto, los valores anuales presentados evidencian que, si bien existe variabilidad interanual marcada, se mantiene un patrón consistente de eventos de alta intensidad. Para sintetizar y contrastar estos resultados, la Tabla 5 resume los principales estadísticos descriptivos de la velocidad máxima del viento y la presión mínima central para cada uno de los tres periodos de estudio, permitiendo identificar cambios en la magnitud y frecuencia de los ciclones más severos. Esta síntesis facilita la transición hacia el análisis de las tendencias temporales, donde se examina la evolución de estas variables de intensidad mediante técnicas de suavización.

Tabla 6: Comparación estadística de la intensidad ciclónica anual por periodo

<i>Estadístico / Variable</i>	<i>1950-1979</i>	<i>1980-2009</i>	<i>2010-2021</i>
<i>Viento máx. anual (kt)</i>			
<i>Promedio</i>	118.5	117.3	123.3
<i>Desviación estándar</i>	19.7	24.5	16.9
<i>Valor máximo</i>	150	165	160
% años $\geq$ 130 kt	30% (9 de 30)	33% (10 de 30)	50% (6 de 12)
<i>Presión mín. anual (hPa)</i>			
<i>Promedio</i>	942.8	941.0	932.6
<i>Desviación estándar</i>	16.3	25.2	11.8
<i>Valor mínimo</i>	900	882	910
% años $\leq$ 930 hPa	23% (7 de 30)	33% (10 de 30)	33% (4 de 12)

3.3.3 Tendencias temporales de las variables

Las Figuras 14 y 15 presentan la evolución temporal de los valores máximos anuales de velocidad del viento y mínimos de presión central de los ciclones tropicales (CTs), respectivamente, utilizando curvas de suavización LOESS con un parámetro de ajuste (span) de 0.75. Esta técnica permite identificar patrones subyacentes y posibles tendencias a largo plazo sin imponer una forma funcional estricta.

En la Figura 14 se identifican tres comportamientos distintivos. Durante el periodo 1950-1979, la serie de velocidad máxima del viento muestra relativa estabilidad, con valores en torno a 120 kt y pocas fluctuaciones abruptas. En el intervalo 1980-2009, la serie presenta mayor variabilidad, con un descenso leve en la década de 1980 seguido de una recuperación gradual hacia finales del periodo. En contraste, el periodo 2010-2021 exhibe una tendencia claramente creciente hasta 2018, donde se estabiliza alrededor de los 130 – 140 kt.




Figura 14: Serie temporal de la velocidad máxima anual del viento (kt)

En la Figura 15, durante 1950-1979, la presión mínima anual se mantuvo relativamente estable, con valores promedio cercanos a 940 hPa. En el periodo 1980–2009 se observa una mayor oscilación, con presiones extremas más frecuentes, destacando una tendencia descendente hacia 2005. Finalmente, en 2010-2021 se identifica una disminución sostenida en la presión mínima, alcanzando valores cercanos a 920 hPa hacia el final del periodo.




Figura 15: Serie temporal de la presión mínima anual (hPa)

3.4 Modelado de extremos mediante distribución GEV

Con el objetivo de caracterizar el comportamiento extremo de la intensidad de los ciclones tropicales (CTs), se ajustó un modelo Generalizado de Valores Extremos (GEV) a los máximos anuales de velocidad del viento y a los mínimos anuales de presión central, esta última variable, transformada a valores negativos para el ajuste y luego invertida para la interpretación. El análisis se realizó por separado para los tres periodos definidos: 1950-1979, 1980-2009 y 2010-2021.

La Tabla 6 resume los parámetros estimados para cada variable y periodo, incluyendo los errores estándar, así como los valores de log-verosimilitud, AIC y BIC como criterios comparativos del ajuste.

Tabla 7: Parámetros estimados del modelo GEV para velocidad del viento y presión mínima central ($\pm$ error estándar)

A) Velocidad máxima del viento (en kt)

	1950-1979	1980-2009	2010-2021
μ (localización)	115.18 $\pm$ 4.84	110.67 $\pm$ 6.18	120.54 $\pm$ 7.59
σ (escala)	22.91 $\pm$ 4.14	29.27 $\pm$ 5.01	24.00 $\pm$ 5.86
ξ (forma)	-0.566 $\pm$ 0.20	-0.448 $\pm$ 0.19	-0.541 $\pm$ 0.21
log-verosimilitud	-131.94	-141.38	-53.37
AIC	269.89	288.76	112.74
BIC	274.09	292.97	114.19

B) Presión mínima central (en hPa)

	1950-1979	1980-2009	2010-2021
μ (localización)	947.50 $\pm$ 3.86	951.26 $\pm$ 6.04	936.78 $\pm$ 6.78
σ (escala)	19.39 $\pm$ 2.70	28.49 $\pm$ 4.58	21.18 $\pm$ 6.57
ξ (forma)	-0.329 $\pm$ 0.10	-0.265 $\pm$ 0.17	-0.762 $\pm$ 0.30
log-verosimilitud	-130.46	-143.59	-50.30
AIC	266.93	293.17	106.59
BIC	271.13	297.38	108.05

Los parámetros estimados para el viento muestran una variabilidad entre periodos. El parámetro de localización (μ), que representa el centro de la distribución de máximos

anuales, muestra una ligera disminución en 1980-2009 ($\mu = 110.67 \text{ kt}$) respecto al periodo base 1950-1979 ($\mu = 115.18 \text{ kt}$), seguida de un aumento en el periodo reciente ($\mu = 120.54 \text{ kt}$), lo que está relacionado con la mayor frecuencia de CTs intensos en años recientes. El parámetro de escala (σ), asociado a la dispersión, es mayor en el periodo 1980-2009, lo que sugiere una mayor variabilidad en los máximos de viento durante esa etapa. El parámetro de forma (ξ) es negativo en los tres periodos, lo que implica colas acotadas, consistentes con límites físicos en la velocidad del viento. Sin embargo, su valor absoluto más alto en 1950-1979 y 2010-2021 ($\xi \approx -0.54$ a -0.56) podría reflejar una mayor frecuencia de valores extremos dentro de un rango finito. Los valores del *AIC* y *BIC* indican que el modelo ajusta mejor en el periodo reciente (*AIC* = 112.74), lo que puede atribuirse a una mayor calidad de los datos satelitales post-2000.

En cuanto a la presión central, el parámetro de localización (μ) muestra un descenso en el periodo más reciente ($\mu = 936.78 \text{ hPa}$), lo cual es coherente con una intensificación de los CTs, ya que valores más bajos de presión implican mayor intensidad. El parámetro de forma (ξ) también es negativo en todos los periodos, lo cual es esperable dada la existencia de un límite físico inferior para la presión atmosférica. Notablemente, el valor más negativo se encuentra en 2010-2021 ($\xi = -0.76$), lo que sugiere colas más acotadas, pero también mayor concentración de eventos extremadamente intensos. La menor presión mínima alcanzada en este periodo también es consistente con la aparición de huracanes de categoría 5 como Irma (2017) y María (2017). Respecto a los indicadores de ajuste, tanto el *AIC* como el *BIC* reflejan un mejor ajuste del modelo GEV para el periodo 2010-2021 (*AIC* = 106.59), lo que se asocia a una mayor homogeneidad y calidad de los datos en la era satelital reciente.

Los valores de *AIC/BIC* informan el equilibrio ajuste-complejidad dentro de cada conjunto de datos; no deben compararse de forma directa entre periodos con tamaños muestrales distintos (p. ej., 30 vs 12 años), pues ello sesga la comparación.

3.4.1 Evaluación del ajuste del modelo GEV

Como parte del análisis de extremos, se evaluó la capacidad del modelo GEV para representar adecuadamente la distribución de los valores anuales máximos de velocidad del viento y mínimos de presión central registrados en CTs. Para ello, se compararon las densidades empíricas, estimadas mediante suavizado kernel, con las densidades teóricas

derivadas del modelo GEV ajustado por periodo. Las Figuras 3.7 a 3.12 ilustran estos resultados para ambas variables (viento y presión) en los tres periodos analizados.

En el primer periodo (1950-1979), el modelo GEV logró capturar adecuadamente la forma de las distribuciones observadas tanto para la velocidad máxima del viento (Figura 16) como para la presión mínima central (Figura 17). En el caso del viento, se observa un buen ajuste en el cuerpo y la cola derecha de la distribución, lo cual es fundamental para representar eventos extremos. Respecto a la presión, la densidad teórica reproduce la forma asimétrica descendente entre los 915 y 950 *hPa*, reflejando correctamente la presencia de eventos intensos.




Figura 16: Densidad observada y ajuste GEV para la velocidad máxima del viento (1950-1979)




Figura 17: Densidad observada y ajuste GEV para la presión mínima central (1950-1979)




Figura 18: Densidad observada y ajuste GEV para la velocidad máxima del viento (1980-2009)




Figura 19: Densidad observada y ajuste GEV para la presión mínima central (1980–2009)

Durante el segundo periodo (1980-2009), el modelo mantuvo un desempeño aceptable (Figuras 18 y 19). Para el viento, el ajuste captura la tendencia general de la distribución, aunque presenta una leve subestimación en la cola superior (vientos > 140 kt), lo que sugiere que algunos eventos extremos podrían estar infraestimados. Por otro lado, la presión mínima mostró una mejor correspondencia, si bien el modelo suaviza parte de la variabilidad empírica, un comportamiento esperable dado el carácter parsimonioso de la distribución GEV.

En el periodo más reciente (2010-2021), el ajuste se mantiene razonablemente consistente (Figuras 20 y 21), aunque con mayor dispersión en los datos. En particular, la distribución observada del viento presenta una forma más compleja y posiblemente multimodal, lo cual podría estar relacionado con una intensificación reciente de eventos extremos. Aunque el modelo GEV logra capturar el comportamiento central, se evidencia una ligera desviación en los valores más altos. En cuanto a la presión, el modelo describe bien el patrón general, pero tiende a subestimar la densidad en los valores más bajos (< 930 hPa), lo cual podría indicar un aumento en la frecuencia de ciclones más intensos durante este periodo.




Figura 20: Densidad observada y ajuste GEV para la velocidad máxima del viento (2010-2021)




Figura 21: Densidad observada y ajuste GEV para la presión mínima central (2010-2021)

En conjunto, estas comparaciones visuales confirman que el modelo GEV proporciona una representación razonable de los extremos anuales de viento y presión, especialmente en los rangos críticos para el análisis de riesgos.

La evaluación adicional del ajuste se llevó a cabo mediante gráficos de cuantiles-cuantiles (QQ-plots), presentados en las Figuras 22 a 27. Estos gráficos permiten visualizar el grado de concordancia entre los cuantiles empíricos observados y los cuantiles teóricos generados por el modelo ajustado, tanto para la velocidad máxima del viento como para la presión mínima central (transformada), a lo largo de los tres periodos estudiados.




Figura 22: *Velocidad máxima del viento (1950-1979) bajo el modelo GEV*




Figura 23: *Presión mínima central (1950-1979) bajo el modelo GEV*

Durante el periodo 1950-1979, el gráfico correspondiente a la velocidad del viento (Figura 22) revela un ajuste razonable en la mayoría de los cuantiles, aunque los valores más extremos tienden a situarse ligeramente por debajo de la línea teórica, lo que indica una leve subestimación de los vientos más intensos. Por su parte, la presión mínima transformada (Figura 23) presenta una alineación general adecuada, aunque se aprecia cierta dispersión en los valores más altos (presiones menos intensas), lo que sugiere mayor variabilidad en esa porción de la distribución.




Figura 24: *Velocidad máxima del viento (1980-2009) bajo el modelo GEV*




Figura 25: *Presión mínima central (1980-2009) bajo el modelo GEV*

En el periodo 1980-2009, el modelo muestra un ajuste más preciso. La Figura 24, correspondiente a la velocidad del viento, exhibe una notable alineación entre cuantiles empíricos y teóricos, incluso en los extremos, lo cual refuerza la validez del modelo GEV para representar eventos severos durante este intervalo. En contraste, el gráfico de presión mínima (Figura 25) muestra una mayor dispersión, especialmente en los cuantiles inferiores, aunque el patrón general sigue siendo aceptable.




Figura 26: *Velocidad máxima del viento (2010-2021) bajo el modelo GEV*




Figura 27: *Presión mínima central (201-2021) bajo el modelo GEV*

Finalmente, para el periodo más reciente (2010-2021), los resultados reflejan un ajuste particularmente sólido para la velocidad del viento (Figura 26), con una alineación casi perfecta entre datos observados y predichos, lo que indica un excelente desempeño del modelo en la representación de los extremos actuales. No obstante, la Figura 27 (presión mínima) revela una leve subestimación en los cuantiles más bajos, lo que podría estar asociado a la intensificación reciente de ciclones tropicales más severos en la región, fenómeno ampliamente documentado en estudios recientes sobre cambio climático e impactos regionales.

La validez estadística del modelo GEV para representar los extremos anuales de velocidad máxima del viento y presión mínima central fue evaluada mediante la prueba de bondad de ajuste de Anderson-Darling, aplicada a las probabilidades transformadas de cada conjunto de datos.

Los resultados para los tres periodos analizados mostraron valores del estadístico Anderson-Darling consistentemente bajos, acompañados de valores p elevados en todos los casos. En el caso de la velocidad del viento, los valores del estadístico oscilaron entre 0.35 y 0.55, con p -valores superiores a 0.69, lo que indica que no se rechaza la hipótesis nula de adecuación a una distribución uniforme (lo que implicaría una correcta especificación del modelo GEV). Para la presión mínima central, los resultados fueron incluso más sólidos, con valores del estadístico aún menores (entre 0.26 y 0.36) y p -valores cercanos o superiores a 0.88, lo que respalda la validez del ajuste.

Estos resultados refuerzan las evidencias gráficas presentadas anteriormente, sugiriendo que el modelo GEV proporciona un ajuste estadísticamente adecuado para ambas variables extremas en los tres periodos de estudio.

3.4.2 Niveles de retorno e incertidumbre asociada

Con el objetivo de cuantificar la magnitud de eventos extremos asociados a ciclones tropicales, se estimaron los niveles de retorno para los valores anuales máximos de velocidad del viento y mínimos de presión atmosférica central, mediante el ajuste de la distribución GEV. Los niveles de retorno fueron calculados para periodos de 2, 5, 10, 20 y 50 años. Estimar un nivel de retorno de, por ejemplo, 100 años implicaría una extrapolación más allá de la información contenida en los datos, lo cual puede inducir

incertidumbre no controlada. Adicionalmente, se estimaron intervalos de confianza al 95% mediante técnicas bootstrap con 1000 replicaciones, filtrando valores no físicos o extremos.

Los niveles de retorno de velocidad del viento (expresados en nudos) muestran una tendencia creciente en los tres periodos analizados (Tabla 7 y Figura 28). Para el periodo 1950-1979, el nivel de retorno a 50 años fue de aproximadamente 151.2 nudos ($IC_{95\%}$: 146.7 – 155.9), mientras que en el periodo 1980–2009 esta estimación se incrementó a 164.6 nudos ($IC_{95\%}$: 156.1 – 184.2). En el periodo más reciente (2010-2021), el nivel de retorno a 50 años alcanzó los 159.6 nudos ($IC_{95\%}$: 134.8 – 169.4), manteniéndose en valores superiores a los observados en las décadas iniciales.

De forma inversa a la variable anterior, los niveles de retorno de presión mínima central (en hPa) evidencian una tendencia descendente, reflejando una intensificación de los sistemas (Tabla 8 y Figura 29). En el periodo 1950-1979, la presión mínima estimada para un evento con período de retorno de 50 años fue de 904.9 hPa ($IC_{95\%}$: 896.9 – 923.8). Esta disminuyó a 882.0 hPa ($IC_{95\%}$: 843.1 – 902.5) durante 1980-2009. En el periodo 2010-2021, el valor estimado fue de 910.4 hPa ($IC_{95\%}$: 888.4 – 927.1), lo cual podría reflejar un leve retroceso o efecto de la menor longitud de la serie (12 años) y su variabilidad interanual.

Tabla 8: Niveles de retorno estimados (en nudos) con Intervalos de Confianza ($IC_{95\%}$) para viento máximo de ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)

<i>Periodo</i>	<i>1950–</i>	<i>IC</i>	<i>IC</i>	<i>1980–</i>	<i>IC</i>	<i>IC</i>	<i>2010–</i>	<i>IC</i>	<i>IC</i>
<i>Retorno</i>	<i>1979</i>	<i>2.5%</i>	<i>97.5%</i>	<i>2009</i>	<i>2.5%</i>	<i>97.5%</i>	<i>2021</i>	<i>2.5%</i>	<i>97.5%</i>
<i>(años)</i>									
2	122.77	112.74	135.47	120.56	104.34	137.49	128.52	114.88	144.42
5	138.33	129.68	146.33	142.64	129.12	155.62	145.20	131.51	155.85
10	144.32	137.17	148.52	152.17	142.33	160.57	151.78	133.65	158.47
20	148.11	142.08	149.82	158.74	150.27	165.68	156.02	134.42	160.59
50	151.19	146.73	155.91	164.64	156.10	184.22	159.55	134.81	169.40




Figura 28: Niveles de retorno con intervalos de confianza al 95% estimados de velocidad máxima del viento (en nudos) para ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)

Tabla 9: Niveles de retorno estimados (hPa) con Intervalos de Confianza (IC 95%) para presión mínima central de ciclones tropicales según periodo (1950–1979, 1980–2009 y 2010–2021)

Período Retorno (años)	1950–1979	IC 2.5%	IC 97.5%	1980–2009	IC 2.5%	IC 97.5%	2010–2021	IC 2.5%	IC 97.5%
2	940.81	932.31	947.80	941.31	926.38	956.79	930.01	919.44	940.38
5	924.55	917.77	932.55	916.00	902.95	931.12	917.84	912.17	929.76
10	916.69	910.17	927.98	902.98	892.72	916.47	913.98	910.64	927.66
20	910.77	904.09	925.66	892.70	877.59	908.31	911.87	903.70	927.24
50	904.93	896.87	923.80	882.01	843.12	902.50	910.39	888.40	927.06




Figura 29: Niveles de retorno con intervalos de confianza al 95% estimados de presión mínima central (en hPa) para ciclones tropicales según periodo (1950-1979, 1980-2009 y 2010-2021)

En conjunto, los niveles de retorno de presión mínima y viento apuntan hacia una intensificación de los ciclones tropicales a lo largo del tiempo, especialmente entre las décadas de 1980 a 2009. Esta intensificación se refleja tanto en una mayor velocidad de viento como en menores presiones centrales, elementos clave para caracterizar la peligrosidad de estos fenómenos. Estos constituyen una herramienta crucial para evaluar el riesgo de ciclones extremos, informar políticas de adaptación climática y diseñar infraestructura resiliente en regiones altamente expuestas como el Caribe y el Golfo de México.

3.5 Inferencias del modelo bayesiano jerárquico para viento y presión mínima

Se presentan a continuación las estimaciones posteriores obtenidas mediante el modelo bayesiano jerárquico ajustado a los valores anuales extremos de velocidad máxima del viento (en *kt*) y presión mínima central (en *hPa*) de CTs, agrupados por los periodos de estudio: 1950-1979, 1980-2009 y 2010-2021. El modelo logró incorporar los priors de forma informativa, pero flexible, estimando los parámetros en concordancia con los resultados del ajuste clásico (MLE).

Las Tablas 9 y 10 muestran las inferencias del modelo (estimaciones posteriores, media posterior, desviación estándar (*sd*) y los percentiles 2.5%, 50% (mediana) y 97.5% para cada parámetro ajustado mediante MCMC. Los valores de presión han sido corregidos (multiplicados por -1) para mantener la interpretación coherente con la magnitud original (en *hPa*).

Tabla 10: *Estimaciones posteriores del modelo bayesiano jerárquico para velocidad máxima del viento y presión mínima central*

	Periodo	μ (media)	σ (escala)	ξ (forma)
Velocidad máxima del viento (nudos)	1950-1979	114.88	23.62	-0.54
		(± 3.26)	(± 2.81)	(± 0.12)
	1980-2009	110.58	29.90	-0.41
		(± 3.76)	(± 3.26)	(± 0.11)
	2010-2021	120.66	25.19	-0.49
		(± 4.06)	(± 3.48)	(± 0.13)
Presión mínima central (hPa)	1950-1979	947.69	20.26	-0.30
		(± 3.11)	(± 2.41)	(± 0.09)
	1980-2009	951.47	29.19	-0.22
		(± 3.83)	(± 3.17)	(± 0.12)
	2010-2021	936.88	21.87	-0.68
		(± 3.61)	(± 3.18)	(± 0.12)

Tabla 11: Estimaciones posteriores de los parámetros GEV de viento máximo y presión mínima por periodo (modelo bayesiano)

<i>Variable</i>	<i>Periodo</i>	<i>Parámetro</i>	2.5%	50%	97.5%
Velocidad del viento (nudos)	1950-1979	μ	108.32	114.95	121.10
		σ	18.63	23.46	29.60
		ξ	-0.78	-0.54	-0.30
	1980-2009	μ	103.11	110.62	117.91
		σ	23.93	29.76	36.67
		ξ	-0.61	-0.41	-0.16
	2010-2021	μ	112.62	120.70	128.62
		σ	18.94	25.00	32.51
		ξ	-0.74	-0.49	-0.23
Presión mínima central (hPa)	1950-1979	μ	953.93	947.63	941.66
		σ	16.10	20.05	25.52
		ξ	-0.47	-0.31	-0.10
	1980-2009	μ	959.00	951.44	944.01
		σ	23.45	29.04	35.80
		ξ	-0.43	-0.23	0.03
	2010-2021	μ	944.11	936.86	929.99
		σ	16.20	21.72	28.66
		ξ	-0.88	-0.69	-0.42

3.5.1 Probabilidades condicionadas por categoría de intensidad

A partir de los parámetros posteriores estimados del modelo GEV para cada uno de los tres periodos analizados (1950-1979, 1980-2009 y 2010-2021), y bajo el supuesto de independencia condicional entre la velocidad máxima del viento y la presión central mínima (utilizado como línea base), se estimaron las probabilidades conjuntas exactas de que un ciclón tropical alcanzara una categoría específica de intensidad según la escala Saffir-Simpson. Estas probabilidades corresponden a la intersección entre los intervalos

de viento y presión definidos para cada categoría, es decir, se consideró simultáneamente que ambos umbrales se cumplan dentro del mismo evento.

Las Tablas 11, 12 y 13 presentan las probabilidades conjuntas exactas por categoría Saffir-Simpson y las probabilidades acumuladas, incluyendo sus intervalos de credibilidad al 95% (IC95%). Seguidamente se resumen e interpretan gráficamente dichos resultados.

Tabla 12: Probabilidades conjuntas por categoría e IC 95%, Periodo 1950-1979

Categoría	P(Cat)	IC 95%
TS	0.0003	[0.0000, 0.0011]
Cat 1	0.0067	[0.0022, 0.0151]
Cat 2	0.0153	[0.0056, 0.0292]
Cat 3	0.1080	[0.0658, 0.1535]
Cat 4	0.0660	[0.0212, 0.1193]
Cat 5	0.0144	[0.0000, 0.0383]
≥ Cat 1	0.2103	[0.1645, 0.2537]
≥ Cat 2	0.2036	[0.1587, 0.2468]
≥ Cat 3	0.1375	[0.0903, 0.1856]
≥ Cat 4	0.0576	[0.0178, 0.0940]
≥ Cat 5	0.0055	[0.0000, 0.0228]

Tabla 13: Probabilidades conjuntas por categoría e IC 95%, Periodo 1980-2009

Categoría	P(Cat)	IC 95%
TS	0.0013	[0.0002, 0.0041]
Cat 1	0.0088	[0.0036, 0.0167]

Cat 2	0.0244	[0.0117, 0.0399]
Cat 3	0.0470	[0.0229, 0.0796]
Cat 4	0.0530	[0.0243, 0.0902]
Cat 5	0.0313	[0.0025, 0.0598]
$\geq$ Cat 1	0.1646	[0.1209, 0.1997]
$\geq$ Cat 2	0.1489	[0.1123, 0.1903]
$\geq$ Cat 3	0.1265	[0.0905, 0.1676]
$\geq$ Cat 4	0.0729	[0.0425, 0.1094]
$\geq$ Cat 5	0.0282	[0.0025, 0.0599]

Tabla 14: Probabilidades conjuntas por categoría e IC 95%, Periodo 2010-2021

Categoría	P(Cat)	IC 95%
TS	0.0008	[0.0000, 0.0046]
Cat 1	0.0039	[0.0004, 0.0103]
Cat 2	0.0091	[0.0013, 0.0207]
Cat 3	0.0810	[0.0321, 0.1351]
Cat 4	0.1170	[0.0501, 0.1866]
Cat 5	0.0137	[0.0000, 0.0389]
$\geq$ Cat 1	0.2248	[0.0868, 0.2614]
$\geq$ Cat 2	0.2209	[0.0854, 0.2596]
$\geq$ Cat 3	0.1661	[0.0754, 0.2497]
$\geq$ Cat 4	0.0931	[0.0051, 0.1678]
$\geq$ Cat 5	0.0043	[0.0000, 0.0389]

La Figura 30 muestra la distribución media de dichas probabilidades por categoría Saffir-Simpson, desde tormenta tropical (TS) hasta huracán categoría 5 (Cat 5), por periodo.




Figura 30: Probabilidades conjuntas por categoría de intensidad ciclónica (TS–Cat5) estimadas a partir de distribuciones GEV para viento y presión, por periodo histórico.

En el periodo 1950-1979, las categorías predominantes fueron Cat 3 y Cat 4, mientras que la ocurrencia de eventos Cat 5 fue marginal. En 1980-2009, destaca un aumento de la categoría 5 (color fucsia), con una probabilidad media superior al 5 %, lo que representa una intensificación extrema transitoria durante ese periodo. En el periodo más reciente (2010-2021), la distribución se concentra en las categorías 3 y 4, que en conjunto representan la mayor parte de la probabilidad total. La categoría 4 muestra el mayor aporte individual, seguida de la categoría 3. La categoría 5 reaparece con menor intensidad, pero persiste como componente del riesgo extremo.

La Figura 31 presenta las probabilidades acumuladas por periodo para tres umbrales de interés: $\geq$ Cat 3, $\geq$ Cat 4 y $\geq$ Cat 5. En el panel izquierdo ($\geq$ Cat 3), se observa un aumento de la probabilidad media desde aproximadamente 14 % en 1950-1979 hasta 18 % en 2010-2021, con mayor incertidumbre en el periodo reciente. En el caso de $\geq$ Cat 4, la probabilidad se incrementa desde 6 % hasta cerca de 10 %. Para $\geq$ Cat 5, la probabilidad acumulada se mantiene por debajo del 5 % en todos los periodos, con un

pico transitorio en 1980-2009. La mayor amplitud de los intervalos creíbles en este último caso refleja la alta variabilidad e incertidumbre inherente a eventos extremos raros.




Figura 31: Probabilidades acumuladas de intensidad ciclónica para $\geq \text{Cat } 3$, $\geq \text{Cat } 4$ y $\geq \text{Cat } 5$

Finalmente, la Figura 32 muestra la evolución temporal de las probabilidades acumuladas para los cinco umbrales de intensidad ($\geq \text{Cat } 1$ a $\geq \text{Cat } 5$). Se observa que las probabilidades para los umbrales bajos ($\geq \text{Cat } 1$ y $\geq \text{Cat } 2$) permanecen relativamente estables a lo largo del tiempo. En cambio, los umbrales $\geq \text{Cat } 3$ y $\geq \text{Cat } 4$ presentan una tendencia claramente ascendente, particularmente en el periodo 2010-2021. La probabilidad de eventos $\geq \text{Cat } 4$ casi se duplica en relación con los periodos anteriores. Para el umbral $\geq \text{Cat } 5$, la evolución es menos concluyente debido a la superposición de los IC95% entre periodos.

Esta visualización comparativa permite identificar no solo un incremento en la probabilidad de eventos intensos, sino también un gradiente creciente de riesgo a medida que se asciende en la escala de intensidad. Las bandas de incertidumbre más amplias en los umbrales superiores son consistentes con la baja frecuencia de ocurrencia y alta variabilidad de estos eventos en los registros históricos.




Figura 32: Evolución de las probabilidades acumuladas por umbral de intensidad ciclónica (de $\geq$ Cat1 a $\geq$ Cat5) entre 1950-2021

3.5.2 Convergencia y validación

La Figura 33 muestra los gráficos de traza correspondientes a los parámetros del modelo GEV ajustado a la velocidad máxima del viento para los tres periodos definidos: 1950-1979 [1], 1980-2009 [2] y 2010-2021 [3]. De manera análoga, la Figura 34 presenta los gráficos de traza para los parámetros del mismo modelo, pero aplicados a la presión mínima central (en hPa), también segmentados por periodo.

En ambos casos, se representan las cuatro cadenas MCMC generadas mediante el algoritmo NUTS (No-U-Turn Sampler), lo cual permite evaluar visualmente la convergencia y mezcla de las cadenas para los tres parámetros de interés: localización (μ), escala (σ) y forma (ξ). Estos gráficos son fundamentales para diagnosticar la estabilidad del muestreo y validar la calidad de las inferencias posteriores obtenidas a partir del modelo jerárquico bayesiano.

Los gráficos de traza evidencian una buena mezcla y convergencia de las cadenas MCMC para todos los parámetros del modelo GEV (μ, σ, ξ) en los tres periodos analizados, tanto para la velocidad máxima del viento como para la presión mínima central. En todos los

casos, las cadenas fluctúan libremente alrededor de regiones centrales estables, sin mostrar patrones sistemáticos, tendencias ni estancamientos, lo que sugiere una adecuada exploración del espacio paramétrico por parte del algoritmo NUTS.




Figura 33: Gráficos de trazas de los parámetros del modelo GEV para la variable velocidad máxima del viento

Los parámetros de localización (μ) presentan trayectorias bien mezcladas y centradas en torno a valores consistentes con las estimaciones obtenidas por máxima verosimilitud, destacándose valores más bajos en el periodo 2010-2021 para la presión, lo cual es coherente con la intensificación reciente de los ciclones. Los parámetros de escala (σ) muestran una variabilidad intermedia, siendo más pronunciada en el periodo 1980-2009, en concordancia con la mayor dispersión observada en los datos durante ese intervalo. Por su parte, los parámetros de forma (ξ) permanecen en el rango negativo (aproximadamente -0.75 a 0), lo que confirma una distribución GEV de tipo Weibull (cola acotada), con una mayor negatividad en el periodo más reciente.

Gráficos de traza - Presión mínima central




Figura 34: Gráficos de trazas de los parámetros del modelo GEV para la variable presión mínima central

Las Figuras 35 y 36 muestran las funciones de autocorrelación (ACF) de los parámetros μ , σ y ξ del modelo GEV ajustado a la velocidad máxima del viento y a la presión mínima central, respectivamente, para los tres periodos analizados (1950-1979, 1980-2009 y 2010-2021). En ambas figuras se representan las autocorrelaciones hasta 20 lags para cada una de las cuatro cadenas MCMC independientes generadas mediante el algoritmo NUTS, lo que permite evaluar la dependencia temporal dentro de las cadenas y la eficiencia del muestreo posterior en ambos casos.

Cada gráfico de autocorrelación mostró los valores desde el retardo 0 hasta el retardo 20 para cada una de las cuatro cadenas generadas por el muestreador. Los resultados indican que, en general, las funciones de autocorrelación decrecen rápidamente hacia cero en los primeros 5 – 10 lags para todos los parámetros y periodos, lo cual sugiere una baja dependencia entre las muestras sucesivas y, por tanto, una alta eficiencia del muestreo.




Figura 35: Gráficos de autocorrelación para los parámetros μ , σ y ξ del modelo GEV aplicado a la velocidad máxima del viento, agrupados por periodo




Figura 36: Gráficos de autocorrelación para los parámetros μ , σ y ξ del modelo GEV aplicado a la presión mínima central, agrupados por periodo

Para el parámetro μ (localización), tanto en viento como en presión, la autocorrelación decrece abruptamente desde el primer lag en todas las cadenas, confirmando un buen nivel de mezcla entre muestras. El parámetro σ (escala) presenta una ligera persistencia en la autocorrelación para el periodo 1980-2009, particularmente en la variable viento, lo cual es coherente con la mayor variabilidad observada en ese periodo. El parámetro ξ (forma) mantiene una autocorrelación baja y estable en todos los casos, incluso en condiciones de colas más pesadas, como en la presión mínima para el periodo 2010-2021. Esto sugiere que la exploración de los extremos del modelo fue eficiente.

Estos resultados complementan los diagnósticos de convergencia obtenidos mediante el estadístico potencial de escala reducida ($\hat{R} \approx 1$) y los tamaños efectivos de muestra ($ESS > 400$), fortaleciendo la validez y fiabilidad de las inferencias bayesianas obtenidas en el modelo.

Aunque no se realizó un análisis formal de sensibilidad a los priors, estos fueron definidos a partir de estimaciones obtenidas mediante máxima verosimilitud en modelos GEV ajustados por periodo, y se mantuvieron dentro de rangos razonables en relación con los datos observados. Dado que el objetivo principal del estudio es la predicción condicional de intensidad ciclónica, se priorizó la evaluación de la capacidad predictiva del modelo por encima de la sensibilidad paramétrica.

La validez de las inferencias se respalda mediante los resultados del Posterior Predictive Check (PPC) y la estabilidad observada en los intervalos de predicción. Este método consiste en comparar la distribución observada de los datos reales con las distribuciones simuladas desde las muestras posteriores del modelo, generando así una verificación gráfica y estadística de la capacidad predictiva del modelo. En las figuras siguientes de PPC se comparan las densidades empíricas y simuladas para las dos variables clave: velocidad máxima del viento y presión mínima central. Además, se evalúan los estadísticos resumen como la media y el valor máximo de las réplicas generadas, contrastados con los valores observados.

La Figura 37 presenta la comparación entre la distribución observada del viento máximo anual (y , línea negra) y las réplicas simuladas (y_{rep} , líneas azul claro) generadas desde el modelo jerárquico bayesiano. Visualmente, se aprecia una alta concordancia entre ambas distribuciones, destacando que el modelo reproduce de manera adecuada la asimetría positiva, la ubicación del modo principal ($\sim 110 - 120 \text{ kt}$) y la dispersión en las colas.

El patrón general indica que el modelo no subestima ni sobreestima sistemáticamente ninguna zona de la distribución, lo que sugiere que la estructura jerárquica utilizada captura correctamente el comportamiento extremo del viento. Esta validación gráfica respalda la idoneidad del modelo para propósitos predictivos y para la estimación de incertidumbre en escenarios futuros.




Figura 37: Comparación entre la distribución observada y las distribuciones generadas por el modelo bayesiano para la velocidad máxima del viento

La Figura 38 muestra la validación equivalente para la presión mínima central (transformada a valores negativos). De forma similar al caso del viento, se observa una alta superposición entre la densidad empírica (y) y las curvas simuladas desde la posterior (y_{rep}). El modelo logra capturar con precisión la forma de la distribución, su asimetría leve hacia valores extremos y el rango de variabilidad esperado.

El ajuste es particularmente bueno en torno al modo ($\sim 940 \text{ hPa}$), y las réplicas reflejan correctamente la incertidumbre inherente al proceso de formación de presiones mínimas

extremas en CTs. No se evidencian desviaciones sistemáticas ni sobreajuste, lo cual confirma la validez del modelo para esta variable.

PPC - Presión mínima




Figura 38: Comparación entre la distribución observada y las distribuciones generadas por el modelo bayesiano para la presión mínima central

En conjunto, ambos PPC indican que el modelo bayesiano jerárquico es capaz de generar distribuciones realistas para las variables de viento y presión, reproduciendo tanto la forma general como la variabilidad de los datos observados. Esta validación visual constituye un insumo clave para justificar la posterior derivación de probabilidades condicionales y escenarios de riesgo ciclónico bajo incertidumbre, conforme a los objetivos de esta investigación.

La evaluación de la media y del máximo (mínimo en el caso de presión) a partir de las réplicas también respaldan la validez del modelo. Las figuras 39 a 42 muestran que los valores observados $T(y)$ se ubican en el centro de las distribuciones generadas $T(y_{rep})$, lo que implica que tanto el comportamiento central como los extremos son bien representados por el modelo ajustado.

PPC - Media (viento)




Figura 39: Distribución de la media simulada del viento máximo frente a la media observada

PPC - Media (presión)




Figura 40: Distribución de la media simulada de la presión mínima central frente a la media observada

PPC - Máximo (viento)




Figura 41: Distribución de los valores máximos simulados del viento frente al valor máximo observado

PPC - Mínimo (presión)




Figura 42: Distribución de los valores máximos simulados de la presión mínima central frente al valor máximo observado

Como verificación cuantitativa adicional, se calculó la proporción de observaciones reales que se encuentran dentro del intervalo creíble del 95% de las simulaciones. Los resultados fueron:

- Cobertura para viento máximo: 100%
- Cobertura para presión mínima: 98.61%

Estos valores se encuentran en línea con el nivel nominal esperado, lo que sugiere que las simulaciones posteriores reflejan de forma adecuada la variabilidad e incertidumbre presente en los datos observados. La alta cobertura observada refuerza la validez del modelo ajustado y su capacidad para realizar inferencias robustas.

La evaluación conjunta de los PPC y la cobertura empírica del 95% confirma que el modelo jerárquico bayesiano propuesto reproduce de manera precisa tanto la forma de las distribuciones como sus estadísticos fundamentales (media, máximo/mínimo) para las variables clave de intensidad ciclónica. Esta validación gráfica y cuantitativa sustenta la solidez del enfoque adoptado y justifica su aplicación en la estimación de probabilidades condicionales, predicción categórica y construcción de escenarios de riesgo en contextos hidrometeorológicos con alta incertidumbre.

3.6 Mapas de probabilidad condicional de intensidad ciclónica por estimación Beta-Binomial

Seguidamente se presenta la evolución espacio-temporal de la probabilidad condicional conjunta de que un ciclón tropical alcance una intensidad mayor o igual a Categoría 3, 4 o 5, de acuerdo con la escala Saffir-Simpson mediante mapas. Las probabilidades fueron estimadas mediante el enfoque bayesiano local (modelo Beta-Binomial conjugado), aplicadas individualmente a cada nodo geográfico dentro de una malla regular de 0.25° de resolución. Esta estrategia permitió capturar patrones regionales del riesgo extremo sin recurrir a modelos espacialmente complejos.

A. Probabilidad condicional de $CTs \geq$ Categoría 3

Durante el periodo 1950-1979, los valores más altos de probabilidad se concentraron principalmente en el sur del Golfo de México, el Caribe occidental y sectores próximos a la península de Yucatán, con una distribución dispersa y valores máximos por debajo del 7.2%.




Figura 43: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 3 (1950-1979)

En el periodo 1980-2009, se observa una expansión e intensificación del núcleo de riesgo, destacando zonas del Caribe central y occidental, incluyendo Cuba, Jamaica y el litoral de Honduras y Nicaragua, además de un aumento notorio hacia el este de Yucatán, con probabilidades que superan el 8.6%.

Finalmente, en 2010-2021, se evidencia un desplazamiento geográfico hacia el noreste, con los valores más altos localizados sobre el este del mar Caribe, el sureste de las Bahamas y zonas cercanas a Puerto Rico y República Dominicana. Este cambio sugiere una mayor propensión reciente a eventos intensos en regiones más orientales del dominio, posiblemente asociada a condiciones favorables del Atlántico abierto (e.j., temperatura superficial elevada, reducción del cizallamiento vertical).




Figura 44: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 3 (1980-2009)




Figura 45: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 3 (2010-2021)

B. Probabilidad condicional de CTs $\geq$ Categoría 4

Durante el periodo 1950-1979, las probabilidades de eventos $\geq$ Cat 4 fueron bajas y con distribución fragmentada, con valores máximos cercanos al 2.5%, localizados principalmente en el sur del Golfo de México, el este del mar Caribe y áreas adyacentes a Yucatán.

En 1980-2009, se observa un incremento en magnitud y extensión del riesgo. Sobresalen núcleos definidos sobre el Caribe occidental, el canal de Yucatán y las costas de Centroamérica, con probabilidades máximas cercanas al 3.9%, lo que refleja condiciones ambientales más propicias para el desarrollo de ciclones severos.

Para el periodo 2010-2021, el patrón muestra nuevamente un desplazamiento hacia el Atlántico occidental, con énfasis en el norte de las Antillas Mayores y el sureste de las Bahamas. Este cambio podría relacionarse con anomalías térmicas, alteraciones en la circulación oceánica y mayor persistencia de condiciones favorables para la intensificación rápida.




Figura 46: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 4 (1950-1979)




Figura 47: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 4 (1980-2009)




Figura 48: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 4 (2010-2021)

C. Probabilidad condicional de $CTs \geq$ Categoría 5

En el periodo 1950-1979, la probabilidad de $CTs \geq$ Cat 5 fue prácticamente nula en la mayoría del dominio, salvo por un foco reducido sobre el sur de Yucatán, donde se registraron valores cercanos al 0.22%. Este patrón indica una ocurrencia altamente esporádica de eventos extremos en esa etapa.

Durante 1980-2009, el riesgo aumentó considerablemente, con un núcleo claro sobre el Caribe occidental y el canal de Yucatán, alcanzando valores máximos en torno al 0.84%. Esta intensificación refleja una mayor frecuencia relativa de eventos de intensidad excepcional.

En 2010-2021, el campo de probabilidad se reconfigura de forma significativa: los valores más altos se localizan sobre el noreste del dominio, en el entorno de Bahamas, el Atlántico occidental y el norte de las Antillas Mayores, con un máximo estimado cercano al 0.25%. Este patrón coincide con la ocurrencia de eventos catastróficos recientes como Dorian (2019) y María (2017), y refuerza la hipótesis de un cambio en la localización preferente de los sistemas más destructivos.




Figura 49: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 5 (1950-1979)




Figura 50: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 5 (1980-2009)




Figura 51: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 5 (2010-2021)

Con el objetivo de evaluar los patrones de riesgo histórico y establecer una línea base para comparación con el periodo reciente (2010-2021), se estimó la probabilidad condicional conjunta de intensidad ciclónica para el intervalo consolidado 1950-2009, considerando igualmente los umbrales de Categoría 3, 4 y 5.

En el caso de $CTs \geq$ Categoría 3, los resultados revelan una amplia zona de riesgo moderado a alto a lo largo del Caribe occidental, el canal de Yucatán y el este del mar Caribe, con valores máximos cercanos al 7.4%. Este patrón representa una síntesis robusta de la propensión histórica a la intensificación ciclónica severa en gran parte del dominio.

Para $CTs \geq$ Categoría 4, la distribución espacial muestra un refuerzo del riesgo sobre el Caribe centro-occidental y las costas de Centroamérica, con concentraciones destacadas al sur de Cuba, noroeste de Jamaica y litoral de Belice-Honduras. Los valores alcanzan hasta 3%, lo que subraya la relevancia de estas zonas como corredores de paso frecuente de huracanes mayores.




Figura 52: Distribución espacial de la probabilidad condicional de $CTs \geq$ Categoría 3 (1950-2009)




Figura 53: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 4 (1950-2009)




Figura 54: Distribución espacial de la probabilidad condicional de CTs $\geq$ Categoría 5 (1950-2009)

Respecto a los eventos más extremos ($\geq$ Categoría 5), aunque las probabilidades son significativamente menores, se identifican núcleos locales de riesgo superior al 0.5%, especialmente en la región del Caribe occidental y canal de Yucatán. Estos valores, si bien bajos en términos absolutos, adquieren importancia dada la magnitud destructiva asociada a estos sistemas.

En conjunto, los mapas para 1950-2009 constituyen una referencia climatológica valiosa para establecer contrastes con el periodo reciente y evaluar posibles tendencias hacia el desplazamiento o intensificación del riesgo extremo en el contexto del cambio climático.

3.6.1 Validación espacial de las estimaciones anuales del modelo

La validación cuantitativa del modelo Beta-Binomial local se realizó utilizando exclusivamente el periodo 2010-2021 como conjunto de prueba, mientras que los datos correspondientes a 1950-2009 se destinaron al entrenamiento. Esta división temporal, que representa aproximadamente una proporción 80/20, permite evaluar la capacidad de generalización del modelo fuera del periodo de estimación, bajo un enfoque de validación cruzada temporal con sentido prospectivo.

El análisis se fundamentó en las estimaciones anuales de probabilidad condicional ($P_{CatXplus_ann}$) generadas por cada nodo geográfico, sin aplicar interpolaciones espaciales posteriores. Este enfoque busca garantizar que las métricas de desempeño reflejen fielmente las salidas puntuales del modelo, evitando distorsiones generadas por procesos de suavización cartográfica.

I. Capacidad discriminativa: curvas ROC

Las curvas ROC correspondientes a las tres categorías de intensidad ciclónica ($\geq$ Cat3, Cat4 y Cat5) evidencian una alta capacidad discriminativa del modelo para distinguir entre nodos con y sin ocurrencia de eventos extremos durante el periodo de validación.

En la Categoría $\geq$ Cat3, se observa una curva ROC próxima al vértice superior izquierdo, con un área bajo la curva (AUC) de 0.884, lo cual indica una relación robusta entre sensibilidad y especificidad. Para la Categoría $\geq$ Cat4, el desempeño mejora aún más, con un AUC de 0.968, reflejando un alto poder de clasificación incluso en eventos menos frecuentes. En la Categoría $\geq$ Cat5, el modelo alcanza un AUC prácticamente perfecto de 0.999, lo que sugiere una capacidad discriminativa sobresaliente. No obstante, esta

precisión podría estar influenciada por la concentración espacial de los pocos eventos observados.




Figura 55: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq \text{Cat3}$




Figura 56: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq \text{Cat4}$




Figura 57: Curva ROC del modelo Beta-Binomial local para el periodo 2010-2021 en la categoría $\geq \text{Cat5}$

II. Calidad probabilística: curvas de calibración




Figura 58: Curva de calibración del modelo para la categoría $\geq \text{Cat3}$




Figura 59: Curva de calibración del modelo para la categoría $\geq$ Cat4




Figura 60: Curva de calibración del modelo para las categorías $\geq$ Cat5

Las curvas de calibración permiten evaluar si las probabilidades estimadas por el modelo reflejan adecuadamente la frecuencia real observada de eventos.

- Para Cat3+, se observa una buena calibración general, con ligera subestimación en los deciles superiores.
- En Cat4+, el modelo mantiene un comportamiento aceptable, aunque la dispersión aumenta en los rangos altos de probabilidad, lo que podría deberse al menor número de eventos extremos.
- En Cat5+, la curva evidencia una subestimación marcada en los últimos deciles, atribuible a la baja frecuencia de eventos y a su alta concentración geográfica en el periodo de prueba.

Los resultados consolidados se presentan en la Tabla 15. El modelo demostró un comportamiento robusto en términos de precisión probabilística y cobertura espacial:

- La cobertura top 20% de los nodos con mayor probabilidad explicaron el 54.5% de los eventos Cat3+, el 68.8% de los eventos Cat4+ y el 100% de los Cat5+.
- Los valores de LIFT en ese mismo umbral fueron de 2.73, 3.44 y 5.00, respectivamente.
- El Brier score, indicador de calibración probabilística, fue más bajo para las categorías más intensas, con 0.76 (Cat3+), 0.52 (Cat4+) y 0.16 (Cat5+), lo que indica un mejor ajuste en los niveles superiores de riesgo.

Además, se realizó una validación cruzada espacial al aplicar las estimaciones del modelo calibrado con datos de 1950-2009 para predecir la ocurrencia de eventos entre 2010 y 2021. Esta prueba mostró una reducción en la cobertura espacial de eventos extremos: la cobertura top 20% cayó a 6.5% en Cat4+ y a 0.0% en Cat5+, lo que sugiere un posible desplazamiento reciente del patrón espacial de riesgo o simplemente la escasa frecuencia de eventos extremos en el periodo evaluado.

En conjunto, los resultados confirman la validez operativa del modelo Beta-Binomial local en su forma nodal original. La combinación de alta capacidad discriminativa, calibración adecuada y precisión espacial respalda su utilidad en contextos de gestión del riesgo. No obstante, se reconoce que la escasa ocurrencia de eventos extremos y su

distribución espacial concentrada pueden afectar algunas métricas. Por ello, se recomienda recalibrar el modelo periódicamente, incorporando nuevas temporadas ciclónicas e implementar análisis de sensibilidad espacial y temporal, que evalúen la robustez del modelo ante cambios en los patrones históricos.

Tabla 15: Métricas de validación espacial del modelo Beta-Binomial local para las estimaciones anuales de probabilidad condicional de intensificación ciclónica (2010–2021).

Métrica	Cat3+	Cat4+	Cat5+
Eventos observados	165	77	10
AUC	0.884	0.968	0.999
IC 95 % del AUC	0.878-0.891	0.965-0.971	0.999-0.999
Brier score	0.76	0.52	0.16
LIFT (top 20%)	2.73	3.44	5.00
Cobertura top 10%	38.2 %	45.5 %	90.0 %
Cobertura top 20%	54.5 %	68.8 %	100.0 %
Cobertura top 30%	70.9 %	81.8 %	100.0 %
Cobertura cross 20%	23.6 %	6.5 %	0.0 %

CONCLUSIONES

El estudio de los ciclones tropicales (CTs) es fundamental debido a su enorme impacto sobre las poblaciones costeras, la infraestructura crítica y los ecosistemas, especialmente en un contexto de cambio climático que incrementa su frecuencia e intensidad. Esta investigación se planteó responder a la siguiente pregunta: ¿es posible estimar de forma probabilística la intensidad de los CTs en el mar Caribe a partir de variables físicas observables como la velocidad del viento y la presión mínima central? Con base en los resultados obtenidos, la respuesta fue afirmativa. A través de un enfoque bayesiano jerárquico y espacial, se logró representar adecuadamente la intensidad de estos sistemas meteorológicos, incorporando tanto la incertidumbre estructural como la variabilidad física de los fenómenos.

La hipótesis formulada fue confirmada. El modelo jerárquico bayesiano propuesto alcanzó una capacidad predictiva superior al 85 %, generando estimaciones coherentes, calibradas y espacialmente diferenciadas para distintas categorías de intensidad ciclónica. Se cumplieron satisfactoriamente los criterios de validación ($\hat{R}$, ESS , PPC y cobertura), lo que respalda la solidez metodológica del enfoque adoptado.

En consecuencia, se cumplió el objetivo general de la tesis, al desarrollar un análisis bayesiano probabilístico para el pronóstico de la intensidad ciclónica en la región del mar Caribe ($15^{\circ} - 34^{\circ} N$, $65^{\circ} - 98^{\circ} O$), capaz de generar inferencias útiles para la evaluación del riesgo bajo escenarios de alta incertidumbre.

Respecto a los objetivos específicos:

- Se caracterizó la evolución histórica de los ciclones tropicales entre 1950 y 2021, identificando una intensificación progresiva en el periodo más reciente (2010-2021), tanto en frecuencia como en severidad.
- Se estimaron parámetros extremos robustos (μ , σ , ξ) mediante un enfoque bayesiano, obteniendo probabilidades conjuntas de intensidad conforme a la escala Saffir-Simpson, diferenciadas por periodo.
- El modelo jerárquico bayesiano ajustado en Stan mostró convergencia satisfactoria ($\hat{R} \approx 1$), cobertura adecuada ($\geq 95\%$) e inferencias coherentes

con los datos, reflejando un aumento en la intensidad extrema reciente, con mayor probabilidad de eventos $\geq$ *Categoría 3* y menores presiones mínimas.

- A través del modelo Beta-Binomial local se mapearon probabilidades condicionales anuales y acumuladas por nodo geográfico. Los mapas mostraron núcleos históricos de riesgo en el Caribe occidental y canal de Yucatán, así como desplazamientos recientes hacia el noreste (Bahamas y Antillas Mayores).
- La validación espacial para 2010-2021 demostró alta capacidad discriminativa ($AUC \geq 0.88$), buena calibración y cobertura efectiva de eventos extremos, confirmando la utilidad operativa del modelo en contextos reales de gestión del riesgo.

Este estudio aporta una herramienta metodológica para representar y comunicar el riesgo ciclónico de forma probabilística, integrando diversas técnicas (GEV, Bayes jerárquico, Beta-Binomial espacial) y facilitando su aplicación cartográfica para la planificación climática y la reducción del riesgo en el contexto del cambio climático.

RECOMENDACIONES

A partir de los resultados obtenidos en esta investigación, se proponen las siguientes recomendaciones para futuras investigaciones y aplicaciones prácticas en el ámbito del pronóstico probabilístico de ciclones tropicales:

- Ampliar la extensión temporal del último periodo (2010-2021) conforme se disponga de nuevas temporadas ciclónicas, con el fin de mejorar la solidez estadística de los estimadores bayesianos, especialmente en categorías extremas como Categoría 5, donde la baja frecuencia de eventos limita la precisión inferencial.
- Explorar modelos bayesianos espaciales explícitos, como los procesos gaussianos o modelos con efectos aleatorios espaciales, que permitan capturar dependencias entre nodos geográficos cercanos y mejorar la interpolación de riesgos sobre zonas con escasa información histórica.
- Integrar variables oceanográficas y atmosféricas adicionales, tales como temperatura superficial del mar, cizalladura vertical del viento o contenido calórico oceánico, como predictores dentro del marco bayesiano jerárquico, con el propósito de incrementar la capacidad predictiva del modelo.
- Recalibrar periódicamente los modelos con datos actualizados de intensidad ciclónica y eventos recientes, mediante enfoques de actualización bayesiana secuencial o modelos dinámicos adaptativos que ajusten las probabilidades a las condiciones cambiantes del sistema climático.
- Implementar el enfoque probabilístico desarrollado en sistemas de alerta temprana y plataformas operativas de gestión del riesgo, en colaboración con agencias hidrometeorológicas regionales, para que los productos generados (mapas y probabilidades) puedan ser utilizados como herramientas de apoyo a la toma de decisiones en tiempo real.
- Aplicar el marco metodológico en otras cuencas tropicales como el Pacífico mexicano con el fin de evaluar la generalización del enfoque bayesiano propuesto y adaptarlo a contextos climáticos y geográficos distintos.

REFERENCIAS BIBLIOGRÁFICAS

- Abdolali, A., van der Westhuisen, A., Ma, Z., Mehra, A., Roland, A., & Moghimi, S. (2021). Evaluating the accuracy and uncertainty of atmospheric and wave model hindcasts during severe events using model ensembles. *Ocean Dynamics*, 71(2), 217–235. <https://doi.org/10.1007/s10236-020-01426-9>
- Aiyyer, A. R., & Thorncroft, C. (2006). Climatology of Vertical Wind Shear over the Tropical Atlantic. *Journal of Climate*, 19(13), 2969–2983. <https://doi.org/10.1175/JCLI3685.1>
- Alaka, G. J., Sippel, J. A., Zhang, Z., Kim, H.-S., Marks, F. D., Tallapragada, V., Mehra, A., Zhang, X., Poyer, A., & Gopalakrishnan, S. G. (2024). Lifetime performance of the operational Hurricane Weather Research and Forecasting (HWRF) model for North Atlantic tropical cyclones. *Bulletin of the American Meteorological Society*. <https://doi.org/10.1175/BAMS-D-23-0139.1>
- Alatorre, J. E., Peres Núñez, W., Bárcena Ibarra, A., & Samaniego, J. (2020, junio 18). *La emergencia del cambio climático en América Latina y el Caribe: ¿Seguimos esperando la catástrofe o pasamos a la acción?* CEPAL. <https://www.cepal.org/es/publicaciones/45677-la-emergencia-cambio-climatico-america-latina-caribe-seguimos-esperando-la>
- Allan, R., Endfield, G., Damodaran, V., Adamson, G., Hannaford, M., Carroll, F., Macdonald, N., Groom, N., Jones, J., Williamson, F., Hendy, E., Holper, P., Arroyo-Mora, J. P., Hughes, L., Bickers, R., & Bliuc, A.-M. (2016). Toward integrated historical climate research: The example of Atmospheric Circulation Reconstructions over the Earth. *Wiley Interdisciplinary Reviews: Climate Change*, 7(2), 164–174. <https://doi.org/10.1002/wcc.379>
- Balaguru, K., Chang, C., Leung, L. R., Foltz, G. R., Hagos, S. M., Wehner, M. F., Kossin, J. P., Ting, M., & Xu, W. (2024). A global increase in nearshore tropical cyclone intensification. *Earth's Future*, 12(5). <https://doi.org/10.1029/2023EF004230>
- Barnard, G. A., & Bayes, T. (1958). Studies in the history of probability and statistics: IX. Thomas Bayes's *Essay towards solving a problem in the doctrine of chances*. *Biometrika*, 45(3–4), 293. <https://doi.org/10.2307/2333180>
- Bartoš, F., Otte, W. M., Gronau, Q. F., Timmers, B., Ly, A., & Wagenmakers, E.-J. (2023). *Empirical prior distributions for Bayesian meta-analyses of binary and time-to-event outcomes*. arXiv. <https://doi.org/10.48550/arXiv.2306.11468>
- Bayes, T. (1763). An essay towards solving a problem in the doctrine of chances. *Philosophical Transactions of the Royal Society of London*, 53, 370–418. <https://doi.org/10.1098/rstl.1763.0053>
- BBC Mundo. (2024, septiembre 20). *¿Qué es un huracán y cómo se forma?* <https://www.bbc.com/mundo/articles/cv20lqwxreyo>

- Bhatia, K., Baker, A., Yang, W., Vecchi, G., Knutson, T., Murakami, H., Kossin, J., Hodges, K., Dixon, K., Bronselaer, B., & Whitlock, C. (2022). A potential explanation for the global increase in tropical cyclone rapid intensification. *Nature Communications*, 13(1), 6626. <https://doi.org/10.1038/s41467-022-34321-6>
- Blake, E. S., Landsea, C. W., & Gibney, E. J. (2011, agosto). *The deadliest, costliest, and most intense United States tropical cyclones from 1851 to 2010 (and other frequently requested hurricane facts)* (NOAA Technical Memorandum NWS NHC-6). National Hurricane Center. <https://www.nhc.noaa.gov/pdf/nws-nhc-6.pdf>
- Boumis, G., Moftakhari, H. R., & Moradkhani, H. (2023). Storm surge hazard estimation along the US Gulf Coast: A Bayesian hierarchical approach. *Coastal Engineering*, 185, 104371. <https://doi.org/10.1016/j.coastaleng.2023.104371>
- Braun, S. A. (2010). Revaluating the role of the Saharan Air Layer in Atlantic tropical cyclogenesis and evolution. *Monthly Weather Review*, 138(6), 2007–2037. <https://doi.org/10.1175/2009MWR3135.1>
- Camargo, S. J., Sobel, A. H., Barnston, A. G., & Klotzbach, P. J. (2007). Tropical cyclone genesis potential index in climate models. *Tellus A: Dynamic Meteorology and Oceanography*, 59(4), 428–443. <https://doi.org/10.1111/j.1600-0870.2007.00238.x>
- Chang, C., Wang, C., & Minhas, F. (2025). Physics-Informed Learning for Tropical Cyclone Intensity Prediction. *IEEE Transactions on Geoscience and Remote Sensing*, 62, Article 10767593. <https://doi.org/10.1109/TGRS.2024.3506627>
- Chen, B.-F., Chen, B., Hsiao, C.-M., Teng, H.-F., Lee, C.-S., & Kuo, H.-C. (2024, 1 de febrero). *Climate trends of tropical cyclone intensity and energy extremes revealed by deep learning* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2402.00362>
- Chu, P.-S., & Zhao, X. (2007). A Bayesian regression approach for predicting seasonal tropical cyclone activity over the central North Pacific. *Journal of Climate*, 20(15), 4002–4013. <https://doi.org/10.1175/JCLI4214.1>
- Chu, P.-S., & Zhao, X. (2011). Bayesian analysis for extreme climatic events: A review. *Atmospheric Research*, 102(3), 243–262. <https://doi.org/10.1016/j.atmosres.2011.07.001>
- Camargo, S. J., & Wing, A. A. (2016). Tropical cyclones in climate models. *Wiley Interdisciplinary Reviews: Climate Change*, 7(2), 211–237. <https://doi.org/10.1002/wcc.373>
- Chavez-Demoulin, V., & Davison, A. C. (2005). Generalized additive modelling of sample extremes. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 54(1), 207–222. <https://doi.org/10.1111/j.1467-9876.2005.00479.x>
- Choulakian, V., & Stephens, M. A. (2001). Goodness-of-fit tests for the generalized Pareto distribution. *Technometrics*, 43(4), 478–484. <https://www.jstor.org/stable/1270819>

- Coles, S. G., & Tawn, J. A. (1996). A Bayesian analysis of extreme rainfall data. *Applied Statistics*, 45(4), 463–478. <https://doi.org/10.2307/2986068>
- Coles, S. (2001). An Introduction to Statistical Modeling of Extreme Values. *Springer*. <https://doi.org/10.1007/978-1-4471-3675-0>
- Conroy, A., Titley, H., Rivett, R., Feng, X., Methven, J., Hodges, K., Brammer, A., Burton, A., Chakraborty, P., Chen, G., Cowan, L., Dunion, J., & Sarkar, A. (2023). Track forecast: Operational capability and new techniques—Summary from the Tenth International Workshop on Tropical Cyclones (IWTC-10). *Tropical Cyclone Research and Review*, 12(1), 64–80. <https://doi.org/10.1016/j.tcrr.2023.05.002>
- Cummings, S. L. (2018). *Using Bayesian statistical post-processing techniques to improve tropical cyclone track and intensity forecasts* (Tesis de doctorado). Naval Postgraduate School. <http://hdl.handle.net/10945/59641>
- DeMaria, M., & Kaplan, J. (1994). A statistical hurricane intensity prediction scheme (SHIPS) for the Atlantic basin. *Weather and Forecasting*, 9(2), 209–220. [https://doi.org/10.1175/1520-0434\(1994\)009<0209:ASHIPS>2.0.CO;2](https://doi.org/10.1175/1520-0434(1994)009<0209:ASHIPS>2.0.CO;2)
- DeMaria, M., Franklin, J. L., Onderlinde, M. J., & Kaplan, J. (2021). Operational Forecasting of Tropical Cyclone Rapid Intensification at the National Hurricane Center. *Atmosphere*, 12(6), 683. <https://doi.org/10.3390/atmos12060683>
- Dietz, L., Arya, S., & Chatterjee, S. (2022). Predictions of damages from Atlantic tropical cyclones: A hierarchical Bayesian study on extremes. *arXiv*. <https://doi.org/10.48550/arXiv.2208.07899>
- Douglas, E. M., R. M. Vogel, and C. N. Kroll (2000), Trends in floods and low flows in the United States: Impact of spatial correlation, *J. Hydrol. Amsterdam*, 240, 90–105, doi:[10.1016/S0022-1694\(00\)00336-X](https://doi.org/10.1016/S0022-1694(00)00336-X).
- Dormady, N., Fasano, A., Roa-Henriquez, A., Flanagan, D., Welch, W., & Wood, D. (2021). Informational Determinants of Large-area Hurricane Evacuations. *Bulletin of the American Meteorological Society*, 103(3), 1–27. <https://doi.org/10.1175/BAMS-D-21-0008.1>
- Dunion, J. P., & Velden, C. S. (2004). The impact of the Saharan Air Layer on Atlantic tropical cyclone activity. *Bulletin of the American Meteorological Society*, 85(3), 353–366. <https://doi.org/10.1175/BAMS-85-3-353>
- Durden, S. L. (2013). Observed tropical cyclone eye thermal anomaly profiles extending above 300 hPa. *Monthly Weather Review*, 141(12), 4256–4268. <https://doi.org/10.1175/MWR-D-13-00021.1>
- Dvorak, V. F. (1984). *Tropical cyclone intensity analysis using satellite data* (NOAA Technical Report NESDIS 11). National Environmental Satellite, Data, and Information Service. <https://repository.library.noaa.gov/view/noaa/19322>

- Elsberry, R. L., Tsai, H.-C., & Jordan, M. S. (2014). Extended-range forecasts of Atlantic tropical cyclone events during 2012 using the ECMWF 32-day ensemble predictions. *Weather and Forecasting*, 29(2), 271–288. <https://doi.org/10.1175/WAF-D-13-00104.1>
- Emanuel, K. (2003). Tropical cyclones. *Annual Review of Earth and Planetary Sciences*, 31, 75–104. <https://doi.org/10.1146/annurev.earth.31.100901.141259>
- Emanuel, K. (2005). Increasing destructiveness of tropical cyclones over the past 30 years. *Nature*, 436(7051), 686–688. <https://doi.org/10.1038/nature03906>
- Emanuel, K. (2017). Will global warming make hurricane forecasting more difficult? *Bulletin of the American Meteorological Society*, 98(3), 495–501. <https://doi.org/10.1175/BAMS-D-16-0134.1>
- Emanuel, K. (2018). 100 years of progress in tropical cyclone research. *Meteorological Monographs*, 59, 15.1–15.68. <https://doi.org/10.1175/AMSMonographs-D-18-0016.1>
- European Centre for Medium-Range Weather Forecasts (ECMWF) (2024, 17 de junio). *Annual Report 2023*. <https://www.ecmwf.int/en/elibrary/81569-annual-report-2023>
- Eusebi, R., Vecchi, G. A., Lai, C.-Y., Tong, M. (2024). Realistic tropical cyclone wind and pressure fields can be reconstructed from sparse data using deep learning. *Communications Earth & Environment*, 5, Article 8. <https://www.nature.com/articles/s43247-023-01144-2>
- Fang, L., Wu, W., Wang, L., & Li, J. (2025). Nonstationary modeling of typhoon-induced wave heights using Gumbel distribution. **Ocean Engineering*, 296*, 110429. <https://doi.org/10.1016/j.oceaneng.2024.110429>
- Frank, W. M. (1977). The structure and energetics of the tropical cyclone I: Storm structure. *Monthly Weather Review*, 105(9), 1119–1135. [https://doi.org/10.1175/1520-0493\(1977\)105<1119:TSAEOT>2.0.CO;2](https://doi.org/10.1175/1520-0493(1977)105<1119:TSAEOT>2.0.CO;2)
- Frank, W. M., & Ritchie, E. A. (1999). Effects of environmental flow upon tropical cyclone structure. *Monthly Weather Review*, 127(9), 2044–2061. [https://doi.org/10.1175/1520-0493\(1999\)127<2044:EOEFUT>2.0.CO;2](https://doi.org/10.1175/1520-0493(1999)127<2044:EOEFUT>2.0.CO;2)
- Frank, W. M., & Ritchie, E. A. (2001). Effects of Vertical Wind Shear on Hurricane Intensity and Structure. *Monthly Weather Review*, vol. 129, pp. 2249–2269. https://journals.ametsoc.org/view/journals/mwre/129/9/1520-0493_2001_129_2249_eovwso_2.0.co_2.xml
- Garner, A. J. (2023). Observed increases in North Atlantic tropical cyclone peak intensification rates. *Scientific Reports*, 13(1), 16299. <https://doi.org/10.1038/s41598-023-42669-y>

- Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A., & Rubin, D. B. (2013). *Bayesian data analysis* (3.^a ed.). Chapman & Hall/CRC. <https://doi.org/10.1201/b16018>
- Gneiting, T., & Raftery, A. E. (2005). *Weather forecasting with ensemble methods. Science*, 310(5746), 248-249. <https://doi.org/10.1126/science.1115255>
- Gray, W. M. (1968). Global view of the origin of tropical disturbances and storms. *Monthly Weather Review*, 96(10), 669–700. [https://doi.org/10.1175/1520-0493\(1968\)096<0669:GVOTOO>2.0.CO;2](https://doi.org/10.1175/1520-0493(1968)096<0669:GVOTOO>2.0.CO;2)
- Grossmann-Matheson, G., Young, I. R., Meucci, A., & Alves, J.-H. (2024). Global tropical cyclone extreme wave height climatology. *Scientific Reports*, 14(1), 4167. <https://doi.org/10.1038/s41598-024-54691-9>
- Gutierrez-Lopez, A. (2022). Methodological guide to forensic hydrology. *Water*, 14(23), 3863. <https://doi.org/10.3390/w14233863>
- Gutierrez-Lopez, A., Muñoz Mandujano, M., Ibarra-Corona, M. A., & Vargas-Diaz, J. A. (2025). Using extreme frequency analysis to explain the impact of hurricanes Pauline (1997) and Otis (2023) on Acapulco, Mexico. *Meteorology Hydrology and Water Management*, 12(2), 74-83. <https://doi.org/10.26491/mhwm/205741>
- Heming, J. T. (2016). Tropical cyclone tracking and verification techniques for Met Office numerical weather prediction models. *Meteorological Applications*, 24(1), 1–8. <https://doi.org/10.1002/met.1599>
- Holland, G. J. (1980). An analytic model of the wind and pressure profiles in hurricanes. *Monthly Weather Review*, 108(8), 1212–1218. [https://doi.org/10.1175/1520-0493\(1980\)108<1212:AAMOTW>2.0.CO;2](https://doi.org/10.1175/1520-0493(1980)108<1212:AAMOTW>2.0.CO;2)
- Hon, K.-K. (2020). Tropical cyclone track prediction using a large-area WRF model at the Hong Kong Observatory. *Tropical Cyclone Research and Review*, 9(1), 67-74. <https://doi.org/10.1016/j.tcr.2020.03.002>
- Hosking, J. R. M., & Wallis, J. (1987). Parameter and quantile estimation for the generalized Pareto distribution. *Technometrics*, 29(3), 339-349. <https://doi.org/10.1080/00401706.1987.10488243>
- Houze, R. A. (2010). Clouds in tropical cyclones. *Monthly Weather Review*, 138(2), 293–344. <https://doi.org/10.1175/2009MWR2989.1>
- Huang, Y., Wang, C., Li, Y., & Zhang, Y. (2021). Bayesian hierarchical modeling for tropical cyclone intensity prediction. *Journal of Climate*, 34*(10), 3867–3883. <https://doi.org/10.1175/JCLI-D-20-0720.1>
- Hurricane Science. (s. f.). *Expendable Airborne Instruments*. University of Rhode Island. <https://www.hurricanescience.org/science/observation/aircraftrecon/expendableairborneinstruments>

- Instituto de Meteorología de Cuba (INSMET) (2019). *Generalidades de los ciclones tropicales*.
<http://www.insmet.cu/asp/genesis.asp?TB0=PLANTILLAS&TB1=OPTION&TB2=/contenidos/ciclones%20tropicales/generalidades/generalidades.htm%20>
- Intergovernmental Panel on Climate Change (IPCC). (2021). *Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change* (V. Masson-Delmotte et al., Eds.). Cambridge University Press. <https://www.ipcc.ch/report/ar6/wg1/>
- Intergovernmental Panel on Climate Change. (2023). *AR6 Synthesis Report: Climate Change 2023*. <https://www.ipcc.ch/report/ar6/syr/>
- Jensen, M. P., Flynn, J. H., Judd, L. M., Kollias, P., Kuang, C., McFarquhar, G., Nadkarni, R., Powers, H., & Sullivan, J. (2022). A succession of cloud, precipitation, aerosol, and air quality field experiments in the coastal urban environment. *Bulletin of the American Meteorological Society*, 103(2), 103–105. <https://doi.org/10.1175/BAMS-D-21-0104.1>
- Katz, R. W., Parlange, M. B., & Naveau, P. (2002). Statistics of extremes in hydrology. *Advances in Water Resources*, 25(8–12), 1287–1304. [https://doi.org/10.1016/S0309-1708\(02\)00056-8](https://doi.org/10.1016/S0309-1708(02)00056-8)
- Knaff, J. A., & Zehr, R. M. (2007). Reexamination of tropical cyclone pressure–wind relationships. *Weather and Forecasting*, 22(1), 71–88. <https://doi.org/10.1175/WAF965.1>
- Kaplan, J., & DeMaria, M. (2003). Large-scale characteristics of rapidly intensifying tropical cyclones in the North Atlantic Basin. *Weather and Forecasting*, 18(6), 1093–1108. [https://doi.org/10.1175/1520-0434\(2003\)018<1093:LCORIT>2.0.CO;2](https://doi.org/10.1175/1520-0434(2003)018<1093:LCORIT>2.0.CO;2)
- Kaplan, J., Rozoff, C. M., DeMaria, M., Sampson, C. R., Kossin, J. P., Velden, C. S., Cione, J. J., Dunion, J. P., Knaff, J. A., Zhang, J. A., Dostalek, J. F., Hawkins, J. D., Lee, T. F., & Solbrig, J. E. (2015). Evaluating environmental impacts on tropical cyclone rapid intensification predictability utilizing statistical models. *Weather and Forecasting*, 30(5), 1374–1396. <https://doi.org/10.1175/WAF-D-15-0032.1>
- Kapoor, A., Negi, A., Marshall, L. A., & Chandra, R. (2023). Cyclone trajectory and intensity prediction with uncertainty quantification using variational recurrent neural networks. *Environmental Modelling & Software*, 162, Article 105654. <https://doi.org/10.1016/j.envsoft.2023.105654>
- Klotzbach, P. J., Schreck, C. J., Compo, G. P., Wood, K. M., Bowen, E., & Bell, M. M. (2023). Influence of the Madden–Julian Oscillation on CONUS hurricane landfalls. *Geophysical Research Letters*, 50(7). <https://doi.org/10.1029/2023GL102762>
- Knapp, K. R., Kruk, M. C., Levinson, D. H., Diamond, H. J., & Neumann, C. J. (2010). The International Best Track Archive for Climate Stewardship (IBTrACS). *Bulletin*

- of the American Meteorological Society, 91(3), 363–376.
<https://doi.org/10.1175/2009BAMS2755.1>
- Knutson, T., Camargo, S. J., Chan, J. C. L., Emanuel, K., Ho, C.-H., Kossin, J., Mohapatra, M., Satoh, M., Sugi, M., Walsh, K., & Wu, L. (2020). Tropical cyclones and climate change assessment: Part II—Projected response to anthropogenic warming. *Bulletin of the American Meteorological Society*, 101(3), E303–E322.
<https://doi.org/10.1175/BAMS-D-18-0194.1>
- Koning, A. J., & Franses, P. H. (2005). Are precipitation levels getting higher? Statistical evidence for the Netherlands. *Journal of Climate*, 18(22), 4701–4714.
<https://doi.org/10.1175/JCLI3576.1>
- Kossin, J. P., Camargo, S. J., & Sitkowski, M. (2010). Climate Modulation of North Atlantic Hurricane Tracks. *Journal of Climate*, 23(11), 3057–3076.
<https://doi.org/10.1175/2010JCLI3497.1>
- Kossin, J. P., Knapp, K. R., Olander, T. L., & Velden, C. S. (2020). Global increase in major tropical cyclone exceedance probability over the past four decades. *Proceedings of the National Academy of Sciences*, 117(22), 11975–11980.
<https://doi.org/10.1073/pnas.1920849117>
- Koutsoyiannis, D. (2004). Statistics of extremes and estimation of extreme rainfall: I. Theoretical investigation. *Hydrological Sciences Journal*, 49(4), 575–590.
<https://doi.org/10.1623/hysj.49.4.575.54430>
- Krichene, H., Vogt, T., Piontek, F., Geiger, T., Schötz, C., & Otto, C. (2023). The social costs of tropical cyclones. *Nature Communications*, 14(1), 7294.
<https://doi.org/10.1038/s41467-023-43114-4>
- Kumar, S., Biswas, K., & Pandey, A. K. (2021). Prediction of Landfall Intensity, Location, and Time of a Tropical Cyclone. *arXiv*. <https://arxiv.org/abs/2103.16180>
- Landsea, C. W., Anderson, C., Charles, N., Clark, G., Dunion, J., Fernandez-Partagas, J., Hungerford, P., Neumann, C., & Zimmer, M. (2004). The Atlantic Hurricane Database Re-Analysis Project: Documentation for the 1851–1910 alterations and additions to the HURDAT database. En R. J. Murnane & K.-B. Liu (Eds.), *Hurricanes and typhoons: Past, present and future* (pp. 177–221). Columbia University Press.
- Landsea, C. W., & Franklin, J. L. (2013). Atlantic hurricane database uncertainty and presentation of a new database format. *Monthly Weather Review*, 141(10), 3576–3592. <https://doi.org/10.1175/MWR-D-12-00254.1>
- Leadbetter, M. R., Lindgren, G., & Rootzén, H. (1983). Extremes and Related Properties of Random Sequences and Processes. *Springer*. <https://doi.org/10.1007/978-1-4612-5449-2>
- Li, M. K., Zhang, S., Wu, L., Lin, X., Chang, P., Danabasoglu, G., Wei, Z., Yu, X., Hu, H., Ma, X., Ma, W., Zhao, H., Jia, D., Liu, X., Mao, K., Jiang, Y., Wang, X., Liu, G.,

- & Chen, Y. (2020). An examination of the predictability of tropical cyclone genesis in high-resolution coupled models with dynamically downscaled coupled data assimilation initialization. *Advances in Atmospheric Sciences*, 37(9), 939–950. <https://doi.org/10.1007/s00376-020-9220-9>
- Lin, Y., Chen, H., & Wu, J. (2022). Application of the regional spectral model in tropical cyclone prediction. *Journal of the Atmospheric Sciences*, 79(4), 899–914. <https://doi.org/10.1175/JAS-D-21-0105.1>
- Liou, Y.-A., & Le, T.-V. (2024). Comparative analysis of machine learning models for tropical cyclone intensity estimation. *Remote Sensing*, 16(17), 3138. <https://doi.org/10.3390/rs16173138>
- Liu, L., Lin, Y.-L., & Chen, S.-H. (2016). *Effects of landfall location and approach angle of an idealized tropical cyclone over a long mountain range*. *Frontiers in Earth Science*, 4, art. 14. <https://doi.org/10.3389/feart.2016.00014>
- Liu, Y., McPhaden, M. J., Cai, W., Zhang, Y., Zhao, J., Nnamchi, H. C., Lin, X., Li, Z., & Yang, J.-C. (2025). Basin-wide and coastal modes of North Tropical Atlantic variability have distinct impacts on hurricanes. *Communications Earth & Environment*, 6(1). <https://doi.org/10.1038/s43247-025-02529-1>
- Lonfat, M., Marks, F. D., Jr., & Chen, S. S. (2004). Precipitation distribution in tropical cyclones using the TRMM Microwave Imager: A global perspective. *Monthly Weather Review*, 132(7), 1645–1660. [https://doi.org/10.1175/1520-0493\(2004\)132<1645:PDITCU>2.0.CO;2](https://doi.org/10.1175/1520-0493(2004)132<1645:PDITCU>2.0.CO;2)
- Loridan, T., & Bruneau, N. (2025). Reask UTC: a machine learning modeling framework to generate climate-connected tropical cyclone event sets globally. *Natural Hazards and Earth System Sciences*, 25(8), 2863–2884. <https://doi.org/10.5194/nhess-25-2863-2025>
- Luettgau, L., Coppock, H., Dubois, M., Summerfield, C., & Ududec, C. (2025, mayo 8). *HiBayES: A hierarchical Bayesian modeling framework for AI evaluation statistics* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2505.05602>
- Magnusson, L., Bidlot, J.-R., Lang, S. T. K., Thorpe, A., Wedi, N., & Yamaguchi, M. (2014). Evaluation of medium-range forecasts for Hurricane Sandy. *Monthly Weather Review*, 142(5), 1962–1981. <https://doi.org/10.1175/MWR-D-13-00228.1>
- Magnusson, L., Doyle, J. D., Komaromi, W. A., Torn, R. D., Tang, C. K., Chan, J. C. L., Yamaguchi, M., & Zhang, F. (2019). Advances in understanding difficult cases of tropical cyclone track forecasts. *Tropical Cyclone Research and Review*, 8(3), 109–122. <https://doi.org/10.1016/j.tcrr.2019.10.001>
- Majumdar, S. J., & Torn, R. D. (2014). Probabilistic Verification of Global and Mesoscale Ensemble Forecasts of Tropical Cyclogenesis. *Weather and Forecasting*, 29(5), 1181–1198. <https://doi.org/10.1175/WAF-D-14-00028.1>

- Majumdar, S. J., Nebylitsa, S., Klotzbach, P. J., Masiello, C., & Michael, Z. R. (2023). North Atlantic tropical cyclone intensification: Regional drivers and trends. *Geophysical Research Letters*, 50, e2023GL104803. <https://doi.org/10.1029/2023GL104803>
- Martins, E. S., & Stedinger, J. R. (2000). Generalized maximum-likelihood generalized extreme-value quantile estimators for hydrologic data. *Water Resources Research*, 36(3), 737–744. <https://doi.org/10.1029/1999WR900330>
- Matear, R. J., & Reddy, P. J. (2025). A machine learning tool for determining the required sample size for GEV fitting in climate applications. *Geophysical Research Letters*, 52, e2024GL112737. <https://doi.org/10.1029/2024GL112737>
- McElreath, R. (2020). Statistical Rethinking: A Bayesian Course with Examples in R and Stan (2nd ed.). CRC Press. <https://doi.org/10.1201/9780429029608>
- Meissner, T., Ricciardulli, L., & Wentz, F. J. (2017). Capability of the SMAP mission to measure ocean surface winds in storms. *Bulletin of the American Meteorological Society*, 98(8), 1660–1677. <https://doi.org/10.1175/BAMS-D-16-0052.1>
- Méndez-Tejeda, R., & Hernández-Ayala, J. J. (2023). Links between climate change and hurricanes in the North Atlantic. *PLOS Climate*, 2(4), e0000186. <https://doi.org/10.1371/journal.pclm.0000186>
- Meza Padilla, J. R., Appendini, C. M., Pedrozo Acuña, A., González Villareal, F. J., & Ortiz Pérez, M. A. (2015). Oleaje y marea de tormenta inducidos por ciclones tropicales en mares mexicanos [Tesis de maestría, Universidad Nacional Autónoma de México]. Repositorio UNAM. <https://repositorio.unam.mx/contenidos/ficha/estimacion-de-marea-de-tormenta-y-oleaje-inducidos-por-ciclones-tropicales-en-mares-mexicanos-86064>
- Met Office. (2023). *Tropical cyclone verification northern hemisphere 2023*. Met Office. <https://www.metoffice.gov.uk/research/weather/tropical-cyclones/verification/summaries/nhem2023>
- Misra, V., & Jayasankar, C. B. (2022, 7 de enero). A high resolution coupled ocean-atmosphere simulation of the regional climate over Central America. *Research Square*. <https://doi.org/10.21203/rs.3.rs-595895/v1>
- Molina-Aguilar, J. P., Gutierrez-Lopez, A., Raynal-Villaseñor, J. A., & Garcia-Valenzuela, L. G. (2019). Optimization of parameters in the generalized extreme-value distribution type 1 for three populations using harmonic search. *Atmosphere*, 10(5), 257. <https://doi.org/10.3390/atmos10050257>
- 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>
- Munsell, E. B., Braun, S. A., & Zhang, F. (2021). GOES-16 Observations of Rapidly-Intensifying Tropical Cyclones: Hurricanes Harvey (2017), Maria (2017),

- And Michael (2018). *Monthly Weather Review*, 149(6). <https://doi.org/10.1175/MWR-D-19-0298.1>
- Murakami, H., Delworth, T. L., Johnson, N. C., Lu, F., McHugh, C. E., & Jia, L. (2025). Seasonal forecasts of tropical cyclones using GFDL SPEAR and HiFLOR-S. *Journal of Climate*, 38(9), 2015-2030. <https://doi.org/10.1175/JCLI-D-24-0356.1>
- NASA / GPM. (2020, 11 de agosto). *Hurricane Isaias Impacts the US East Coast*. GPM Applications. <https://gpm.nasa.gov/applications/weather/hurricane-isaias-impacts-us-east-coast>
- Naseef, T. M., & Sanil Kumar, V. (2020). Climatology and trends of the Indian Ocean surface waves based on 39-year long ERA5 reanalysis data. *International Journal of Climatology*, 40(2), 979-1006. <https://doi.org/10.1002/joc.6251>
- Nath, S., Kotal, S. D., & Kundu, P. K. (2015). Application of fuzzy clustering technique for analysis of North Indian Ocean tropical cyclone tracks. *Tropical Cyclone Research and Review*, 4(3), 110–123. <https://doi.org/10.6057/2015TCRRh3.02>
- National Centers for Environmental Prediction & National Centers for Environmental Information. (2020, 12 de agosto). *Global Forecast System (GFS)*. NOAA. <https://www.ncei.noaa.gov/products/weather-climate-models/global-forecast>
- National Centers for Environmental Information. (s. f.). *North American Mesoscale (NAM) Forecast System*. National Oceanic and Atmospheric Administration (NOAA). <https://www.ncei.noaa.gov/products/weather-climate-models/north-american-mesoscale>
- National Hurricane Center. (2012). *Saffir–Simpson Hurricane Wind Scale*. NOAA. <https://www.nhc.noaa.gov/aboutsshws.php>
- National Hurricane Center. (2017, June 18). *Potential Tropical Cyclone Two – Advisory 1A, 8 PM AST* [Gráfico de cono de incertidumbre]. NOAA National Weather Service. <https://www.nhc.noaa.gov>
- National Hurricane Center. (2023). *The Cone of Uncertainty*. <https://www.nhc.noaa.gov/aboutcone.shtml>
- National Hurricane Center. (s.f.-a). *Hurricane Preparedness – Hazards*. NOAA. <https://www.nhc.noaa.gov/prepare/hazards.php>
- National Hurricane Center. (s.f.-b). *Tropical Cyclone Climatology*. NOAA. <https://www.nhc.noaa.gov/climo/>
- National Oceanic and Atmospheric Administration. (s. f.). *Global tropical cyclone formation zones*. NOAA. <https://www.nhc.noaa.gov/climo/>
- Nishimura, M., & Yamaguchi, M. (2015). Selective ensemble mean technique for tropical cyclone track forecasts using multi-model ensembles. *Tropical Cyclone Research and Review*, 4(2), 71–78. <https://doi.org/10.6057/2015TCRR02.03>

- NOAA Hurricane Research Division. (2023). *Saffir–Simpson Hurricane Wind Scale*. National Oceanic and Atmospheric Administration. <https://www.aoml.noaa.gov/hrd/tcfaq/tcfaqD.html#D4>
- NOAA. (2023). *A look back with hurricane researcher Dr. Sim Aberson*. NOAA Heritage. <https://www.noaa.gov/heritage/stories/look-back-with-hurricane-researcher-dr-sim-aberson>
- Nordhaus, W. D. (2010). The economics of hurricanes and implications of global warming. *Climate Change Economics*, 1(1), 1–20. <https://doi.org/10.2307/climchanecon.1.1.1>
- Ogata, T., Mizuta, R., Adachi, Y., Murakami, H., & Ose, T. (2016). Atmosphere-ocean coupling effect on intense tropical cyclone distribution and its future change with 60 km-AOGCM. *Scientific Reports*, 6, Article 29800. <https://doi.org/10.1038/srep29800>
- O’Grady, J. G., Stephenson, A. G., & McInnes, K. L. (2022). Gauging mixed climate extreme value distributions in tropical cyclone regions. *Scientific Reports*, 12, Article 4626. <https://doi.org/10.1038/s41598-022-08382-y>
- Otto, M., & Castelo, R. (2025). *Modeling bounded count environmental data using a contaminated beta-binomial regression model*. Preprint. <https://doi.org/10.48550/arXiv.2504.13665>
- Ouyang, L., Zhu, S., Ye, K., Park, C., & Wang, M. (2021). Robust Bayesian hierarchical modeling and inference using scale mixtures of normal distributions. *IJSE Transactions*, 1–13. <https://doi.org/10.1080/24725854.2021.1912440>
- Payez, A., Stoffelen, A., de Valk, C., & Giesen, R. (2025, mayo 13). *An extreme value method to study decadal hurricane wind trends* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2505.08591>
- Peduzzi, P., Dao, H., Herold, C., & Mouton, F. (2009). Assessing global exposure and vulnerability towards natural hazards: The Disaster Risk Index. *Natural Hazards and Earth System Science*, 9(4), 1149–1159. <https://doi.org/10.5194/nhess-9-1149-2009>
- Pielke, R. A., Gratz, J., Landsea, C. W., Collins, D., Saunders, M., & Musulin, R. (2008). Normalized hurricane damage in the United States: 1900–2005. *Natural Hazards Review*, 9(1), 29–42. [https://doi.org/10.1061/\(ASCE\)1527-6988\(2008\)9:1\(29\)](https://doi.org/10.1061/(ASCE)1527-6988(2008)9:1(29))
- Ragab, M. (2025). Tropical cyclone intensity prediction using Bayesian machine learning with marine predators algorithm on satellite cloud imagery. *Ain Shams Engineering Journal*, 16(3), 103316. <https://doi.org/10.1016/j.asej.2025.103316>
- Rappaport, E. N., Franklin, J. L., Avila, L. A., Baig, S. R., Beven, J. L., Blake, E. S., Burr, C. A., Jiing, J.-G., Juckins, C. A., Knabb, R. D., Landsea, C. W., Mainelli, M., Mayfield, M., McAdie, C. J., Pasch, R. J., Sisko, C., Stewart, S. R., & Tribble, A. N. (2009). Advances and challenges at the National Hurricane Center. *Weather and Forecasting*, 24(2), 395–419. <https://doi.org/10.1175/2008WAF2222128.1>

- Rappaport, E. N. (2014). Fatalities in the United States from Atlantic tropical cyclones: New data and interpretation. *Bulletin of the American Meteorological Society*, 95(3), 341–346. <https://doi.org/10.1175/BAMS-D-12-00074.1>
- Ren, D., Lynch, M., Leslie, L. M., & LeMarshall, J. (2014). Sensitivity of Tropical Cyclone Tracks and Intensity to Ocean Surface Temperature: Four Cases in Four Different Basins. *Tellus A: Dynamic Meteorology and Oceanography*, 66(1), Article 24212. <https://doi.org/10.3402/tellusa.v66.24212>
- Renard, B., Lang, M., Bois, P., Dupeyrat, A., Mestre, O., Niel, H., Sauquet, E., Prudhomme, C., Parey, S., Paquet, E., Neppel, L., & Gailhard, J. (2008). Regional methods for trend detection: Assessing field significance and regional consistency for hydrological extremes. *Water Resources Research*, 44(8), W08419. <https://doi.org/10.1029/2007WR006268>
- Rendón-Macías, M. E., Riojas-Garza, A., Contreras-Estrada, D., & Martínez-Ezquerro, J. D. (2018). Análisis bayesiano: Conceptos básicos y prácticos para su interpretación y uso. *Revista Alergia México*, 65(3), 285–298. <https://doi.org/10.29262/ram.v65i3.512>
- Rogers, R. F., Reasor, P. D., & Lorsolo, S. (2013). Airborne Doppler observations of the inner-core structural differences between intensifying and steady-state tropical cyclones. *Journal of the Atmospheric Sciences*, 70(3), 626–643. <https://doi.org/10.1175/JAS-D-12-018.1>
- Rydén, J. (2024). Improving confidence intervals for extreme wave return levels with ACER. *JMSE*, 5(1), 8. <https://doi.org/10.3390/jmse5010008>
- Sánchez Rivera, G., Frausto Martínez, O., Cervantes Martínez, A., Gómez Mendoza, L., & Terán Cuevas, Á. R. (2021). Análisis histórico (1851–2019) de huracanes extremos en Quintana Roo, México. En R. Álvarez & M. González (Eds.), *Fenómenos hidrometeorológicos en sistemas socioecológicos de México* (pp. 245–272). Universidad de Quintana Roo / ECOSUR. <https://es.scribd.com/document/526040993/Sanchez-Rivera-Etal-2021-Capitulo-XII-Analisis-Historico-1851-2019-de-Huracanes-Extremos-en-QRoo-1>
- Sato, K., Inoue, J., & Yamazaki, A. (2020). Performance of Forecasts of Hurricanes with and without Upper-Level Troughs over the Mid-Latitudes. *Atmosphere*, 11(7), Article 702. <https://doi.org/10.3390/atmos11070702>
- Studholme, J., et al. (2015). Objective determination of the extratropical transition of tropical cyclones. *Tellus A: Dynamic Meteorology and Oceanography*, 67, 24474. <https://doi.org/10.3402/tellusa.v67.24474>
- Skamarock, W. C., Klemp, J. B., Dudhia, J., Gill, D. O., Liu, Z., Berner, J., Wang, W., Powers, J. G., Duda, M. G., Barker, D. M., & Huang, X.-Y. (2019). A description of the Advanced Research WRF Version 4 (NCAR Technical Note NCAR/TN-556+STR). <https://doi.org/10.5065/1dfh-6p97>

- Song, X., Zhu, Y., Peng, J., & Guan, H. (2018). Improving multi-model ensemble forecasts of tropical cyclone intensity using Bayesian model averaging. *Journal of Meteorological Research*, 32(5), 794–803. <https://doi.org/10.1007/s13351-018-7117-7>
- Stephens, M. A. (1976). Asymptotic results for goodness-of-fit statistics with unknown parameters. *The Annals of Statistics*, 4(2), 357–369. <https://doi.org/10.1214/aos/1176343411>
- Stern, D. P., Bryan, G. H., Lee, C. Y., & Doyle, J. D. (2021). Estimating the risk of extreme wind gusts in tropical cyclones using idealized large-eddy simulations and a statistical-dynamical model. *Monthly Weather Review*, 149(12), 4183–4204. <https://doi.org/10.1175/MWR-D-21-0059.1>
- Strobl, E. (2012). The economic growth impact of natural disasters in developing countries: Evidence from hurricane strikes in the Central American and Caribbean regions. *Journal of Development Economics*, 97(1), 130–141. <https://doi.org/10.1016/j.jdeveco.2010.12.002>
- Tallapragada, V. (2016). “Overview of the NOAA/NCEP operational hurricane weather research and forecast (HWRF) modelling system,” in *Advanced numerical modeling and data assimilation techniques for tropical cyclone prediction*. Editors U. C. Mohanty, and S. G. Gopalakrishnan (Dordrecht: Springer). [doi:10.5822/978-94-024-0896-6_3](https://doi.org/10.5822/978-94-024-0896-6_3)
- Tang, B., & Emanuel, K. (2012). A ventilation index for tropical cyclones. *Bulletin of the American Meteorological Society*, 93(12), 1901–1912. <https://doi.org/10.1175/BAMS-D-11-00165.1>
- Tang, C. K., Chan, J. C. L., & Yamaguchi, M. (2021). Large tropical cyclone track forecast errors of global numerical weather prediction models in the western North Pacific basin. *Tropical Cyclone Research and Review*, 10(3), 151–169. <https://doi.org/10.1016/j.tcr.2021.07.001>
- Trenberth, K. E., Davis, C. A., & Fasullo, J. (2007). Water and energy budgets of hurricanes: Case studies of Ivan and Katrina. *Journal of Geophysical Research*, 112(D23). <https://doi.org/10.1029/2006JD008303>
- Trošelj, J., & Lee, H. S. (2021). Modelling typhoon-induced extreme river discharges: A case study of Typhoon Hagibis in Japan. *Journal of Hydrology: Regional Studies*, 34, 100776. <https://doi.org/10.1016/j.ejrh.2021.100776>
- UCAR / NCAR. (s. f.). *AVAPS History: Airborne Vertical Atmospheric Profiling System*. Earth Observing Laboratory. <https://www.eol.ucar.edu/content/avaps-history>
- USAF / 403rd Wing. (s. f.). *Hurricane Hunter Weather Equipment*. United States Air Force. <https://www.403wg.afrc.af.mil/About/Fact-Sheets/Display/Article/192532/hurricane-hunter-weather-equipment>

- United Nations Office for Disaster Risk Reduction (UNDRR). (2021). *Global Assessment Report on Disaster Risk Reduction (GAR)*. <https://www.undrr.org/gar>
- Valderá, N., González, C., & Pérez, R. (2021). Variabilidad de la actividad ciclónica tropical en el océano Atlántico, golfo de México, mar Caribe y Cuba. *Revista Cubana de Meteorología*, 27(4). <http://rcm.insmet.cu/index.php/rcm/article/view/589>
- Vecchi, G. A., & Soden, B. J. (2007). Increased tropical Atlantic wind shear in model projections of global warming. *Geophysical Research Letters*, 34(8). <https://doi.org/10.1029/2006GL028905>
- Vehtari, A., Gelman, A., Simpson, D., Carpenter, B., & Bürkner, P.-C. (2021). Rank-normalization, folding, and localization: An improved $\hat{R}$ for assessing convergence of MCMC (with discussion). *Bayesian Analysis*, 16(2), 667–718. <https://doi.org/10.1214/20-BA1221>
- Velden, C. S., et al. (2006). *The Dvorak tropical cyclone intensity estimation technique: A satellite-based method that has endured for over 30 years*. Bulletin of the American Meteorological Society, 87(9), 1195–1210. <https://doi.org/10.1175/BAMS-87-9-1195>
- Venema, V. K. C., Mestre, O., Aguilar, E., Auer, I., Guijarro, J., Domonkos, P., ... & Winkler, W. (2012). Benchmarking homogenization algorithms for monthly data. *Climate of the Past*, 8(1), 89–115. <https://doi.org/10.5194/cp-8-89-2012>
- Wada, R., Rohmer, J., Krien, Y., & Jonathan, P. (2022). Statistical estimation of spatial wave extremes for tropical cyclones from small data samples: Validation of the STM-E approach using long-term synthetic cyclone data for the Caribbean Sea. *Natural Hazards and Earth System Sciences*, 22, 431–444. <https://doi.org/10.5194/nhess-22-431-2022>
- Walsh, S. A., Ferreira, M. A. R., Higdon, D., & Zick, S. (2022). A Bayesian hierarchical model framework to quantify uncertainty of tropical cyclone precipitation forecasts. *arXiv*. <https://doi.org/10.48550/arXiv.2210.16683>
- Wang, C., Wang, X., Weisberg, R. H., & Black, M. L. (2017). Variability of tropical cyclone rapid intensification in the North Atlantic and its relationship with climate variations. *Climate Dynamics*, 49(11–12), 3627–3645. <https://doi.org/10.1007/s00382-017-3537-9>
- Wang, G., Wu, L., Mei, W. et al. (2022). Ocean currents show global intensification of weak tropical cyclones. *Nature* 611, 496–500. <https://doi.org/10.1038/s41586-022-05326-4>
- Wang, X., Quan, M., & Fan, K. (2025). *Effects of El Niño–Southern Oscillation dissipation phases on tropical cyclone activity over the North Atlantic*. *Ocean-Land-Atmosphere Research*, 4. <https://doi.org/10.34133/olar.0082>
- Weiss, R. E. (2010). Bayesian methods for data analysis. *American Journal of Ophthalmology*, 149(2), 187–188.e1. <https://doi.org/10.1016/j.ajo.2009.11.011>

- Wendt, T. (2017). *A hierarchical multivariate Bayesian approach to Ensemble Model Output Statistics in atmospheric prediction* (Tesis de doctorado). Naval Postgraduate School. <https://apps.dtic.mil/sti/trecms/pdf/AD1046945.pdf>
- Wielicki, B. A., Young, D. F., Mlynczak, M. G., Thome, K. J., Leroy, S., Corliss, J., Anderson, J. G., Ao, C. O., Bantges, R., Best, F., Bowman, K., Brindley, H., Butler, J. J., Collins, W., Dykema, J. A., Doelling, D. R., Feldman, D. R., Fox, N., Huang, X., & Holz, R. (2013). Achieving climate change absolute accuracy in orbit. *Bulletin of the American Meteorological Society*, 94(10), 1519–1539. <https://doi.org/10.1175/BAMS-D-12-00149.1>
- World Meteorological Organization, Commission for Climatology. (1967). *A note on climatological normals: Report of a working group of the Commission for Climatology* (Technical Note No. 84; WMO-No. 208). Ginebra, Suiza: WMO. https://library.wmo.int/viewer/58649/download?file=wmo_208.pdf&type=pdf
- World Meteorological Organization. (2015, 12 de noviembre). *Communicating forecast uncertainty for service providers*. WMO. <https://wmo.int/media/magazine-article/communicating-forecast-uncertainty-service-providers>
- World Meteorological Organization. (2020). *WMO guidelines on tropical cyclone forecasting and warning*. WMO-No. 1194. https://library.wmo.int/doc_num.php?explnum_id=10446
- World Meteorological Organization. (2020). *Climate data homogenization*. WMO. Recuperado de <https://community.wmo.int/en/climate-data-homogenization>
- World Meteorological Organization. (2022). *A primer on public policy and management with a focus on national meteorological and hydrological services* (WMO-No. 1289). <https://library.wmo.int/viewer/58042/>
- World Meteorological Organization. (2024, 8 de mayo). *State of the climate in Latin America and the Caribbean 2023* (Reporte No. WMO-1351). Ginebra: WMO. https://library.wmo.int/doc_num.php?explnum_id=12077
- World Meteorological Organization. (s. f.). *Regional Association IV—Hurricane Operational Plan for North America, Central America and the Caribbean: Tropical Cyclone Programme* (WMO-No. 1163). https://library.wmo.int/viewer/48739/download?file=RAIV-TC-30_HC-44_WMO-1163_en.pdf&type=pdf&navigator=1
- Wu, S., & Chandra, V. (2025). Quantifying SST influence on tropical cyclone intensity using machine learning. *arXiv*. <https://arxiv.org/abs/2506.09254>
- Wu, T., & Duan, Z. (2023). A new and efficient method for tropical cyclone detection and tracking in gridded datasets. *Weather and Climate Extremes*, 100626. <https://doi.org/10.1016/j.wace.2023.100626>

- Yang, C., & Xu, J. (2024). Tropical cyclone wind field reconstruction for hazard estimation via Bayesian hierarchical modeling with neural network. *Earth and Space Science*, 11(12). <https://doi.org/10.1029/2024EA003678>
- Zhang, X. (2025). Characteristics and representation of subgrid convective processes. *Journal of Advances in Modeling the Earth System*. <https://doi.org/10.1029/2024MS004558>
- Zhang, J., Li, Q., Wu, L., Qian, Q., Ge, X., Kwong, S. T. W., Zhang, Y., Lyu, X., Zhou, G., Nie, G., Chan, P. W., Wong, W. K., & Zhu, L. (2025). *Influence of inner-core symmetry on tropical cyclone rapid intensification and its forecasting by a machine learning ensemble model*. *Weather and Climate Extremes*, 48, Article 100770. <https://doi.org/10.1016/j.wace.2025.100770>
- Zhou, G., Gao, S., Liu, L., & Huang, B. (2023). Application of high-level environmental field factor in TC's sudden recurvature process. *Tropical Cyclone Research and Review*, 11(4), 244-251. <https://doi.org/10.1016/j.tcrr.2023.02.003>
- Zhu, G., Li, Q., Zhao, W., Lv, X., Qian, C., & Qian, Q. (2022). Tropical Cyclones Intensity Prediction in the Western North Pacific Using Gradient Boosted Regression Tree Model. *Frontiers in Earth Science*, 10, 929115. <https://doi.org/10.3389/feart.2022.929115>

ANEXOS

Anexo A. Mapas de probabilidad condicional acumulada por categoría y periodo

Este anexo presenta los mapas de probabilidad condicional acumulada ($P_{CatXplus_acum}$) estimados para las categorías de intensidad ciclónica Cat3+, Cat4+ y Cat5+ en los tres periodos históricos analizados: 1950-1979, 1980-2009 y 2010-2021. Estas probabilidades representan la frecuencia integrada con la que un ciclón tropical alcanzó, al menos una vez dentro del intervalo temporal correspondiente, la categoría especificada, de acuerdo con las estimaciones obtenidas mediante el modelo Beta-Binomial local.

Los mapas fueron generados a partir de una malla geoespacial regular con resolución de 0.25° , definida en coordenadas geográficas (WGS84). Las probabilidades estimadas por nodo fueron interpoladas mediante el método de ponderación por distancia inversa (Inverse Distance Weighting, IDW), generando superficies raster de mayor resolución espacial. Para la representación cartográfica se aplicó remuestreo bilineal, con el fin de suavizar la visualización sin alterar el significado estadístico de las estimaciones probabilísticas originales.




Figura 61: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (1950-1979)




Figura 62: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (1980-2009)




Figura 63: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 3 (2010-2021)




Figura 64: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (1950-1979)




Figura 65: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (1980-2009)




Figura 66: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 4 (2010-2021)




Figura 67: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (1950-1979)




Figura 68: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (1980-2009)




Figura 69: Distribución espacial de la probabilidad condicional acumulada de CTs $\geq$ Categoría 5 (2010-2021)

Anexo B. Intervalos de credibilidad de estimaciones anuales

En este anexo se presentan los intervalos de credibilidad al 95% asociados a las probabilidades anuales de intensidad ($P_{CatXplus_l_ann}$, $P_{CatXplus_u_ann}$), calculadas para las categorías Cat3+, Cat4+ y Cat5+. Se incluyen tanto los límites inferiores como los superiores (l_{ann} , u_{ann}) obtenidos mediante simulación Monte Carlo sobre las distribuciones Beta posteriores.

Los resultados se resumen mediante estadísticas robustas (mediana y percentiles P10-P90), calculadas sobre el conjunto de nodos geográficos de cada período. Dado que estos valores representan cotas estadísticas derivadas directamente de la inferencia bayesiana, y no superficies continuas, se presentan exclusivamente en forma tabular, sin interpolación espacial.

Tabla 16: Intervalos de credibilidad (95 %) de las probabilidades anuales

	Período	Estadístico	l_{ann}	u_{ann}
Categoría Cat3+	1950-1979	Mediana	0.0173	0.0568
		P10-P90	0.0080	0.0932
	1980-2009	Mediana	0.0147	0.0466
		P10-P90	0.00383	0.0977
	2010-2021	Mediana	0.00525	0.0263
		P10-P90	0.00170	0.0816
Categoría Cat4+	1950-1979	Mediana	0.00081	0.00926
		P10-P90	0.00020	0.0251
	1980-2009	Mediana	0.00173	0.01122
		P10-P90	0.00020	0.0387
	2010-2021	Mediana	0.00036	0.00638
		P10-P90	9.05×10^{-5}	0.0290
Categoría Cat5+				
	1950-1979	Mediana	1.35×10^{-10}	0.00024
		P10-P90	4.92×10^{-11}	0.00183
	1980-2009	Mediana	1.03×10^{-6}	0.00064
		P10-P90	1.59×10^{-7}	0.00566
	2010-2021	Mediana	3.80×10^{-10}	0.00020
		P10-P90	1.69×10^{-10}	0.00210
Nodos: 1950-1979: 9290, 1980-2009: 10625, 2010-2021: 10312				

Anexo C. Soporte observacional local

El soporte observacional local (n_{local}) corresponde al número de observaciones históricas de ciclones tropicales registradas dentro del radio espacial definido para el modelo Beta-Binomial local y representa el tamaño efectivo de muestra utilizado en cada nodo de la malla geográfica. Dado que n_{local} depende exclusivamente del muestreo espacial y temporal, su valor es común a todas las categorías de intensidad dentro de un mismo período.

Al tratarse de una variable discreta directamente asociada a las observaciones, el soporte observacional se presenta sin interpolación espacial, permitiendo evaluar la densidad de datos disponibles y contextualizar la estabilidad de las estimaciones probabilísticas y de sus intervalos de credibilidad.

Tabla 17: Resumen del soporte observacional local (n_{local}) por período

Período	Nodos	$n_{\text{local}}\text{mín}$	Mediana n_{local}	$n_{\text{local}}\text{máx}$
1950-1979	9290	15	48	125
1980-2009	10625	15	88	185
2010-2021	10312	15	48	109

El soporte observacional local muestra diferencias claras entre períodos. El intervalo 1980-2009 presenta la mayor mediana de observaciones por nodo, reflejando una mayor densidad del registro histórico durante este período. En contraste, 1950-1979 y 2010-2021 presentan medianas más moderadas, asociadas respectivamente a limitaciones en los registros tempranos y a la menor longitud temporal del período más reciente.

Estas variaciones en el tamaño efectivo de muestra explican parcialmente las diferencias observadas en la amplitud de los intervalos de credibilidad de las probabilidades estimadas, reforzando la necesidad de interpretar los resultados probabilísticos en conjunto con su soporte observacional.