NOTA TÉCNICA Nº IDB-TN-03139

Revisión de métodos y herramientas de software para evaluación de riesgo de desastres

María Carolina Rogelis
Andrés Abarca
María Alejandra Escovar
Ginés Suarez

Banco Interamericano de Desarrollo
Unidad de Gestión de Riesgos de Desastres

Septiembre 2025

Revisión de métodos y herramientas de software para evaluación de riesgo de desastres

María Carolina Rogelis
Andrés Abarca
María Alejandra Escovar
Ginés Suarez

Banco Interamericano de Desarrollo
Unidad de Gestión de Riesgos de Desastres

Septiembre 2025

Catalogación en la fuente proporcionada por la
Biblioteca Felipe Herrera del
Banco Interamericano de Desarrollo
Revisión de métodos y herramientas de software para evaluación de riesgo de desastres / María Carolina Rogelis, Andrés Abarca, María Alejandra Escovar, Ginés Suarez.
p. cm. — (Nota técnica del BID ; 3139)
Incluye referencias bibliográficas.
1. Climatic changes-Risk management-Software-Latin America. 2. Climatic changes-Risk management-Software-Caribbean Area. 3. Hazard mitigation-Software-Latin America. 4. Hazard mitigation-Software-Caribbean Area. I. Rogelis, María Carolina. II. Abarca, Andrés. III. Escovar, María Alejandra. IV. Suarez, Ginés. V. Banco Interamericano de Desarrollo. Unidad de Gestión de Riesgos de Desastres. VI. Serie.
IDB-TN-3139

Códigos JEL: Q54, N56, O18, D81
Palabras clave: Evaluación de riesgo, Desastres, Amenazas naturales, Inteligencia artificial, Gestión de desastres, Cambio climático, Vulnerabilidad

http://www.iadb.org

Copyright © 2025 Banco Interamericano de Desarrollo (BID). Esta obra se encuentra sujeta a una licencia Creative Commons CC BY 3.0 IGO (https://creativecommons.org/licenses/by/3.0/igo/legalcode). Se deberá cumplir los términos y condiciones señalados en el enlace URL y otorgar el respectivo reconocimiento al BID.

En alcance a la sección 8 de la licencia indicada, cualquier mediación relacionada con disputas que surjan bajo esta licencia será llevada a cabo de conformidad con el Reglamento de Mediación de la OMPI. Cualquier disputa relacionada con el uso de las obras del BID que no pueda resolverse amistosamente se someterá a arbitraje de conformidad con las reglas de la Comisión de las Naciones Unidas para el Derecho Mercantil (CNUDMI). El uso del nombre del BID para cualquier fin distinto al reconocimiento respectivo y el uso del logotipo del BID, no están autorizados por esta licencia y requieren de un acuerdo de licencia adicional.

Note que el enlace URL incluye términos y condiciones que forman parte integral de esta licencia.

Las opiniones expresadas en esta obra son exclusivamente de los autores y no necesariamente reflejan el punto de vista del BID, de su Directorio Ejecutivo ni de los países que representa.



REVISIÓN DE MÉTODOS Y HERRAMIENTAS DE SOFTWARE PARA EVALUACIÓN DE RIESGO DE DESASTRES

Autores:

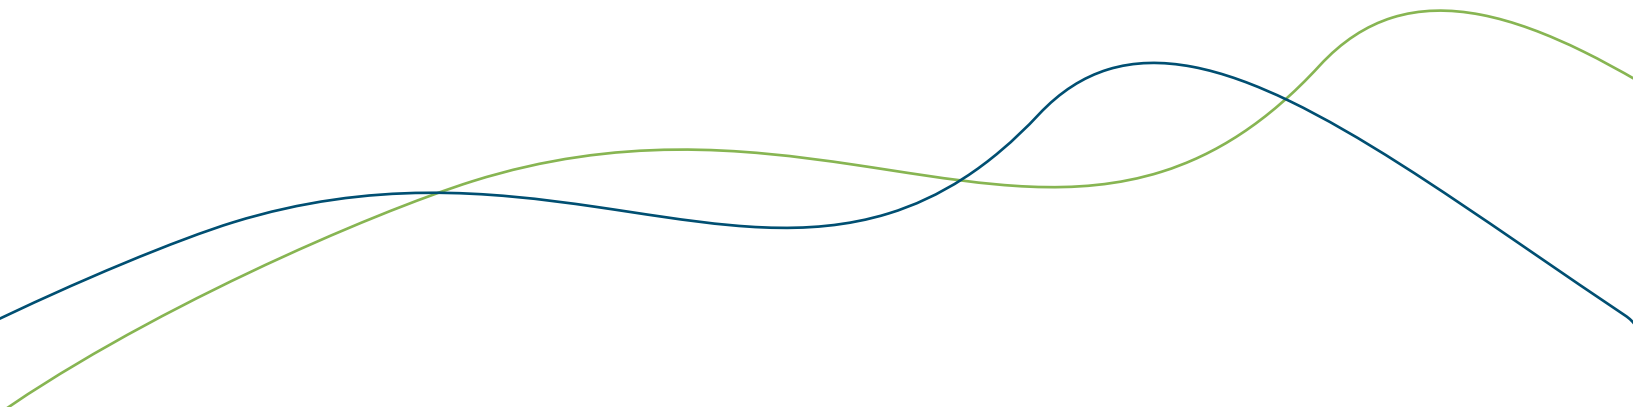
María Carolina Rogelis
María Alejandra Escovar
Andrés Abarca
Kenneth Otálora
Walter Cortes
Ginés Suarez
(CSD/DRM)



REVISIÓN DE MÉTODOS Y HERRAMIENTAS DE SOFTWARE PARA EVALUACIÓN DE RIESGO DE DESASTRES

Autores:

María Carolina Rogelis, María Alejandra Escovar, Andrés Abarca, Kenneth Otálora, Walter Cortes, Ginés Suarez (CSD/DRM).





INTRODUCCIÓN

La evaluación del riesgo de desastres es un componente fundamental en la gestión del riesgo y la planificación de medidas de reducción de riesgo[1] y adaptación. En los últimos años, el desarrollo de herramientas especializadas ha permitido mejorar la capacidad de análisis mediante el uso de metodologías avanzadas que incorporan análisis para varios tipos de amenazas, modelos matemáticos, inteligencia artificial, enfoques de gobernanza y consideraciones sobre el cambio climático. Este documento ofrece una revisión detallada de las principales plataformas y métodos utilizados en el cálculo de riesgo, destacando sus capacidades, limitaciones y áreas de aplicación.

El documento está estructurado en siete secciones. En la Sección 1, se presentan las herramientas existentes para el cálculo de riesgo, diferenciando aquellas que permiten la evaluación multiamenaza[2] de aquellas especializadas en riesgos específicos como inundaciones y sismos. La Sección 2 explora el uso de inteligencia artificial en la gestión del riesgo de desastres, incluyendo aplicaciones en mitigación, preparación y respuesta. En la Sección 3, se describen los modelos matemáticos utilizados para la estimación del riesgo, desde enfoques basados en eventos probabilísticos hasta métodos específicos de cuantificación de la incertidumbre implementados en diversas herramientas. La Sección 4 analiza metodologías que incorporan la vulnerabilidad social y la gobernanza en los análisis de riesgo. La Sección 5 está dedicada a la evaluación del riesgo considerando el cambio climático, con un énfasis particular en CLIMADA, la única plataforma revisada que cuenta con métodos específicos para este propósito. Posteriormente, la Sección 6 describe los productos globales de precipitación de libre acceso que pueden ser utilizados en análisis de amenazas hidrometeorológicas. Finalmente, la Sección 7 aborda la información global disponible para la evaluación de exposición y vulnerabilidad, aspectos clave en la estimación del riesgo de desastres.

Este documento busca proporcionar una visión integral de las herramientas y metodologías disponibles, facilitando su selección y aplicación en estudios de riesgo a diferentes escalas y contextos.

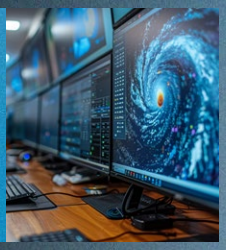
[1] La conceptualización de la clasificación de las medidas de reducción del riesgo puede variar dependiendo del país su normatividad. Por ejemplo, en Colombia (ley 1523 de 2012) la reducción del riesgo la componen la intervención correctiva del riesgo existente, la intervención prospectiva de nuevo riesgo y la protección financiera.

[2] El término multiamenaza es equivalente en ingles a *multi-hazard* que según la **Oficina de las Naciones Unidas para la Reducción del Riesgo de Desastres** significa: (1) la selección de múltiples amenazas principales a las que se enfrenta el país, y (2) los contextos específicos en los que los eventos peligrosos pueden ocurrir de manera simultánea, en cascada o acumularse con el tiempo, teniendo en cuenta los posibles efectos interrelacionados.

SECCIÓN 1

REVISIÓN DE HERRAMIENTAS EXISTENTES PARA EL CÁLCULO DE RIESGO

Se presentan las herramientas existentes para el cálculo de riesgo, diferenciando aquellas que permiten la evaluación multiamenaza[2] de aquellas especializadas en riesgos específicos como inundaciones y sismos.





SECCIÓN 2

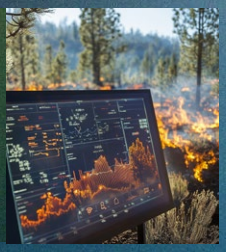
MÉTODOS DE INTELIGENCIA ARTIFICIAL EN EL CÁLCULO DE RIESGO

Explora el uso de inteligencia artificial en la gestión del riesgo de desastres, incluyendo aplicaciones en mitigación, preparación y respuesta.

SECCIÓN 3

MODELOS MATEMÁTICOS USADOS EN LAS PLATAFORMAS DE CÁLCULO DE RIESGO DE DESASTRES

Analiza metodologías que incorporan la vulnerabilidad social y la gobernanza en los análisis de riesgo.





SECCIÓN 4

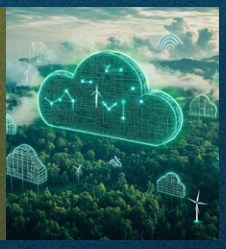
MÉTODOS QUE INCORPORAN VULNERABILIDAD SOCIAL Y/O GOBERNANZA EN LOS ANÁLISIS DE RIESGO

Analiza metodologías que incorporan la vulnerabilidad social y la gobernanza en los análisis de riesgo especializadas en riesgos específicos como inundaciones y sismos.

SECCIÓN 5

CAMBIO CLIMÁTICO Y CÁLCULOS DE RIESGO

Está dedicada a la evaluación del riesgo considerando el cambio climático, con un énfasis particular en CLIMADA, la única plataforma revisada que cuenta con métodos específicos para este propósito.





SECCIÓN 6

PRODUCTOS GLOBALES DE PRECIPITACIÓN DE LIBRE ACCESO

Describe los productos globales de precipitación de libre acceso que pueden ser utilizados en análisis de amenazas hidrometeorológicas.

SECCIÓN 7

INFORMACIÓN GLOBAL DE LIBRE ACCESO PARA ANÁLISIS DE EXPOSICIÓN Y VULNERABILIDAD

Aborda la información global disponible para la evaluación de exposición y vulnerabilidad, aspectos clave en la estimación del riesgo de desastres.



CONTENIDO

INTRODUCCIÓN ---- 04



1 REVISIÓN DE HERRAMIENTAS EXISTENTES PARA EL CÁLCULO DE RIESGO 11

1.1. INTRODUCCIÓN ---- 12
1.2. PLATAFORMAS MULTIAMENAZA ---- 13
2.2.1. Descripción ---- 14
2.2.2. Accesibilidad ---- 16
2.2.3. Comunidad de desarrollo y soporte ---- 18
2.2.4. Actualizaciones y mejora continua del software ---- 20
2.2.5. Interfaz gráfica ---- 22
2.2.6. Marco conceptual para la estimación del riesgo ---- 23
2.2.7. Comparación de herramientas ---- 26
1.3. PLATAFORMAS PARA EL CÁLCULO DE RIESGO POR INUNDACIÓN ---- 28
1.4. PLATAFORMAS PARA EL CÁLCULO DE RIESGO SÍSMICO ---- 30
2.4.1. Accesibilidad ---- 30
2.4.2. Comunidad de desarrollo y soporte ---- 31
2.4.3. Actualizaciones y mejora continua ---- 31
2.4.4. Interfaz gráfica ---- 32
2.4.5. Marco conceptual para la estimación del riesgo ---- 32
1.5. CONCLUSIONES ---- 33



2 MÉTODOS DE INTELIGENCIA ARTIFICIAL EN EL CÁLCULO DE RIESGO 35

2.1. INTRODUCCIÓN ---- 36
2.2. APLICACIONES DE LA IA EN LA GESTIÓN DE RIESGOS DE DESASTRES ---- 40
2.2.1. Mitigación y preparación ante desastres ---- 43
2.2.2. Respuesta ante desastres ---- 60
2.3. RETOS ---- 62



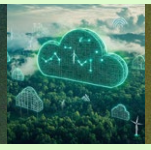
3 MODELOS MATEMÁTICOS USADOS EN LAS PLATAFORMAS DE CÁLCULO DE RIESGO DE DESASTRES ---- 67

3.1. INTRODUCCIÓN ---- 68
3.2. CURVAS DE VULNERABILIDAD Y DE FRAGILIDAD ---- 72
3.3. EVALUACIÓN PROBABILISTA COMPLETA EN LAS PLATAFORMAS EVALUADAS ---- 76
3.4. EVALUACIÓN PROBABILISTA SIMPLIFICADA DE RIESGO EN LAS PLATAFORMAS EVALUADAS ---- 78
3.5. EVALUACIÓN MIXTA DETERMINISTA PROBABILISTA ---- 81
3.6. RESUMEN ---- 83



4 MÉTODOS QUE INCORPORAN VULNERABILIDAD SOCIAL Y/O GOBERNANZA EN LOS ANÁLISIS DE RIESGO 89

4.1. INTRODUCCIÓN ---- 90
4.2. MÉTODOS INCORPORADOS EN EL PLUG IN THE OPENQUAKE ---- 92
4.3. PLUGINS THE QGIS PARA ANÁLISIS MULTICRITÉRIO ---- 94
4.3.1. Spatial Sustainability Assessment Model (SSAM) 95
4.3.2. Weighted Multi-Criteria Analysis (WMCA) ---- 95



5 CAMBIO CLIMÁTICO Y CÁLCULOS DE RIESGO ---- 97

5.1. INTRODUCCIÓN ---- 98
5.2. ESTIMACIÓN DE RIESGO INCORPORANDO CAMBIO CLIMÁTICO EN LAS PLATAFORMAS ---- 99
5.3. ENFOQUE DE CAMBIO CLIMÁTICO EN CLIMADA ---- 101
5.4. MÉTODOS INCORPORADOS EN CLIMADA PARA CAMBIO CLIMÁTICO ---- 105
5.5. PUNTOS CLAVE PARA EL ANÁLISIS DE RIESGO BAJO CAMBIO CLIMÁTICO ---- 108



6 PRODUCTOS GLOBALES DE PRECIPITACIÓN DE LIBRE ACCESO 111

6.1. INTRODUCCIÓN 112
6.2. PRODUCTOS SATELITALES DE PRECIPITACIÓN 113
6.3. PRODUCTOS DE REANÁLISIS 118



7 INFORMACIÓN GLOBAL DE LIBRE ACCESO PARA ANÁLISIS DE EXPOSICIÓN Y VULNERABILIDAD 121

7.1. EXPOSICIÓN 122
7.1.1. Modelos globales 123
7.1.2. Información disponible que puede ser usada para generar capas de exposición 129
7.2. VULNERABILIDAD 140

REFERENCIAS 142

ANEXOS 154

ANEXO A. CARACTERÍSTICAS DE LAS HERRAMIENTAS EXISTENTES PARA EL CÁLCULO DE RIESGO 155

A.1. CAPRA (PROBABILISTIC RISK ASSESSMENT PLATFORM) 155
A.1.1 Descripción general 155
A.1.2 Métodos aplicados 155
A.1.3 Enfoque matemático 157
A.1.4 Avances recientes en capra 158
A.1.5 Comunidad de desarrollo 159
A.1.6 Limitaciones 159
A.1.7 Casos de uso 159

A.2. HAZUS 162
A.2.1 Descripción general 162
A.2.2 Métodos aplicados 162
A.2.3 Enfoque matemático 172
A.2.4 Avances recientes e innovaciones 177
A.2.5 Comunidad de desarrollo 177
A.2.6 Limitaciones 177
A.2.7 Casos de uso 177

A.3. RISKSCAPE: HERRAMIENTA DE EVALUACIÓN DE RIESGO 180
A.3.1 Descripción general 180
A.3.2 Métodos aplicados 180
A.3.3 Enfoque matemático 184
A.3.4 Avances recientes e innovaciones 192
A.3.5 Comunidad de desarrollo 193
A.3.6 Limitaciones 193
A.3.7 Casos de uso 193

A.4. INASAFE 198
A.4.1 Descripción general 198
A.4.2 Métodos aplicados 198
A.4.3 Avances recientes e innovaciones 201
A.4.4 Comunidad de desarrollo 201
A.4.5 Limitaciones 201
A.4.6 Casos de uso 201

A.5. OASIS LOSS MODELLING FRAMEWORK (OASIS LMF) 204
A.5.1 Descripción general 204
A.5.2 Métodos aplicados 206
A.5.3 Enfoque matemático 209
A.5.4 Avances recientes e innovaciones 212
A.5.5 Comunidad de desarrollo 212
A.5.6 Limitaciones 212
A.5.7 Casos de uso 212

A.6. INTERDEPENDENT NETWORKED COMMUNITY RESILIENCE MODELING ENVIRONMENT IN-CORE 215
A.6.1 Descripción general 215
A.6.2 Métodos aplicados 217
A.6.3 Enfoque matemático 232
A.6.4 Avances recientes e innovaciones 233
A.6.5 Comunidad de desarrollo 233
A.6.6 Limitaciones 233
A.6.7 Casos de uso 233

A.7. CLIMADA (CLIMATE ADAPTATION) 236
A.7.1 Descripción general 236
A.7.2 Métodos aplicados 236
A.7.3 Enfoque matemático 238
A.7.4 Avances recientes e innovaciones 242
A.7.5 Comunidad de desarrollo 242
A.7.6 Limitaciones 242
A.7.7 Casos de uso 242

A.8. CATSIM (CATASTROPHE SIMULATION TOOL) ---- 246

A.8.1 Descripción general ---- 246
A.8.2 Métodos aplicados ---- 247
A.8.3 Avances recientes e innovaciones ---- 249
A.8.4 Comunidad de desarrollo ---- 250
A.8.5 Limitaciones ---- 250
A.8.6 Casos de uso ---- 250

A.9. RISKCHANGES ---- 254

A.9.1 Descripción general ---- 254
A.9.2 Métodos aplicados ---- 254
A.9.3 Avances recientes e innovaciones ---- 254
A.9.4 Comunidad de desarrollo ---- 254
A.9.5 Limitaciones ---- 254
A.9.6 Casos de uso ---- 254

A.10. FLOODRISK - QGIS PLUGIN ---- 257

A.10.1 Descripción general ---- 257
A.10.2 Métodos aplicados ---- 259
A.10.3 Avances recientes e innovaciones ---- 260
A.10.4 Comunidad de desarrollo ---- 260
A.10.5 Limitaciones ---- 261
A.10.6 Casos de uso ---- 261

A.11. FLOODRISE ---- 264

A.11.1 Descripción general ---- 264
A.11.2 Métodos aplicados ---- 264
A.11.3 Avances recientes e innovaciones ---- 264
A.11.4 Comunidad de desarrollo ---- 264
A.11.5 Limitaciones ---- 264
A.11.6 Casos de uso ---- 265

A.12. DELFT-FIAT ---- 265

A.12.1 Descripción general ---- 265
A.12.2 Métodos aplicados ---- 266
A.12.3 Avances recientes e innovaciones ---- 267
A.12.4 Comunidad de desarrollo ---- 267
A.12.5 Limitaciones ---- 267
A.12.6 Casos de uso ---- 267

A.13. HEC-FDA ---- 269

A.13.1 Descripción general ---- 269
A.13.2 Métodos aplicados ---- 269
A.13.3 Enfoque matemático ---- 270
A.13.4 Avances recientes e innovaciones ---- 274
A.13.5 Comunidad de desarrollo ---- 274
A.13.6 Limitaciones ---- 274
A.13.7 Casos de uso ---- 274

A.14. OPENQUAKE ---- 278

A.14.1 Introducción a openquake ---- 278
A.14.2 Métodos aplicados ---- 278
A.14.3 Enfoque matemático ---- 280
A.14.4 Avances recientes e innovaciones ---- 284
A.14.5 Comunidad de desarrollo ---- 284
A.14.6 Limitaciones ---- 285
A.14.7 Casos de uso ---- 285

ANEXO B. TIPOS DE DATOS ---- 288



Imagen: Flickr - Ciudades Sostenibles BID / Panamá

SECCIÓN 1



Imagen: Adobe Stock

REVISIÓN DE HERRAMIENTAS EXISTENTES PARA EL CÁLCULO DE RIESGO

1.1. INTRODUCCIÓN



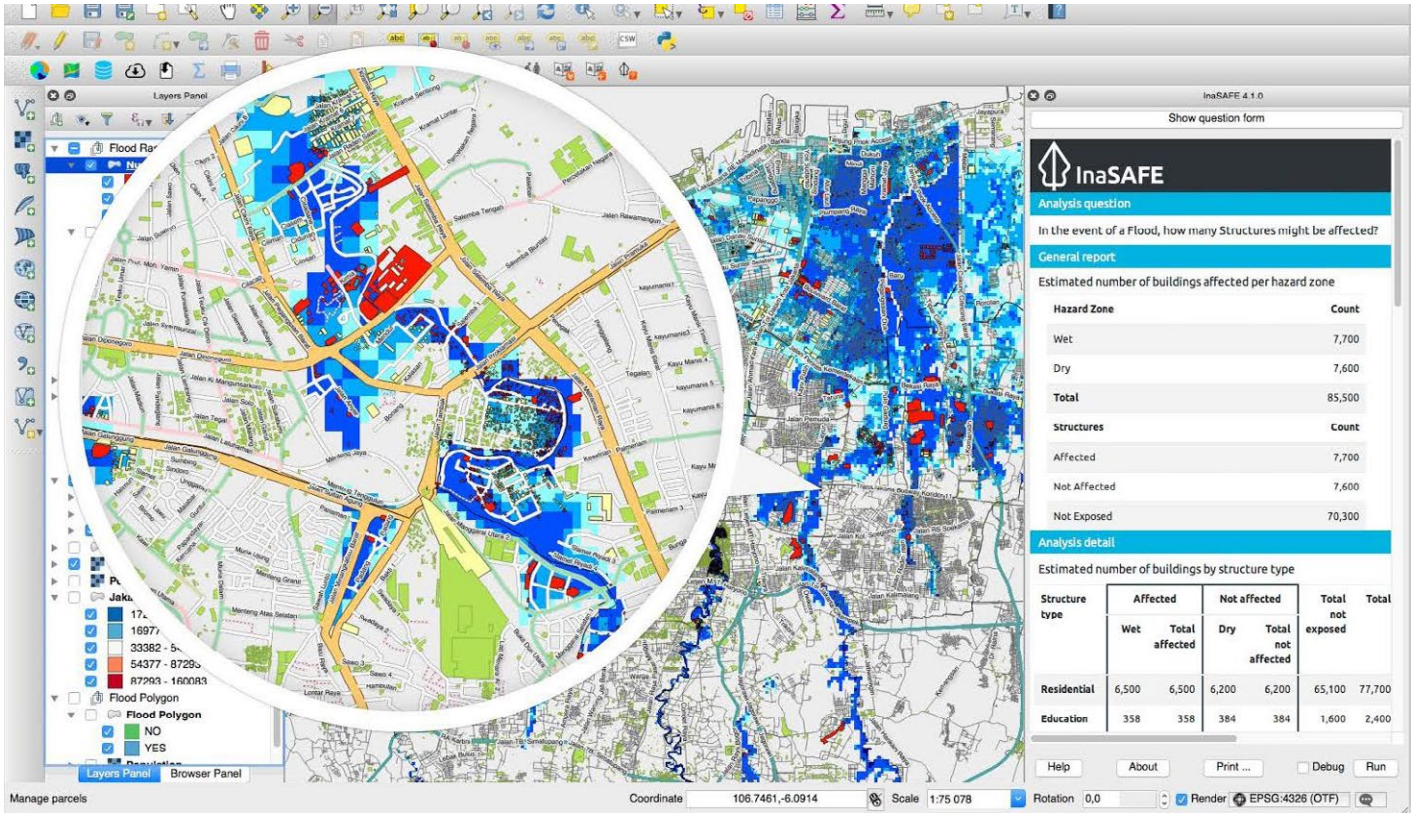
Imagen: Adobe Stock

La capacidad de evaluar y gestionar el riesgo es una prioridad para gobiernos nacionales, regionales y locales, organizaciones e instituciones financieras. Las plataformas de cálculo de riesgos son herramientas fundamentales que permiten analizar, modelar y proyectar los impactos de diversos escenarios, facilitando la toma de decisiones informada. Estas plataformas han tenido un desarrollo acelerado en los últimos años incorporando métodos avanzados de análisis estadístico, modelado probabilístico, simulación e incluso inteligencia artificial para ofrecer herramientas que permitan el cálculo de riesgo haciendo uso del estado del arte del conocimiento y potenciando los recursos computacionales.

El desarrollo de plataformas y herramientas de cálculo de riesgo representa un avance significativo en la evaluación del riesgo. En la actualidad, existe una disponibilidad significativa de plataformas y herramientas, cada una de estas tiene características únicas que las hacen especialmente útiles en diferentes contextos, desde la evaluación de riesgos sísmicos hasta la modelización de impactos climáticos. Su implementación no solo permite cuantificar los posibles daños económicos y sociales, sino que también promueve una mejor preparación y resiliencia frente a desastres.

Este capítulo ofrece un análisis de diversas plataformas de cálculo de riesgos, destacando sus características, funcionalidades y aplicaciones específicas. La estructura del capítulo se organiza como un resumen de la revisión de literatura sobre las herramientas disponibles para el cálculo de riesgo multiamenaza, para riesgo de inundación y riesgo sísmico evaluando diferentes criterios como su accesibilidad, comunidad de desarrollo y soporte, disponibilidad del software, interfaz gráfica y marco conceptual para la estimación del riesgo. El **Anexo A** incluye detalles adicionales sobre cada una de las plataformas, así como ejemplos de uso que amplían el contenido expuesto en el capítulo. A través de este análisis, se pretende proporcionar una visión integral que facilite la identificación de la solución más adecuada para los tipos de análisis que el Banco Interamericano de Desarrollo desea ofrecer a los países de América Latina y el Caribe.

1.2. PLATAFORMAS MULTIAMENAZA



fuente https://inasafe.org/

1.2.1. Descripción

Estas plataformas están diseñadas para analizar diversos tipos de amenazas y aunque algunas de ellas pueden estar diseñadas para amenazas específicas debido a su flexibilidad podrían ser utilizadas con otras amenazas. A continuación, una breve descripción de las plataformas evaluadas, para mayor detalle de las características de las plataformas consultar el **Anexo A**.

CAPRA (Probabilistic Risk Assessment Platform) (https://ecapra.org/) es una plataforma que utiliza un enfoque probabilístico para la evaluación de riesgos de desastres. Permite cuantificar y analizar el riesgo asociado con sismos, tsunami, volcanes, movimientos en masa, huracanes, inundaciones, precipitación y sequía (Universidad de Los Andes 2024a). Genera métricas como curvas de riesgo, distribución espacial de daños y la pérdida anual esperada (Banco Mundial et al. 2009).

HAZUS (https://www.fema.gov/flood-maps/products-tools/hazus) es un software desarrollado por FEMA que se centra en la evaluación del riesgo de desastres mediante una metodología estandarizada. Se utiliza para estimar los impactos de terremotos, huracanes, inundaciones y tsunamis. Sus resultados incluyen estimaciones de daños físicos a las estructuras, pérdidas económicas y sociales (FEMA 2023).

RiskScape (https://riskscape.org.nz/) es una aplicación que procesa datos espaciales para realizar análisis de riesgos multiamenaza. Combina capas espaciales para evaluar la exposición de edificios y otras infraestructuras, ofreciendo un análisis de riesgos potenciales (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024c).

InaSAFE (https://inasafe.org/) una herramienta de software libre, también se especializa en evaluar los impactos de los desastres, particularmente sismos, tsunamis e inundaciones. Su enfoque está en la generación de escenarios de impacto y la creación de capas de mapas para mostrar los efectos de diferentes amenazas, aunque no realiza un análisis económico del riesgo, sino que se enfoca en la exposición de elementos y la planificación de la respuesta (InaSAFE 2019a).

OASIS (https://oasislmf.org/) esta herramienta se enfoca en el modelado de catástrofes, proporcionando herramientas estandarizadas para la evaluación de riesgos y la cuantificación de pérdidas financieras. Los usuarios pueden evaluar pérdidas potenciales y áreas de alto riesgo a través de modelos que integran datos de exposición y análisis de escenarios catastróficos (OASIS 2024a).

IN-CORE (Integrated Computational Resilience) (https://in-core.org/) es una plataforma desarrollada por la Universidad Estatal de Colorado para analizar la resiliencia de infraestructuras y comunidades ante desastres. Integra modelos de simulación para evaluar los impactos tanto físicos como socioeconómicos de los desastres, analizando la recuperación de comunidades y ofreciendo herramientas para optimizar la planificación de la resiliencia y la respuesta ante desastres (IN-CORE 2024).

CLIMADA (CLIMate ADAptation) (https://climada.ethz.ch/) es una herramienta de modelado probabilístico que evalúa el riesgo socioeconómico de eventos climáticos, pero puede ser utilizada para el análisis de otras amenazas, considerando tanto el presente como proyecciones futuras. Permite realizar estudios de eventos individuales y conjuntos, y evaluar cómo las medidas de adaptación pueden reducir los impactos del cambio climático (Aznar-Siguan y Bresch 2019).

CATSIM (Catastrophe Simulation Tool) (https://iiasa.ac.at/models-tools-data/catsim) desarrollado por IIASA, se enfoca en ayudar a los responsables de políticas a identificar las mejores estrategias financieras para enfrentar los riesgos de desastres. CATSIM incluye un módulo para evaluar el riesgo y otro para mostrar los costos y beneficios de diferentes estrategias financieras, permitiendo a los usuarios ajustar parámetros y simular diversas condiciones económicas y de riesgo (IIASA 2024a).

RiskChanges (https://riskchanges.org/) desarrollada por la Universidad de Twente y el Instituto de Tecnología de Asia, Centro de Geoinformática. Es una herramienta de código abierto, diseñado para analizar riesgos dinámicos multiamenaza. Permite evaluar y gestionar riesgos asociados con diferentes amenazas naturales y antropogénicas, considerando sus interacciones y efectos acumulativos (PreventionWeb 2023).

Además de estas nueve plataformas, se identificaron páginas web de otras herramientas que, aunque representan esfuerzos valiosos, no fueron incluidas en el análisis comparativo ni en el Anexo A. Esto se debe a que no se logró confirmar su continuidad. Un ejemplo es PRAISys (Probabilistic Resilience Assessment for Interdependent Systems), que cuenta con una página web (Lehigh University y Florida Atlantic University 2020) y permite descargar el software previa solicitud, proporcionando un enlace de Google Drive para la descarga. Sin embargo, no se encontró documentación detallada, y la última versión del software data de 2020, sin evidencia clara de que la iniciativa haya tenido continuidad.

1.2.2. Accesibilidad

Las plataformas multiamenaza revisadas tienen diferentes licencias y niveles de acceso a su código fuente, lo que influye en la flexibilidad de su uso y modificación. CAPRA no especifica públicamente su licencia, y aunque originalmente se contempló como de código abierto, actualmente no está disponible para acceso público. El software está diseñado para ser usado en sistemas Windows con soporte mejorado para sistemas operativos de 64 bits, y fue desarrollado en VB.NET 2005. No tiene un repositorio público para su código, lo que limita la posibilidad de personalizar o extender la plataforma por los usuarios (Universidad de Los Andes 2024a). HAZUS, es gratuito, pero requiere el uso de ArcGIS, que es un software pago. Aunque algunas de las herramientas complementarias de HAZUS son de código abierto, y existe un proyecto de FEMA para crear una distribución open-source en Python (FEMA 2020), el código completo no está accesible para su libre modificación.

En cuanto a RiskScape, este software está disponible bajo la licencia AGPLv3[3] y es de código abierto. Se puede ejecutar en Windows, Linux y macOS, siempre que se tenga instalada la versión 17 o superior de Java. La plataforma está desarrollada en Java y Python, y su código fuente está disponible en la página web oficial del software, lo que permite a los usuarios investigar, modificar y contribuir al proyecto. InaSAFE es una herramienta totalmente de código abierto bajo la licencia GPLv3, compatible con Windows, macOS y Linux. Desarrollado en Python, InaSAFE está disponible en su repositorio en GitHub, lo que facilita su personalización y adaptación para necesidades específicas.

Por otro lado, OASIS es de código abierto con licencia BSD 3[4], pero el uso de los modelos que emplea no es gratuito. Está disponible en Windows a través de contenedores Docker o el subsistema de Linux para Windows, y fue desarrollado en Python 3 y C++ 11. Su código fuente está disponible en GitHub. IN-CORE también distribuye su código fuente bajo una licencia de código abierto, específicamente la Licencia Pública de Mozilla 2.0[5]. Es compatible con Windows, macOS y Linux, y está desarrollado en

[3] La Licencia Pública General Affero versión 3 (AGPLv3) es una licencia de software libre y de código abierto. La AGPLv3 requiere que cualquier modificación del software, incluso si se ejecuta en un servidor y no se distribuye directamente a los usuarios, también debe ser liberada bajo la misma licencia (https://www.gnu.org/licenses/agpl-3.0.html).

[4] La Licencia BSD de 3 cláusulas (BSD 3-Clause License) es una licencia de software libre y de código abierto que permite el uso, modificación y distribución del software con mínimas restricciones. Es una versión más permisiva de la licencia BSD original, eliminando la cláusula de publicidad pero manteniendo tres condiciones principales: (1) se debe conservar el aviso de copyright y la lista de condiciones en todas las copias o distribuciones del software; (2) no se puede usar el nombre de los autores o colaboradores para promocionar productos derivados sin permiso; y (3) se exonera de responsabilidad a los desarrolladores originales (https://opensource.org/licenses/BSD-3-Clause).

[5] La Licencia Pública de Mozilla 2.0 (MPL-2.0) es una licencia de software libre y de código abierto que combina características de licencias permisivas y copyleft. Permite que el código licenciado bajo MPL-2.0 se use, modifique y distribuya, incluso en proyectos propietarios, siempre que los archivos modificados bajo MPL permanezcan bajo la misma licencia y se compartan con la comunidad (https://opensource.org/licenses/MPL-2.0).

Python y Java. Su repositorio en GitHub permite a los usuarios acceder al código y contribuir al desarrollo de la plataforma. CLIMADA, otra herramienta de código abierto está bajo la licencia GNU GPL3[6] y es compatible con Windows, macOS y Linux. Desarrollada en Python, MATLAB y Octave, también tiene su código disponible en GitHub, facilitando el acceso y la colaboración. RiskChanges se distribuye bajo una licencia de código abierto MIT[7]. Esta herramienta es compatible con sistemas operativos Windows, Linux y macOS, y ha sido desarrollada utilizando el lenguaje de programación Python.

Finalmente, CATSIM tiene una licencia personalizada, lo que significa que no es de código abierto, aunque el acceso al software se puede solicitar bajo ciertas condiciones. Su repositorio no está disponible públicamente.

La **Tabla 1** resume los criterios de accesibilidad seleccionados para la comparación de las plataformas, en donde se ha considerado de alta importancia que la herramienta sea de código abierto y que además ponga a disponibilidad del público el código a través de GitHub.

Tabla 1. Criterios de accesibilidad

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Código abierto	✗	✗ [1]	✓	✓	✓	✓	✓	✗	✓
GitHub	✗	✗ [2]	✗ [3]	✓	✓	✓	✓	✗	✓

Notas:
1,2. Existe un proyecto de FEMA para crear una distribución open-source de HAZUS como paquete de Python. El avance de este proyecto es desconocido, aunque el paquete está disponible para descarga e instalación con licencia GNU General Public License v3 (GPLv3+). https://fema-ftp-snapshot.s3.amazonaws.com/Hazus/hazpy/build/html/index.html https://github.com/nhrap-hazus última actualización hace 5 años.
3. El código de RiskScape no está en GitHub pero se puede descargar de la página web oficial.

[6] La Licencia Pública General de GNU, versión 3 (GPL-3.0), es una licencia de software libre con un enfoque de copyleft fuerte, lo que significa que cualquier software derivado o distribuido que incluya código bajo esta licencia también debe mantenerse bajo GPL-3.0. Garantiza a los usuarios la libertad de ejecutar, estudiar, modificar y distribuir el software, pero impone restricciones para evitar que el código sea convertido en propietario (https://www.gnu.org/licenses/gpl-3.0.html).

[7] La Licencia MIT es una licencia de software de código abierto permisiva, lo que significa que permite a los desarrolladores utilizar, modificar y distribuir el software con pocas restricciones. Su única condición es que se incluya el aviso de copyright original y la renuncia de responsabilidad en todas las copias o versiones modificadas (https://opensource.org/license/mit/).

1.2.3. Comunidad de desarrollo y soporte

En el caso de CAPRA

- No se especifica un canal de contacto directo con los desarrolladores.
- Incluye herramientas de ayuda dentro de su interfaz gráfica para guiar a los usuarios.
- Los manuales disponibles datan de 2009 y no se han registrado actualizaciones desde entonces, lo que podría limitar el soporte actualizado.

En el caso de HAZUS

- Proporciona asistencia técnica a través de un correo de contacto específico: FEMA-Hazus-Support@fema.dhs.gov
- Ofrece manuales de usuario y técnicos.
- Cuenta con un menú de ayuda integrado en la herramienta, mejorando la accesibilidad.

En el caso de RiskScape

- Ofrece un manual y herramientas de ayuda.
- Dispone de documentación en línea y tutoriales.
- No se especifica un canal directo de contacto con los desarrolladores.

En el caso de InaSAFE

- Ofrece un manual y recursos de ayuda

En el caso de OASIS

- Tiene documentación extensa disponible en su repositorio.

En el caso de IN-CORE

- Proporciona ejemplos de uso y documentación detallada en su página web.

En el caso de CLIMADA

Destaca por su documentación extensa y ejemplos de uso disponibles, facilitando la comprensión de la plataforma.

En el caso de CATSIM

No tiene un repositorio público.

Proporciona contacto directo con el líder del proyecto para soporte.

Cuenta con un manual de usuario y directrices prácticas para el uso del software.

En el caso de RiskChanges

La página web proporciona información de contacto con los desarrolladores.

Incluye herramientas de ayuda.

La documentación es muy básica y está enfocada en el uso operativo, sin detalles sobre procedimientos de cálculo.

La **Tabla 2** presenta los criterios de comparación entre las herramientas en relación con la comunidad de desarrollo y soporte. Se consideró esencial la disponibilidad de algún tipo de contacto con los desarrolladores, así como la existencia de manuales y herramientas de ayuda. No obstante, la calidad de estos últimos no se incluyó como criterio de evaluación.

Tabla 2. Criterios de comunidad de desarrollo y soporte

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Contacto con desarrolladores	X	✓	✓	✓	✓	✓	✓	✓	✓
Manuales y ayuda	✓	✓	✓	✓	✓	✓	✓	✓	✓

1.2.4. Actualizaciones y mejora continua del software

La periodicidad con la cual se pone a disposición del público la actualización del software se consideró un criterio clave para la evaluación, ya que refleja el compromiso de los desarrolladores con el mantenimiento, la incorporación de mejoras, la corrección de errores y la adaptación a nuevas necesidades o métodos

CAPRA GIS (motor de cálculo de riesgo de CAPRA)

- Comenzó su desarrollo en 2008.
- La última actualización fue en 2018 con la versión 2.4.
- El que su última actualización haya sido hace 7 años puede indicar una posible pausa en su evolución (Universidad de Los Andes 2024a).

HAZUS

- Inició en 1997.
- Ha mantenido un ciclo de actualizaciones más activo.
- La última versión (7.0) fue lanzada en noviembre de 2024 (FEMA 2024a).

RiskScape

- Inició a principios de la década de 2000.
- La versión estable más reciente, la v1.6.0, fue lanzada en abril de 2024.
- Mantiene una actualización relativamente constante.

InaSAFE

- Comenzó en octubre de 2012.
- La última actualización fue en noviembre de 2018 con la versión 5.0.0.
- Muestra una menor frecuencia de actualizaciones en comparación con otras plataformas.

OASIS

- Comenzó en 2012.
- Actualmente en evolución con la versión 2.4.0 de febrero de 2025.

IN-CORE

- Comenzó en 2015.
- Se actualiza activamente.
- La versión 5.5.1 fue lanzada en noviembre de 2024.

CLIMADA

- Comenzó en 2018.
- Se actualiza constantemente.
- La última versión (v5.0.0) fue en julio de 2024.

CATSIM

- Sin fecha de inicio específica.
- Está en proceso de expansión hacia una versión web interactiva.
- La última modificación del manual fue en agosto de 2021, indicando que el desarrollo activo continúa.

RiskChanges

- No se pudo identificar la fecha de inicio de desarrollo.
- La última modificación del código en GitHub fue en junio de 2022.
- No hay información sobre actualizaciones posteriores.

La **Tabla 3** presenta el criterio seleccionado para evaluar las actualizaciones y la mejora continua del software, el cual establece que debe haberse realizado al menos una actualización en los últimos dos años.

Tabla 3. Criterio de actualizaciones y mejora continua del software

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Actualización en los últimos dos años	✗	✓	✓	✗	✓	✓	✓	✗	✗

1.2.5. Interfaz gráfica

Las plataformas multiamenaza varían en cuanto a su interfaz de usuario y su integración con otros software. CAPRA cuenta con una interfaz gráfica en español, y se presenta como un software standalone, lo que significa que puede utilizarse de manera independiente sin depender de otras aplicaciones. En cambio, HAZUS, que tiene una interfaz gráfica en inglés, requiere de ArcGIS para su funcionamiento, lo que lo convierte en un software que no es autónomo y requiere que el usuario adquiera la licencia de ArcGIS.

RiskScape y OASIS son plataformas con interfaces gráficas en inglés que funcionan como software independiente y no dependen de otras aplicaciones como QGIS o ArcGIS, aunque RiskScape no cuenta con una interfaz gráfica y la interacción de usuario se realiza a través de la línea de comando. InaSAFE, por otro lado, se integra como un plugin de QGIS y tiene una interfaz gráfica en inglés e indonesio, lo que le permite ser una herramienta fácil de usar dentro del entorno de QGIS.

Las plataformas IN-CORE y CLIMADA no cuentan con interfaces gráficas propias. IN-CORE se utiliza en el entorno de Python/Jupyter, lo que significa que los usuarios interactúan a través de código en lugar de interfaces visuales. Similarmente, CLIMADA también es un paquete de Python que se utiliza a través de Python/Jupyter, sin una interfaz gráfica dedicada. CLIMADA también tiene una versión en MATLAB que data de 2016 pero que en este momento ya no tiene soporte.[8]

En el caso de RiskChanges, esta herramienta cuenta con una interfaz de usuario bajo su funcionamiento como herramienta web y además, puede ser utilizada como una biblioteca de Python, permitiendo la interacción del usuario a través de código (RiskChanages 2021).

[8] https://github.com/davidnbresch/climada

Por último, CATSIM presenta una interfaz gráfica en inglés y es una aplicación standalone, aunque está en proceso de lanzar una versión web interactiva.

La **Tabla 4** muestra los criterios seleccionados, que consisten en que el software no dependa de otro que requiera una licencia paga y en verificar si cuenta o no con una interfaz de usuario propia.

Tabla 4. Criterios de interfaz gráfica

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
No dependencia de otro software con licencia paga	✓	x [1]	✓	✓ [2]	✓	✓	✓	✓	✓
Interfaz de usuario propia	✓	✓	x [3]	✓	✓	x [4]	x [4]	✓	✓

Notas:
1. El uso de HAZUS requiere ArcGis pero las funciones que se han desarrollado en Python no requieren de este software.
2. InaSAFE es un plugin de QGIS que no requiere licencia.
3. RiskScape funciona desde la línea de comando.
4. Tanto IN-CORE como CLIMADA funcionan en el entorno de Python/Jupyter por lo que no tienen interfaz propia y las funciones y visualización se realiza a través de código de Python generado por el usuario.

1.2.6. Marco conceptual para la estimación del riesgo

Las plataformas multiamenaza están estructuradas en módulos que abordan diferentes aspectos del análisis de riesgos. CAPRA, por ejemplo, incluye módulos para evaluar amenazas específicas como inundaciones, movimientos en masa, huracanes y sismos, además de un módulo de vulnerabilidad y CAPRA-GIS, una herramienta especializada para el cálculo probabilístico de riesgo. En el caso de HAZUS, los módulos corresponden a las amenazas: sismos, huracanes, inundaciones y tsunamis.

Por otro lado, herramientas como RiskScape y OASIS están diseñadas con módulos que integran análisis de amenaza, exposición y vulnerabilidad. OASIS añade un módulo financiero para evaluar el impacto económico de los desastres. IN-CORE amplía esta funcionalidad al incluir módulos enfocados en impactos sociales, recuperación y optimización, mientras que CATSIM se centra exclusivamente en la evaluación del riesgo macroeconómico y el análisis de estrategias financieras. Aunque CLIMADA no presenta módulos en el sentido tradicional, organiza sus funcionalidades en paquetes que abarcan entidades[9], amenazas

[9] La clase *entity* o entidad es una clase contenedora que almacena las exposiciones y las funciones de impacto (curvas de vulnerabilidad) necesarias para un cálculo de riesgo, así como las tasas de descuento y las medidas de adaptación para un análisis costo-beneficio de adaptación. Al igual que los objetos *Hazard* o amenaza, las *Entities* pueden leerse desde archivos o crearse mediante código.

y utilidades específicas. Finalmente, RiskChanges divide sus herramientas entre modelamiento de exposición (sección de la herramienta web en donde se seleccionan las capas de elementos expuestos y amenaza para análisis de exposición), pérdidas (sección de la herramienta web llamado *loss* en donde se escoge el tipo de pérdida a calcular entre población, cuantificación de objetos, costos o geometría que puede ser área, longitud o número y un evento caracterizado por un periodo de retorno) y riesgo (sección de la herramienta web en donde es posible configurar un análisis de riesgo completo por escenarios, para una amenaza o multiamenaza). Riskchanges también contiene una base de datos de curvas de vulnerabilidad que permite a los usuarios compartir curvas.

En cuanto a los resultados y métricas calculadas, las plataformas pueden generar curvas de riesgo, lo que permite calcular la pérdida anual esperada (PAE) tanto para pérdidas físicas como humanas, dependiendo de cómo se ingresen los elementos expuestos y la vulnerabilidad. La excepción es InaSAFE, que está limitada a cálculos de exposición y, por lo tanto, no genera estimaciones de riesgo.

En el caso de OASIS y CATSIM, no se identificó documentación que indique que estas herramientas calculen métricas sociales. CATSIM, en particular, está restringida a un enfoque exclusivamente macroeconómico.

Herramientas como CAPRA, OASIS, RiskScape, IN-CORE y CLIMADA se destacan por su diseño flexible y robusto

- **CAPRA y OASIS,** en particular, fueron diseñadas primordialmente para realizar análisis probabilísticos que abarcan cientos o miles de eventos.
- **RiskScape, IN-CORE y CLIMADA** cuentan con un enfoque que abarca tanto el análisis de un número limitado de eventos como la ejecución de cálculos con un número ilimitado, gracias a su integración en entornos de Python.
- **HAZUS y RiskChanges** están diseñadas para el análisis de grupos de eventos limitados, particularmente para inundaciones y sismos en el caso de HAZUS, y para todas las amenazas en RiskChanges.

- Las versiones iniciales de HAZUS incluso restringían la cantidad de eventos para analizar (5 para inundaciones y 8 para sismos), aunque en su versión 7 esta limitación parece haber sido superada, requiriendo configuración manual en ArcGIS.
- En el caso de RiskChanges, en su versión como herramienta web, también requiere configuración manual de los análisis, aunque su integración con Python podría permitir la flexibilidad para ejecutar análisis con un número alto de eventos a través de código desarrollado por el usuario.

La cuantificación de la incertidumbre en las herramientas evaluadas se centra en la amenaza, con tres excepciones notables: CAPRA, que incluye la incertidumbre en las curvas de vulnerabilidad; IN-CORE, que emplea métodos avanzados en la cuantificación de incertidumbre de la vulnerabilidad como la Probabilidad de Estado Límite de Monte Carlo; y CLIMADA, que utiliza su módulo *Unsequa* para realizar análisis de incertidumbre global, incluyendo amenaza, exposición y función de impacto (Kropf et al. 2022).

En general, las herramientas no presentan restricciones en el uso de archivos para los análisis. Por lo general, las amenazas se modelan con archivos raster de formatos estándar, la exposición con archivos shapefile y las curvas de vulnerabilidad se ingresan mediante archivos de texto o directamente en la interfaz. La única excepción es CAPRA, que requiere archivos específicos en formato *.ame para describir las amenazas.

Todas las plataformas permiten la visualización espacial de resultados, excepto CATSIM, cuyo enfoque está limitado al análisis macroeconómico.

Tabla 5. Criterios de marco conceptual

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Curva de riesgo y PAE	X	✓	✓	X	3 ✓	✓	✓	X	X
Algún tipo de métrica de riesgo social	✓	✓	1 ✓	✓	X	✓	✓	X	✓
Diseñada para análisis probabilístico[4]	✓	X	✓	X	✓	✓	✓	X	X
Sin restricciones en el uso de algunos formatos de archivos	X	✓	1 ✓	2 ✓	✓	✓	✓	✓	✓
Métodos de análisis de incertidumbre en el componente de vulnerabilidad	✓	X	X	X	✓	✓	✓	X	X
Visualización espacial de resultados	✓	✓	✓	✓	✓	✓	✓	X	✓

Notas:
1. Aunque las herramientas no han sido diseñadas para realizar análisis completamente probabilísticos en el caso de inundaciones, sismos y tsunamis, la excepción son los huracanes, donde Hazus sí considera eventos generados para un largo periodo y toma en cuenta la incertidumbre en el impacto.
2. Aunque los métodos no se encuentran disponibles en la herramienta podrían ser desarrollados mediante Python e integrados en el flujo de trabajo de RiskScape.
3. InaSAFE puede producir valores de exposición de población, aunque no propiamente de riesgo, sin embargo, se considerará que esto es suficiente desde el punto de vista de análisis de riesgo humano.
4. En este documento el análisis probabilístico implica que es necesario analizar cientos o miles de escenarios.

1.2.7. Comparación de herramientas

La consolidación de los aspectos evaluados se muestra en la **Tabla 6**. Las tres herramientas que mayor número de criterios cumplen son CLIMADA, IN-CORE y OASIS con 12 criterios cumplidos.

Tabla 6. Consolidado de criterios cumplidos por cada herramienta evaluada

Criterio	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Código abierto	X	X	✓	✓	✓	✓	✓	X	✓
GitHub	X	X	X	✓	✓	✓	✓	X	✓
Contacto con desarrolladores	X	✓	✓	✓	✓	✓	✓	✓	✓
Manuales y ayuda	✓	✓	✓	✓	✓	✓	✓	✓	✓
Actualización en los últimos dos años	X	✓	✓	X	✓	✓	✓	X	X
No dependencia de otro software con licencia paga	✓	X	✓	✓	✓	✓	✓	✓	✓
Interfaz de usuario propia	✓	✓	X	✓	✓	X	X	✓	✓
Curva de riesgo y PAE	✓	✓	✓	X	✓	✓	✓	✓	✓
Algún tipo de métrica de riesgo social	✓	✓	✓	✓	X	✓	✓	X	✓
Diseñada para análisis probabilístico	✓	X	✓	X	✓	✓	✓	X	X
Sin restricciones en el uso de algunos formatos de archivos	X	✓	✓	✓	✓	✓	✓	✓	✓
Métodos de análisis de incertidumbre en el componente de vulnerabilidad	✓	X	X	X	✓	✓	✓	X	X
Visualización espacial de resultados	✓	✓	✓	✓	✓	✓	✓	X	✓
Total de criterios cumplidos	**8**	**8**	**10**	**9**	**12**	**12**	**12**	**6**	**10**

Si bien todas las herramientas evaluadas tienen aspectos valiosos que pueden contribuir al cálculo de riesgos, IN-CORE y CLIMADA se destacan por su avance significativo en comparación con las demás. Además de los criterios evaluados y consolidados en la **Tabla 6**, una exploración más profunda de estas dos herramientas, que incluyó la revisión de manuales y el desarrollo de tutoriales, permitió identificar las ventajas que se presentan en la **Tabla 7**.

Tabla 7. Ventajas de IN-CORE y CLIMADA

IN-CORE	CLIMADA
Contiene funciones específicas para análisis de riesgo en infraestructura como vías, sistemas eléctricos y de agua potable.	Proporciona funciones para acceso directo a modelos de cambio climático y cuenta con una API (Interfaz de Programación de Aplicaciones) que permite acceder a datos de exposición y amenaza.
Contiene funciones para estimar impactos en población, por ejemplo, el desplazamiento de la población después de un desastre.	Proporciona métodos para generar las capas de exposición a partir de información global.
Contiene funciones para análisis de impactos socio económicos de los desastres.	Puede utilizar Google Earth Engine.
Contiene funciones para analizar la recuperación.	CLIMADA puede ejecutarse en el clúster Euler de la Universidad ETH Zurich, aunque la documentación no especifica claramente si personas ajenas a la universidad pueden hacer uso del clúster ni bajo qué requisitos.
Cuenta con herramientas web y a través del In-CORE lab es posible desarrollar y ejecutar código en el NCSA (National Center for Supercomputing Applications) cloud system.	Tiene un enfoque particular en la evaluación costo-beneficio de medidas de adaptación.
	El módulo *Unsequa* permite el análisis de incertidumbre y sensibilidad para los parámetros de amenaza, exposición, función de vulnerabilidad y medidas de adaptación.

- Libre, de código abierto.
- Flexible y adaptable a las necesidades del usuario.
- Funciona en el entorno de Python, por lo que puede combinarse con cualquier otra biblioteca.
- Los métodos desarrollados están respaldados por publicaciones con revisión de pares.

Tanto IN-CORE como CLIMADA han sido desarrolladas para el análisis probabilístico de riesgo, implementando diversos métodos de cuantificación de incertidumbre que han sido desarrollados y publicados por el Centro de Excelencia para la Planificación de Resiliencia Comunitaria Basada en Riesgo localizado en la Universidad del Estado de Colorado en el caso de IN-CORE y por la ETH de Zurich en el caso de CLIMADA. Las ventajas que se presentan en la **Tabla 7** no son compartidas por las demás herramientas evaluadas, lo que hace que estas se destaquen ampliamente. Sin embargo, ambas tienen desventajas. Ambas herramientas tienen su documentación desarrollada en inglés, lo que podría limitar su acceso en Latinoamérica, requiriéndose el desarrollo de material en español. Además, ambas requieren experiencia del usuario en Python, lo que hace que el perfil de usuario sea específico; además de ser un experto en la amenaza de análisis y cálculo de riesgo, se requiere capacidad para desarrollar código en Python. En el caso de IN-CORE, algunas de las funciones están basadas en información disponible en Estados Unidos, por lo que sería necesario realizar adaptaciones para otros contextos.

1.3. PLATAFORMAS PARA EL CÁLCULO DE RIESGO POR INUNDACIÓN



Imagen: Adobe Stock

Dentro de la revisión de literatura se encontraron plataformas desarrolladas en principio para analizar riesgo por inundación. Estas plataformas no muestran el grado de desarrollo y sofisticación de métodos encontrados en las plataformas IN-CORE y CLIMADA analizadas en la sección 2.2 y por lo tanto no serán comparadas en detalle en esta sección, aunque todas sus características junto con las otras plataformas pueden ser consultadas en el **Anexo A**.

Las herramientas que se revisaron son:

- **FloodRisk:** es un plugin para QGIS gratuito y de código abierto que proporciona una evaluación de las consecuencias de las inundaciones, incluyendo la pérdida de vidas humanas y los daños económicos directos. El plugin permite a los usuarios realizar una evaluación simple de riesgo considerando eventos fijos donde la probabilidad de cada uno se estima por separado y se calculan las consecuencias de manera determinista.

- **FloodRISE (Flood Resilience, Insurance, and Spatial Equity)** es un proyecto liderado por la Universidad de California, Irvine, que se enfoca en mejorar la resiliencia ante inundaciones mediante el desarrollo de simulaciones de amenaza de inundación de alta resolución. El proyecto tiene como objetivo proporcionar visualizaciones de riesgo de inundación que sean

útiles para la toma de decisiones locales, involucrando a las comunidades en el proceso de co-desarrollo de mapas de amenaza de inundación. FloodRISE utiliza simulaciones de amenaza de inundación a escala métrica para evaluar riesgos en diferentes tipos de inundaciones (costeras, fluviales, pluviales). El enfoque incluye la participación iterativa de las partes interesadas a través de reuniones, encuestas y sesiones de capacitación para desarrollar mapas de amenaza de inundación personalizados para cada comunidad.

- **Delft-FIAT (Flood Impact Assessment Tool)** es una herramienta desarrollada por el instituto de investigación Deltares que se utiliza para evaluar de manera rápida los impactos económicos directos causados por inundaciones en infraestructuras, edificios, y vías. Esta herramienta, de código abierto y basada en Python, es especialmente útil en la planificación de la adaptación climática, ya que permite modelar rápidamente los impactos de diferentes escenarios de inundaciones y las medidas de mitigación correspondientes. Delft-FIAT destaca por su capacidad de automatización y flexibilidad, lo que la convierte en una solución adaptable a diferentes necesidades de análisis.

- **HEC-FDA (Hydrologic Engineering Center - Flood Damage Reduction Analysis)** es una herramienta desarrollada por el Cuerpo de Ingenieros del Ejército de los Estados Unidos (USACE). Su principal objetivo es evaluar y cuantificar los daños económicos asociados con eventos de inundación, ayudando a la toma de decisiones en proyectos de reducción de riesgos por inundaciones. HEC-FDA emplea métodos probabilísticos para analizar la relación entre la frecuencia de inundaciones y los daños potenciales, permitiendo estimar beneficios y costos asociados con diferentes medidas de mitigación de riesgos.

De estas cuatro herramientas evaluadas, se destacan Delft-FIAT y HEC-FDA. La primera se destaca porque es un script que puede utilizarse de manera simple y efectiva para calcular los daños de escenarios que pueden ir desde unos pocos hasta cientos. Además, al ser un script de Python, puede integrarse en códigos más complejos según las necesidades del análisis. En el caso de HEC-FDA, uno de sus grandes aportes es que integra la evaluación del desempeño de las medidas de protección, como un dique, en el análisis de riesgo, evaluando la capacidad de los sistemas de protección y la probabilidad de su falla. La herramienta utiliza simulaciones de Monte Carlo para evaluar la incertidumbre de las funciones que describen la frecuencia de caudal, nivel de agua, daño por inundación, etc., y el funcionamiento del sistema de protección, generando una evaluación de riesgo probabilística. De Delft-FIAT no se identificó una ventaja que superara a IN-CORE o CLIMADA, aparte de su mayor sencillez, particularmente la posibilidad de usar esta herramienta a través de Excel. En el caso de HEC-FDA, el método implementado para integrar los sistemas de protección en la evaluación de riesgo constituye una ventaja frente a IN-CORE o CLIMADA. Sin embargo, en Latinoamérica, son pocos los análisis de riesgo que consideran estos sistemas, por lo que esta herramienta resultaría especialmente útil solo en situaciones donde sea necesario evaluar la incertidumbre asociada al funcionamiento de los sistemas de protección o implementar una metodología de cuantificación de incertidumbre de muestreo de curvas (para mayor detalle del método, ver **Anexo A**).

1.4. PLATAFORMAS PARA EL CÁLCULO DE RIESGO SÍSMICO


Imagen: Adobe Stock

En términos de plataformas que son exclusivamente para el cálculo de riesgo sísmico, la única herramienta que sobresalió de la revisión de literatura fue el OpenQuake Engine (https://www.globalquakemodel.org/product/openquake-engine), desarrollado por el Global Earthquake Model (GEM) Foundation. Otras herramientas populares que se utilizan en el ámbito de análisis sísmico, como R-CRISIS (http://www.r-crisis.com/) se excluyen de esta revisión, debido a que se enfocan en el componente de amenaza y no incorporan la exposición y vulnerabilidad para llevar a cabo estimaciones de riesgo sísmico.

La revisión de OpenQuake se llevó a cabo considerando los mismos criterios con los que se evaluaron las plataformas de riesgo multi-amenaza.

1.4.1. Accesibilidad

OpenQuake es un desarrollo de código abierto que se encuentra disponible en un repositorio público de GitHub (https://github.com/gem/oq-engine) bajo una licencia abierta AGPL v3.0. Su desarrollo es casi completamente llevado a cabo en el lenguaje Python, además, para cada lanzamiento de nuevas versiones se encuentran disponibles los ejecutables compilados para correr la plataforma en sistemas Windows, Mac y Linux.

1.4.2. Comunidad de desarrollo y soporte

En el caso de OpenQuake

La versión inicial de OpenQuake fue lanzada en el año 2013, lo que evidencia su estabilidad de desarrollo y sostenibilidad a lo largo del tiempo.

La plataforma cuenta con mantenimiento constante proporcionado por la Fundación GEM, que opera desde el año 2009. GEM recibe financiamiento de múltiples patrocinadores, lo que garantiza el soporte continuo del proyecto.

OpenQuake ha logrado consolidar una comunidad activa de usuarios y desarrolladores.

La comunidad interactúa a través de un foro público en línea (https://groups.google.com/g/openquake-users),: OpenQuake Users Forum. En este foro, los usuarios pueden hacer consultas sobre el funcionamiento de la plataforma, las cuales son respondidas tanto por el equipo de desarrolladores de GEM como por otros miembros de la comunidad.

1.4.3. Actualizaciones y mejora continua

OpenQuake

OpenQuake está en constante actualización, lo que garantiza mejoras continuas y nuevas funcionalidades. La plataforma posee un ciclo de desarrollo estructurado, incluyendo versiones con soporte a largo plazo (LTS - Long-Term Support). Las versiones LTS se mantienen estables durante varios años, facilitando su uso en proyectos sostenidos sin necesidad de actualizaciones frecuentes.

En paralelo, se desarrollan versiones experimentales que incorporan las últimas innovaciones técnicas. Este enfoque permite a los usuarios optar por estabilidad o funciones avanzadas, según sus necesidades específicas.

La última versión estable disponible al momento de redactar el informe es la 3.23 “Bellamy”, lanzada en febrero de 2025. Este lanzamiento refleja el compromiso constante del equipo desarrollador con la evolución y el mantenimiento de OpenQuake.

1.4.4. Interfaz gráfica

El OpenQuake Engine no posee una interfaz gráfica independiente, sin embargo, existe la posibilidad de instalar un plugin de QGIS (https://plugins.qgis.org/plugins/svir/) con el que se es capaz de correr los análisis de la plataforma, cuando ambos se encuentran instalados en el mismo sistema. El plugin no posee la funcionalidad completa del OpenQuake Engine, si no que se enfoca en las funciones más recurrentes para usuarios principiantes a intermedios. Al mismo tiempo, el esquema de desarrollo del plugin es diferente al de la plataforma y no posee el mismo ciclo de actualizaciones. Sin embargo, la existencia del plugin representa una gran ventaja ya que permite a usuarios familiarizarse con el uso de la plataforma de una manera gráfica, utilizando QGIS que es en sí mismo un sistema muy popular y de libre acceso.

1.4.5. Marco conceptual para la estimación del riesgo

El OpenQuake Engine posee un set de módulos de cálculo para llevar a cabo análisis de tipo probabilista, los cuales pueden considerar sólo estimaciones de amenaza o incorporar información de exposición y vulnerabilidad para calcular métricas de riesgo sísmico. Para la amenaza, la plataforma puede llevar a cabo la evaluación de eventos individuales o estimación de potencial de amenaza sísmica considerando múltiples fuentes (fallas sísmicas y funciones de magnitud-recurrencia), ya sea a través de la integración de las fuentes (identificado como método clásico en la documentación), o a través de la simulación de un set de eventos. La plataforma utiliza su propia definición de archivos de entrada para la definición de la amenaza (archivos XML para representar fallas y árboles lógicos), la exposición (archivos CSV) y la vulnerabilidad (archivos XML). En la documentación se presentan ejemplos para generar estos archivos en el formato correcto y la Fundación GEM hace disponibles archivos compatibles bajo licencias abiertas, que representan sus interpretaciones de cada componente para las mayores partes del mundo. Finalmente, la plataforma cuenta con comandos para obtener fácilmente productos y métricas de riesgo, como curvas de excedencia de pérdidas económicas, estimaciones de fatalidades promedio anuales, poblaciones desplazadas y otras métricas de carácter humanitario.



Imagen: Adobe Stock

1.5. CONCLUSIONES



Imagen: Adobe Stock

Las plataformas multi-amenaza IN-CORE y CLIMADA se destacaron en la evaluación realizada, ya que cumplen con una serie de criterios clave, como accesibilidad, soporte de la comunidad de desarrollo, disponibilidad del software, interfaz gráfica y un marco conceptual sólido para la estimación del riesgo. Superan a las demás plataformas evaluadas en estos aspectos y presentan ventajas que las posicionan a la vanguardia en el cálculo de riesgos para plataformas multi-amenaza.

En cuanto al cálculo de riesgo por inundación, se identificaron dos herramientas con ventajas destacables: Delft-FIAT, por su sencillez y flexibilidad, aunque sin superar las capacidades de IN-CORE o CLIMADA, y HEC-FDA, que resulta particularmente útil en casos donde se desee incluir en el análisis de riesgo el funcionamiento de los sistemas de protección.

En cuanto al cálculo de riesgo sísmico, la plataforma OpenQuake es la única que se encontró disponible en la literatura que cumple con los requisitos de código abierto requeridos para esta revisión. Sin embargo, la plataforma se destacó por cumplir con una serie de criterios claves y representa una excelente opción para ser utilizada con el fin de estimar métricas de riesgo sísmico.



SECCIÓN 2

Imagen: Adobe Stock

MÉTODOS DE INTELIGENCIA ARTIFICIAL EN EL CÁLCULO DE RIESGO

2.1. INTRODUCCIÓN

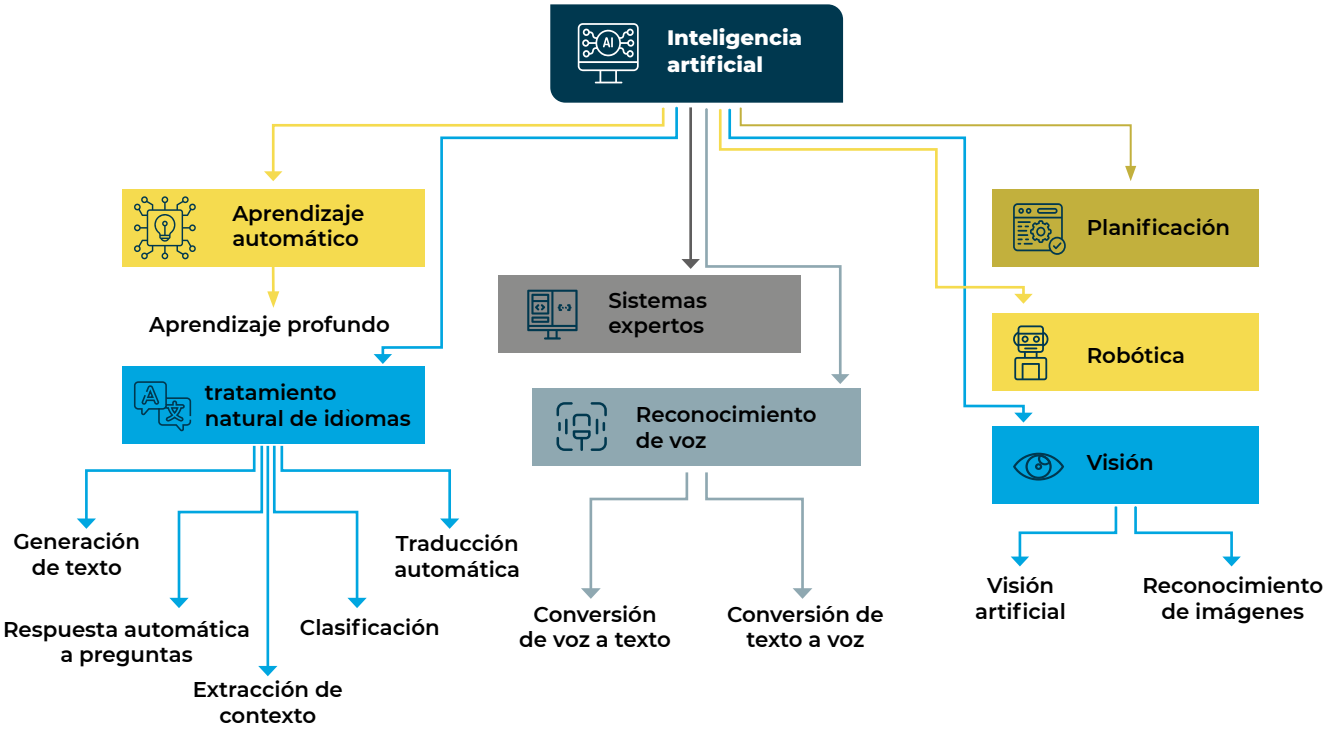


Imagen: Adobe Stock

La inteligencia artificial (IA) abarca actividades relacionadas con la informática que buscan desarrollar máquinas inteligentes capaces de realizar tareas que, tradicionalmente, requieren de la intervención humana (Abid et al. 2021). Según Mccarthy (2007), la IA es “la ciencia e ingeniería de crear máquinas inteligentes, especialmente programas de computadora inteligentes”.

Existen varias clasificaciones de la inteligencia artificial (IA), y una de ellas se muestra en la Figura 1, propuesta por Ivić (2019). En esta figura, las ramas de la IA incluyen el aprendizaje automático (Machine Learning o ML), el aprendizaje profundo (Deep Learning o DL), el procesamiento del lenguaje natural (Natural Language Processing o NLP), los sistemas expertos (Expert Systems o ES), así como la robótica, la visión por computadora y el reconocimiento de voz.

Figura 1. Ramas de la inteligencia artificial



Fuente: Ivić (2019).

El ML está presente en la mayoría de las aplicaciones de IA. Es una rama de la IA que permite a los sistemas aprender y mejorar a partir de la experiencia sin ser programados explícitamente (expert.ai 2024). Existen tres tipos principales de ML: supervisado, no supervisado y aprendizaje profundo (DL). Los algoritmos de aprendizaje automático que son entrenados por humanos basándose en datos preexistentes se llaman supervisados, mientras que aquellos que aprenden únicamente a partir de datos sin intervención humana se conocen como no supervisados (GFDRR 2018). El aprendizaje profundo utiliza redes neuronales artificiales inspiradas en el cerebro humano para procesar datos en múltiples capas de abstracción (GFDRR 2018; Ivić 2019).

El aprendizaje supervisado se divide en problemas de clasificación y de regresión. En la clasificación, el resultado esperado es una etiqueta o clase semántica. Los problemas de regresión, por otro lado, buscan predecir una variable continua. Existen diferentes tipos de algoritmos de aprendizaje supervisado, con arquitecturas a veces fundamentalmente distintas. El algoritmo más común para clasificación es la regresión logística, mientras que el más utilizado para regresión es la regresión lineal. Entre los algoritmos de clasificación más conocidos se encuentran los bosques aleatorios, el boosting de gradiente, las máquinas de soporte vectorial (SVM), los modelos bayesianos ingenuos y las redes bayesianas de boosting de gradiente (GFDRR 2018).

Una de las aplicaciones más comunes de ML no supervisado es el clustering, donde se agrupan muestras según su similitud. Otras aplicaciones incluyen la reducción de dimensionalidad y la detección de anomalías para reducir la varianza en un conjunto de datos y filtrar valores atípicos. Los métodos no supervisados se basan únicamente en los patrones de los datos, los cuales dependen de las características estadísticas de las muestras de entrada. Frecuentemente, los resultados de los algoritmos de aprendizaje no supervisado se introducen en algoritmos de aprendizaje supervisado, donde la intervención humana puede ayudar a alcanzar una mayor precisión en el conjunto de datos de manera más rápida. Existen tres tipos de aprendizaje automático no supervisado: el clustering K-means, el análisis de componentes principales (PCA) y el t-SNE (GFDRR 2018).

La **Tabla 8** muestra la clasificación de métodos de IA propuesta por Sun et al. (2020) incluyendo no solo los modelos supervisados, no supervisados y DL sino también el aprendizaje por refuerzo, aprendizaje profundo por refuerzo y optimización. El aprendizaje por refuerzo es un tipo de aprendizaje automático que se inspira en la psicología del comportamiento. En términos simples, el conjunto de datos de entrenamiento y las reglas en un algoritmo de aprendizaje automático no son decisiones binarias (sí o no), sino que buscan lograr un equilibrio entre la exploración de datos y la precisión. En otras palabras, se permite que el modelo cometa errores y explore los datos dentro de ciertos parámetros (GFDRR 2018).

Tabla 8. Clasificación de métodos de IA

Nombre del Método	Descripción	Usos
Modelos Supervisados	Algoritmos entrenados con datos etiquetados, donde se conocen tanto las entradas como las salidas. Utilizan métodos de regresión y clasificación para predecir resultados.	Reconocimiento de objetos en visión por computadora, extracción de información, reconocimiento de patrones y voz.
Modelos No Supervisados	Utilizan métodos estadísticos para encontrar estructuras ocultas en datos no etiquetados, basándose en las características inherentes de los datos.	Agrupación de datos (clustering), reducción de dimensionalidad, detección de datos anómalos, agregación de datos.
Aprendizaje Profundo (Deep Learning)	Algoritmos que utilizan múltiples capas para extraer características de datos de manera progresiva. Adecuado para problemas complejos que requieren gran capacidad de procesamiento.	Detección de movimiento, procesamiento de lenguaje natural (NLP), reconocimiento facial, predicción en transporte, etc.
Aprendizaje por Refuerzo	Algoritmos que aprenden mediante refuerzos (castigos y recompensas) para tomar decisiones en una secuencia de acciones. Se basan en procesos de decisión de Markov.	Robótica, control de tráfico, gestión de recursos en entornos complejos y cambiantes.
Aprendizaje Profundo por Refuerzo	Combina el aprendizaje por refuerzo con redes neuronales profundas para resolver tareas secuenciales complejas, optimizando las decisiones a largo plazo.	Visión por computadora, robótica, finanzas, gestión de redes inteligentes.
Optimización	Técnicas utilizadas en la mayoría de los métodos de IA para mejorar el rendimiento de los modelos, evaluando su desempeño mediante una función objetivo.	Optimización de modelos para la gestión de desastres, mejora de algoritmos de IA en varios dominios como planificación y logística.

Fuente: Sun et al.

Las metodologías de aprendizaje automático se están aplicando cada vez más en todos los campos, incluida la gestión del riesgo de desastres. Estas aplicaciones buscan mejorar el modelado del riesgo y la priorización de recursos durante la respuesta y reconstrucción. Se han empleado análisis de imágenes satelitales y enfoques de visión por computadora para comprender mejor la exposición física y socioeconómica, así como para identificar vulnerabilidades. Además, la inteligencia artificial está potenciando el modelado de amenazas mediante el uso de datos de sensores físicos y remotos, y ha avanzado en la predicción de daños. También se han desarrollado aplicaciones para priorizar recursos durante las fases de respuesta y recuperación, incluyendo la priorización de inspecciones, la minería de redes sociales y el monitoreo de la reconstrucción mediante visión por computadora (GFDRR 2018).

Jones et al. (2023) agruparon en 3 categorías los métodos de IA en relación con su aplicación a la avaluación de riesgo por inundación como se muestra en la **Tabla 9**, resaltando que estos pueden mejorar la eficiencia computacional de los modelos, permitiendo la cuantificación de incertidumbre aprovechando nuevos conjuntos de datos geoespaciales. Esto no solo optimiza el rendimiento de los modelos, sino que también aumenta la precisión de las predicciones y análisis, proporcionando mejores herramientas para la toma de decisiones y planificación en diversos contextos.

Tabla 9. Grupos de métodos de inteligencia artificial

Nombre del Método	Descripción	Ventajas	Desventajas
Modelado basado en datos	Se refiere al uso de técnicas de aprendizaje automático (ML) para crear modelos empíricos basados únicamente en datos observados. Estos modelos pueden abordar la falta de conocimiento científico o complejidad del sistema. Son útiles para predecir eventos específicos a nivel local al ajustar modelos físicos existentes. Ejemplos incluyen la predicción de riesgos de incendios y patrones de inundación.	Reduce costos computacionales y es ideal para adaptarse a condiciones locales.	Dificultad para interpretar los resultados (“caja negra”) y la necesidad de datos locales precisos.
Modelado sustituto	Consiste en entrenar un modelo de ML utilizando datos simulados, con el fin de reemplazar las simulaciones originales con versiones más eficientes y rápidas de ejecutar. Este enfoque es eficiente para realizar pruebas de calibración y análisis de sensibilidad, especialmente en situaciones donde las simulaciones son costosas.	Reduce el tiempo de simulación y el costo computacional. Puede aplicarse en calibraciones de modelos climáticos y predicciones de impacto.	La precisión puede disminuir si el modelo sustituto no captura todas las complejidades del original.
Explotación de big data geoespacial	Utiliza técnicas de IA y ML para analizar grandes cantidades de datos geoespaciales como imágenes satelitales o datos de sensores. Estos métodos son particularmente útiles en la detección automática de eventos climáticos extremos como inundaciones o incendios forestales.	Acelera el análisis de grandes volúmenes de datos y mejora la precisión en el mapeo de riesgos climáticos.	Requiere infraestructura computacional avanzada para manejar grandes volúmenes de datos, y la complejidad de los mismos puede ser un reto importante.

Fuente: Jones et al. (2023).

2.2. APLICACIONES DE LA IA EN LA GESTIÓN DE RIESGOS DE DESASTRES

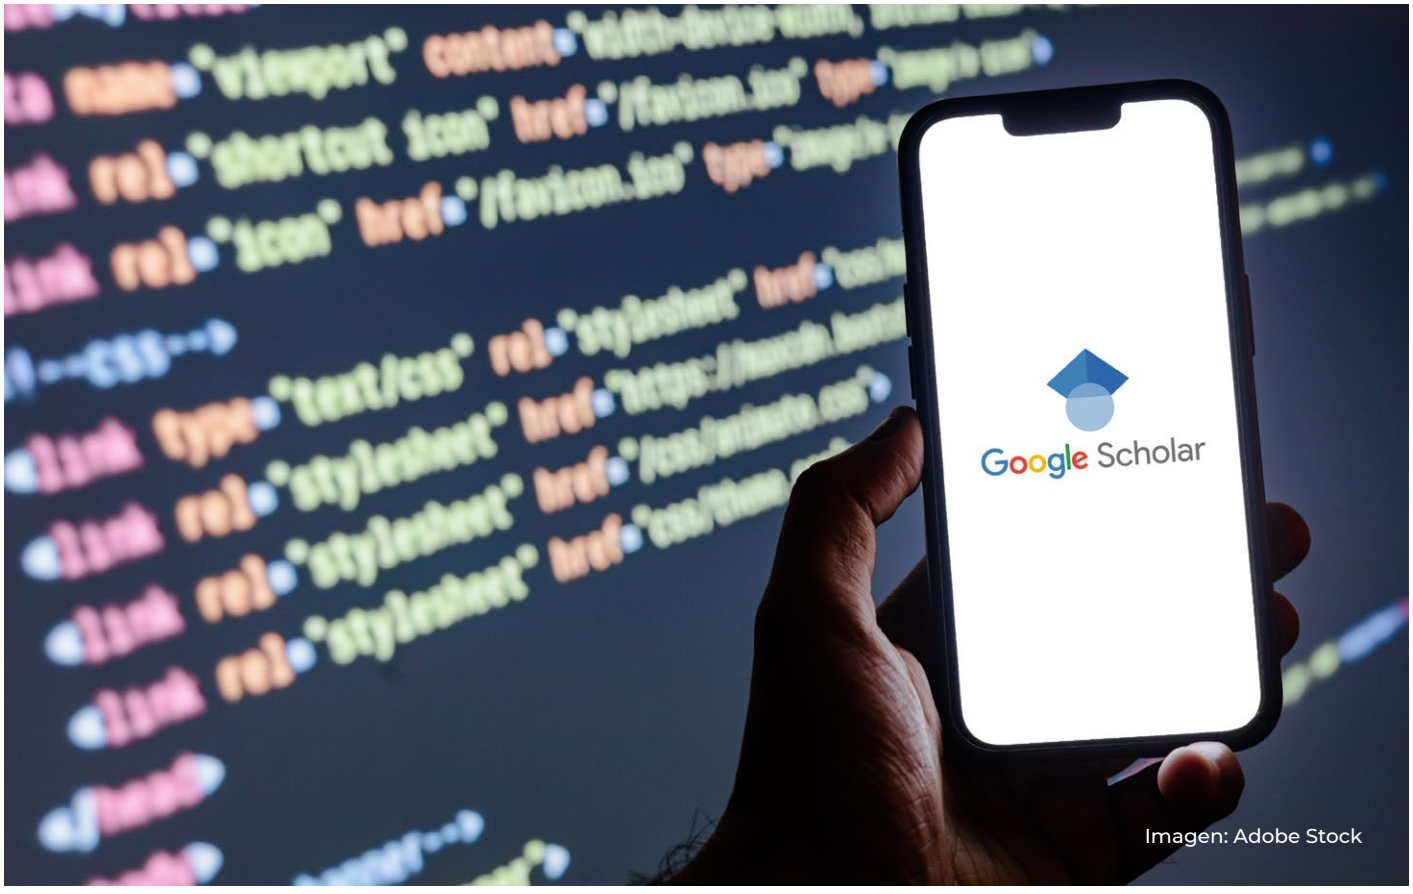


Imagen: Adobe Stock

Para ilustrar cómo se han aplicado diversos métodos de IA en la gestión de riesgos de desastres, Sun et al. (2020) identificaron un total de 26 métodos de inteligencia artificial y 17 áreas de aplicación representativas. Para realizar este análisis, se utilizaron los nombres de los métodos y áreas de aplicación como palabras clave en búsquedas en sitios web académicos como Google Scholar y Web of Science. Los resultados se presentan en la **Figura 2** que muestra las aplicaciones de los métodos de IA en las cuatro fases de la gestión de riesgos de desastres y sus subáreas. Cada línea sólida en la figura indica la presencia de aplicaciones en una determinada área. Las fases de mitigación y respuesta destacan por tener más líneas sólidas conectando con las áreas de aplicación, lo que sugiere un mayor número de estudios que aplican métodos de IA en estas fases.

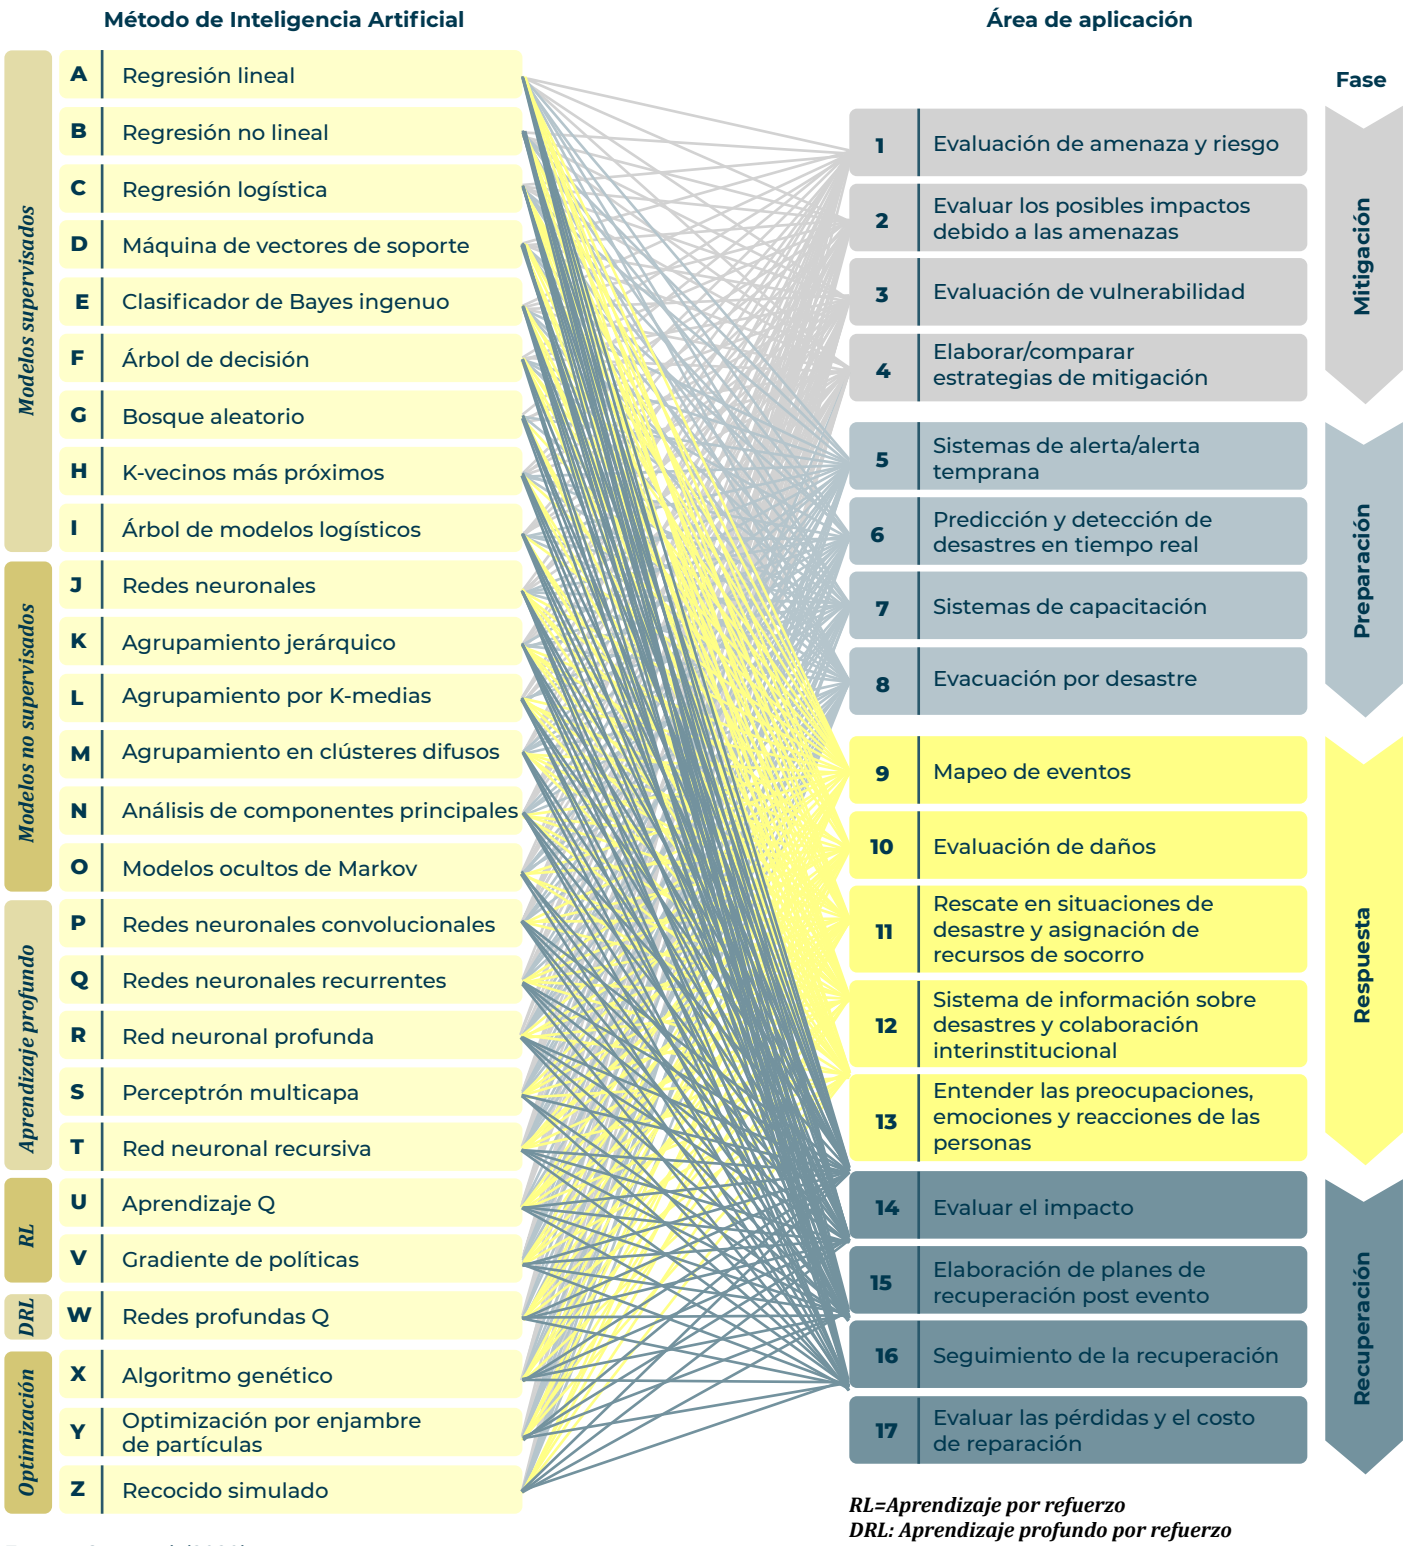
Los métodos de inteligencia artificial, como la regresión (lineal, no lineal y logística), se utilizan para evaluar amenazas y riesgos, así como para evaluar el impacto potencial de los desastres. Las máquinas de vectores de soporte también proporcionan pronósticos y evaluaciones de riesgos. Redes neuronales, agrupamiento jerárquico, k-means, agrupamiento difuso y análisis de componentes principales se han empleado para desarrollar y comparar estrategias de mitigación, sistemas de entrenamiento y procedimientos de evacuación en casos de desastres. Sin embargo, las técnicas de aprendizaje profundo (DL), como las redes neuronales convolucionales, redes neuronales profundas y perceptrón multicapa, se utilizan principalmente para el mapeo de riesgo. Además, las técnicas más recientes, como las redes Deep Q y los algoritmos genéticos, se han empleado para evaluar costos de pérdida y reparación (Abid et al. 2021).

Otro campo en el que la IA ha comenzado a desempeñar un papel fundamental en el modelado de riesgos de desastres, especialmente en el ámbito hidrológico e hidráulico, es la codificación asistida. Herramientas como ChatGPT y entornos de codificación asistidos por IA están revolucionando la forma en que los ingenieros y científicos de datos abordan la simulación y el análisis de modelos de riesgo. Estas herramientas permiten manipular archivos de modelos de manera eficiente, extraer datos relevantes y automatizar tareas complejas, lo cual resulta en un flujo de trabajo más ágil y eficiente (Australian Water School 2024).



Imagen: Adobe Stock

Figura 2. Métodos de inteligencia artificial y áreas de aplicación en la gestión de riesgos de desastre



RL=Aprendizaje por refuerzo
DRL: Aprendizaje profundo por refuerzo

Fuente: Sun et al. (2020).

2.2.1. Mitigación y preparación ante desastres

Los métodos IA se han utilizado ampliamente en la evaluación de amenazas y riesgos. Entre ellos, los modelos supervisados y no supervisados son los más comunes, mientras que el aprendizaje por refuerzo y el DL son métodos más recientes y emergentes. Las técnicas tradicionales de identificación de riesgos pueden ser laboriosas y presentar altas tasas de falsos positivos, lo que hace que las técnicas de IA sean particularmente útiles para analizar grandes volúmenes de datos de manera más rápida y eficiente (Sun et al. 2020). La evaluación de amenaza es la etapa más estudiada por los académicos, empleando métodos como sistemas evolutivos (ES), redes neuronales artificiales (ANN), lógica difusa (FL), máquinas de soporte vectorial (SVM) y sistemas adaptativos neuro-difusos (ANFIS). La investigación se centra en la evaluación de riesgos de desastres, el monitoreo y la alerta temprana, abarcando inundaciones, terremotos, movimientos en masa y otras amenazas (Tan et al. 2020).

Diversos estudios han demostrado que la IA puede evaluar amenazas mediante el análisis de datos. Por ejemplo, se han utilizado métodos de árboles de decisión, visión por computadora, aprendizaje profundo y aprendizaje automático para analizar inundaciones, movimientos en masa, e incendios forestales. Estas técnicas han demostrado ser eficaces en la elaboración de mapas de amenaza y en el pronóstico de eventos.

Las técnicas de IA también se aplican para estimar los posibles impactos, evaluar la vulnerabilidad y predecir daños estructurales a través de curvas de fragilidad. Aunque hay menos aplicaciones de IA en la estimación de impactos y la evaluación de vulnerabilidades en comparación con la evaluación de amenazas, estas herramientas son promisorias para desarrollar estrategias de mitigación más efectivas. Además, las técnicas de IA pueden ayudar a identificar prioridades de gestión y optimizar los planes de respuesta. De otro lado, la investigación sobre el uso de IA para comparar estrategias de mitigación aún es limitada (Sun et al. 2020).



Imagen: Adobe Stock

Uno de los principales beneficios de la IA es su capacidad para analizar grandes volúmenes de datos de manera rápida y precisa. Esto la convierte en una herramienta invaluable para identificar las áreas más vulnerables a los efectos del cambio climático, como zonas propensas a inundaciones, movimientos en masa o sequías. Al analizar datos como modelos climáticos, imágenes satelitales y patrones meteorológicos, los gobiernos y las comunidades pueden desarrollar planes de adaptación específicos para cada riesgo. La IA facilita el acceso a información, lo que permite diseñar estrategias de adaptación ante el cambio climático (Jain et al. 2023).

Desde la perspectiva de la gestión de **inundaciones**, los estudios se centran en cuatro aspectos principales: evaluación de riesgos de inundación, pronóstico de niveles y caudales, modelado de lluvia-escorrentía y análisis de frecuencia de inundaciones (Tan et al. 2020). En cuanto al pronóstico de niveles y caudales, se han empleado tanto métodos únicos como híbridos siendo los híbridos aquellos que combinan diferentes enfoques para mejorar la precisión y el alcance de las evaluaciones. Además, en el modelado del proceso de lluvia-escorrentía, se han empleado diversas metodologías para simular flujos en cuencas, destacando estudios que integran algoritmos de optimización. Aunque el análisis de frecuencia de inundaciones aún tiene un desarrollo limitado, algunas investigaciones han comenzado a abordar este tema utilizando redes neuronales y regresiones de soporte vectorial para estimar cuantiles de inundación en áreas específicas (Tan et al. 2020).

En la revisión de literatura realizada por Bentivoglio et al. (2022) se encontró que los métodos de perceptrón multicapa (MLP) y las redes neuronales convolucionales (CNN) fueron los tipos de modelos de aprendizaje profundo más comunes en la cartografía de inundaciones, mientras que las redes neuronales recurrentes (RNN) se utilizaron con menos frecuencia. Para superar su falta de sesgos inductivos y lograr buena precisión, los MLP suelen combinarse con otras técnicas estadísticas. Por otro lado, gracias a sus sesgos inductivos espaciales y temporales, se encontró que las CNN y las RNN superan regularmente a otros modelos. Independientemente de la aplicación, los resultados muestran que las soluciones de aprendizaje profundo superan a los enfoques tradicionales y a otras técnicas de aprendizaje automático. Los modelos de aprendizaje profundo utilizados para modelado sustituto ofrecen una aceleración significativa (hasta 3 órdenes de magnitud) manteniendo una precisión suficiente (Bentivoglio et al. 2022). Un ejemplo de aplicación de modelos de aprendizaje profundo en la evaluación de amenaza por inundación es el trabajo de McSpadden et al. (2023) que compararon modelos de inundación pluvial sustitutos mostrando las ventajas del aprendizaje profundo (DL) para cuantificación de incertidumbre manteniendo altos niveles de precisión y mostrando su alto potencial en la gestión de riesgo de desastres.

La modelación y proyecciones climáticas apoyadas por IA se refieren al uso de técnicas para mejorar la precisión y confiabilidad de estos modelos. La modelación climática utiliza simulaciones para comprender cómo factores como las emisiones de gases de efecto invernadero afectan el clima de la Tierra con el tiempo. A partir de estos modelos, se realizan proyecciones para predecir cambios climáticos futuros. La IA puede analizar grandes volúmenes de datos de diversas fuentes, como imágenes satelitales y patrones climáticos, para identificar tendencias y patrones no evidentes mediante métodos

tradicionales, lo que ayuda a reducir incertidumbres en las simulaciones y predicciones climáticas. Existen varias técnicas de IA que pueden aplicarse, como algoritmos de aprendizaje automático y redes neuronales. Los beneficios de la modelación climática apoyada por IA incluyen una mayor precisión, un análisis más rápido y eficiente de los datos climáticos, y una mejor comprensión de los impactos potenciales del cambio climático en diferentes regiones y ecosistemas. Esta información es crucial para informar decisiones políticas y guiar los esfuerzos de adaptación y mitigación frente al cambio climático. Ejemplos de sistemas de modelación y proyección climática apoyados por IA incluyen Google Earth Engine, Climate.ai, IBM Watson y Microsoft Azure como se muestra en la **Tabla 10** (Jain et al. 2023).

Tabla 10. Sistemas de modelación y proyección climática apoyados por IA

Sistema de IA	Función	Referencia
Climate.ai	Utiliza IA para analizar datos climáticos y generar escenarios probabilísticos de cambio climático para modelado y proyecciones futuras	Dewitte et al. (2021)
DeepMind	Utiliza IA para mejorar la precisión del modelado climático al reducir incertidumbres en simulaciones y predicciones climáticas	Subramaniam et al. (2022)
Google Earth	Utiliza IA para analizar datos satelitales y generar modelos climáticos y proyecciones de alta resolución	Yang et al. (2022)
Engine IBM Watson	Utiliza IA para generar proyecciones climáticas y evaluar los riesgos de impactos climáticos en infraestructura y cadenas de suministro	Yigitcanlar et al. (2020)
Microsoft Azure	Utiliza IA para crear modelos climáticos y proyecciones de alta resolución utilizando datos satelitales y algoritmos de aprendizaje automático	Khan et al. (2023)

Fuente: H. Jain et al. (2023).

Además, los modelos climáticos basados en IA permiten a los responsables de políticas anticipar impactos y diseñar estrategias. Por ejemplo, los sensores y drones impulsados por IA permiten monitorear y analizar en tiempo real los impactos de eventos climáticos extremos, mejorando la respuesta y gestión de sus efectos. De manera similar, los algoritmos de aprendizaje automático ayudan a crear modelos predictivos sobre el cambio climático, lo que permite a los tomadores de decisiones planificar y tomar medidas proactivas para proteger comunidades y empresas (Jain et al. 2023).

La **Tabla 11** presenta varios proyectos y modelos que utilizan técnicas de IA para abordar diferentes aspectos relacionados con el análisis de **inundaciones y el impacto del cambio climático** en la infraestructura costera. Cada proyecto se caracteriza por la tecnología que utiliza, su objetivo principal y los tipos de datos que analiza. Por ejemplo, CoastalDEM (Kulp y Strauss 2018), se centra en la creación de modelos digitales de elevación para identificar áreas expuestas a inundaciones costeras. Además, proyectos como CoastalAI y Deltares (Jain et al. 2023) utilizan IA para simular el impacto del aumento del nivel del mar en la infraestructura, lo que permite desarrollar estrategias de adaptación que protejan a las comunidades y a las infraestructuras en riesgo. En general, estas iniciativas muestran cómo la IA puede ser una herramienta poderosa para mejorar la resiliencia ante los desafíos climáticos.

Tabla 11. Ejemplos de proyectos que utilizan IA en análisis de inundaciones y cambio climático

Proyecto/ Modelo	Tecnología Utilizada	Objetivo	Datos Analizados	Resultados Esperados
CoastalDEM	Redes neuronales	Crear mapas de elevación de alta resolución	Imágenes satelitales, datos de elevación	Identificación de áreas en riesgo
DeepSD	Aprendizaje profundo	Predecir cambios en patrones climáticos	Datos de modelos climáticos	Predicciones sobre temperatura y precipitación a escala regional
Climate Informatics Toolbox	Aprendizaje automático	Proporcionar herramientas para analizar datos climáticos	Datos de modelos climáticos	Identificación de patrones y tendencias en datos climáticos
CoastalAI	Aprendizaje automático	Simular impacto del aumento del nivel del mar en infraestructura	Datos climáticos y de infraestructura	Estrategias de adaptación para proteger comunidades vulnerables
Deltares	Aprendizaje automático	Simular impacto del aumento del nivel del mar en infraestructura	Datos climáticos y de infraestructura	Estrategias de adaptación para proteger comunidades vulnerables

Fuente: H. Jain et al. (2023).

La IA se puede utilizar para desarrollar **sistemas de alerta temprana para eventos climáticos** como huracanes e inundaciones, permitiendo a las comunidades prepararse y evacuar antes de que ocurra el desastre. El aprendizaje automático, en particular, permite predecir inundaciones mediante el análisis de datos históricos y la detección de patrones que indiquen la posibilidad de inundación (ver **Tabla 13** y **Caja 1** para ejemplos de aplicación en sistemas de alerta temprana). Al analizar variables como patrones climáticos, niveles de agua y otras variables relevantes, los algoritmos pueden estimar la probabilidad de inundaciones y emitir alertas tempranas a las personas en riesgo, facilitando una respuesta rápida

y efectiva (Jain et al. 2023). En particular, la IA ha demostrado ser esencial para mejorar la precisión y la cobertura de los pronósticos de inundaciones. Por ejemplo, modelos basados en redes neuronales como LSTM (Long Short-Term Memory) están siendo utilizados para predecir inundaciones en tiempo real, incluso en cuencas no calibradas, donde la falta de datos hace que los pronósticos sean tradicionalmente menos precisos. Estos modelos pueden integrar múltiples fuentes de datos y generar simulaciones confiables de eventos extremos, lo que es crucial para la gestión del riesgo de desastres (Nevo et al. 2022; Gegenleithner et al. 2024; Zhu et al. 2023).

Un ejemplo del uso de IA en sistemas de alerta temprana de inundaciones a nivel operativo es el sistema de Google, que ha demostrado su efectividad ayudando a comunidades vulnerables a prepararse y responder ante inundaciones. El sistema de Google fue desarrollado para proporcionar alertas en tiempo real sobre inundaciones fluviales en grandes ríos monitoreados (ver **Caja 1** para más información sobre este sistema). Operativo desde 2018, ha expandido su cobertura geográfica y actualmente se compone de cuatro subsistemas: validación de datos, pronóstico de niveles, modelado de inundación y difusión de alertas. La inteligencia artificial se utiliza en el pronóstico de niveles y el modelado de la inundación, empleando redes LSTM y modelos lineales para predecir niveles y para calcular la extensión y profundidad de la inundación. Durante el monzón de 2021, el sistema operó en India y Bangladesh, cubriendo una región de 470,000 km² y enviando más de 100 millones de alertas a la población afectada y a autoridades pertinentes (Nevo et al. 2022).

En el campo de los **movimientos en masa** la IA se está utilizando en tres áreas clave: la detección, la evaluación de la susceptibilidad y amenaza, y la predicción del desplazamiento de movimientos en masa con resultados muy promisorios. Por ejemplo, Akosah et al. (2024) concluyeron que los algoritmos de aprendizaje automático y aprendizaje profundo y las tecnologías de teledetección evalúan razonablemente el mapeo de susceptibilidad a movimientos en masa, con una precisión de predicción que varía entre el 56 % y casi el 100 %. He et al. (2024) condensaron sus conclusiones sobre las técnicas de IA más utilizadas en las áreas de desarrollo mencionadas en el diagrama que se muestra en la **Figura 3**.



Imagen: Adobe Stock

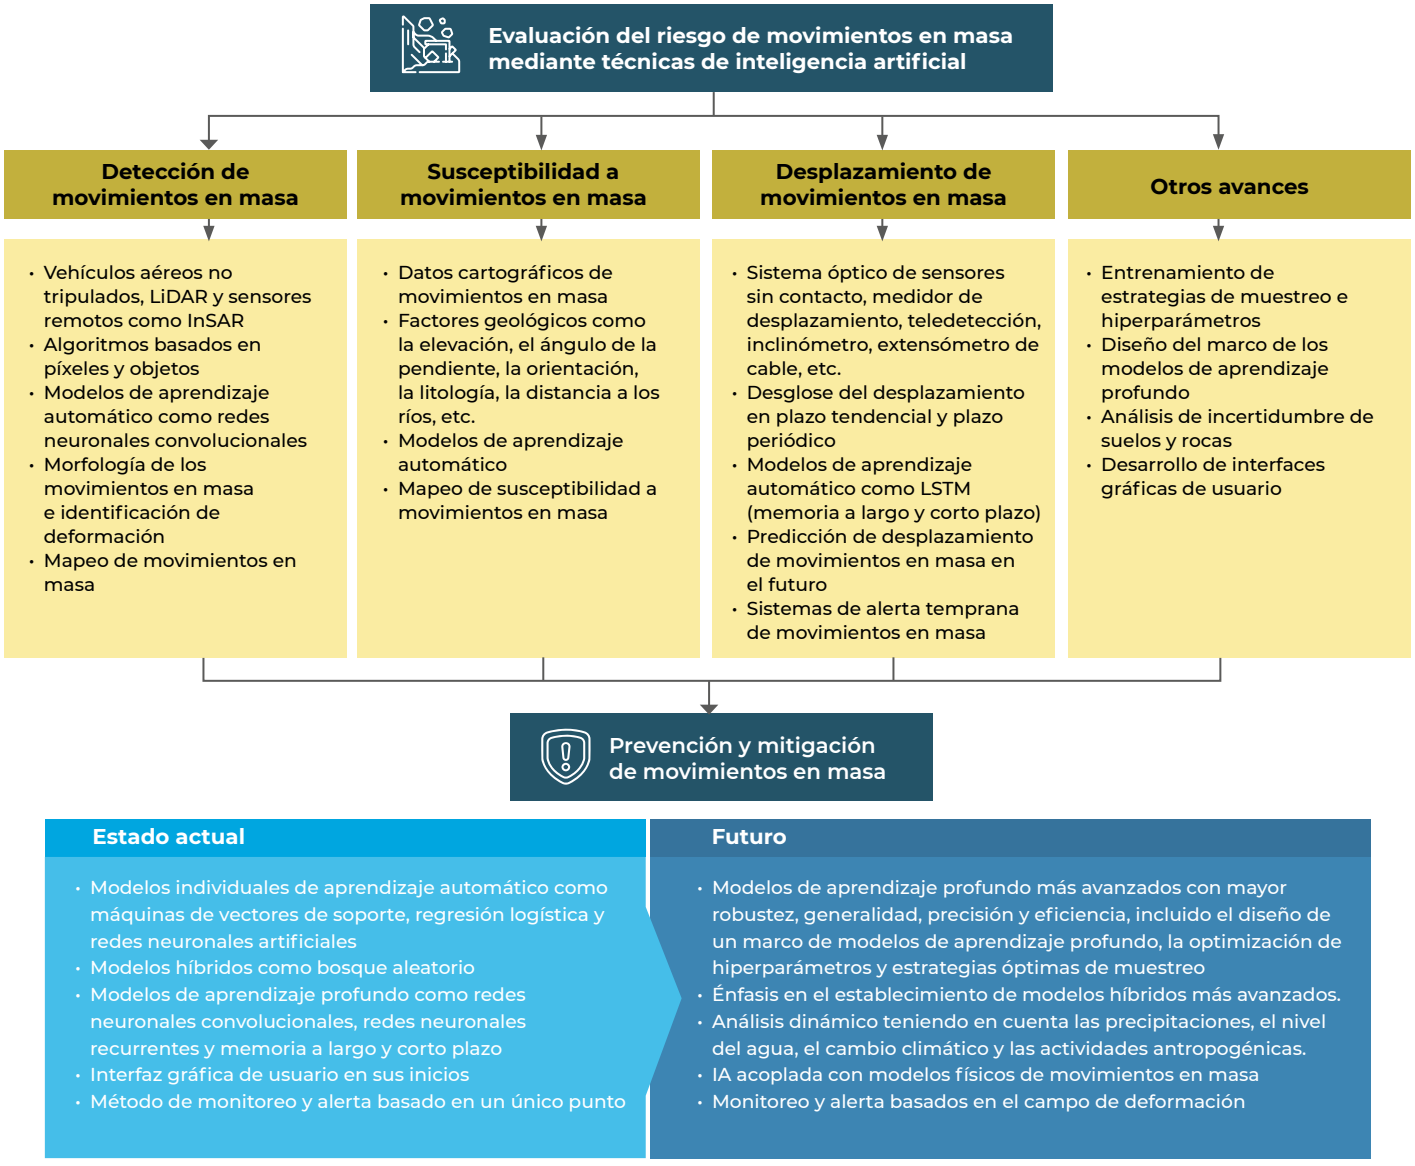
La detección de movimientos en masa consiste en identificar y mapear los eventos que ya han ocurrido en una región, proporcionando información clave como su ubicación, tipo, volumen y fecha. Tradicionalmente, esto se hacía mediante la interpretación visual de imágenes de sensores remotos y fotografías aéreas, lo cual era costoso, consumía mucho tiempo y estaba sujeto a sesgos de interpretación. La IA ha facilitado la automatización de este proceso, utilizando tecnología de reconocimiento de imágenes que puede identificar los movimientos en masa con mayor precisión y eficiencia, reduciendo la dependencia de la interpretación humana y mejorando la objetividad y reproducibilidad (He et al. 2024).

En la evaluación de la susceptibilidad y amenaza de movimientos en masa, la IA ayuda a determinar la probabilidad de ocurrencia en una región específica. Esta evaluación se basa en factores como la altitud, pendiente, tipo de suelo, distancia a ríos y vías, entre otros. Tradicionalmente, se utilizaban métodos estadísticos y conocimiento de expertos que dependían de la experiencia práctica. Con la IA, se utilizan modelos de aprendizaje automático (ML) para mapear la susceptibilidad de manera más objetiva y eficiente, eliminando factores de influencia altamente correlacionados y reteniendo aquellos que sean menos correlacionados (He et al. 2024). En el caso de los métodos únicos, se han realizado análisis de factores desencadenantes, clasificadores estadísticos (regresión logística y modelo aditivo generalizado) junto con técnicas de aprendizaje automático como RF y SVM (Tan et al. 2020). Por otro lado, los métodos híbridos integran diferentes enfoques para ofrecer una evaluación más completa. Dentro de estos enfoques se han utilizado redes neuro-difusas y modelos de aprendizaje automático, como la máxima entropía, SVM y ANN, para realizar simulaciones espaciales (Tan et al. 2020).

Un ejemplo de la aplicación de la visión por computadora en la evaluación del riesgo de movimientos en masa es el proyecto Landslide Reporter (NASA 2024), que utiliza la recopilación de datos a través de la participación del público y el aprendizaje automático para identificar áreas en riesgo de movimientos en masa a partir de imágenes satelitales. Este proyecto ha sido exitoso en la identificación de eventos de movimientos en masa y podría ayudar a las comunidades a tomar medidas proactivas para mitigar los impactos potenciales (Prakash et al. 2021; Shameem Ansar et al. 2022; Jain et al. 2023).


Imagen: Adobe Stock

Figura 3. Prácticas actuales y futuro de la aplicación de IA en la evaluación de susceptibilidad y amenaza por movimientos en masa



Fuente: He et al. (2024).

En cuanto a la predicción del desplazamiento de movimientos en masa; la IA, en particular el aprendizaje profundo (DL), se está utilizando para predecir el movimiento futuro de movimientos en masa existentes. Los modelos de redes neuronales, como las redes convolucionales (CNN) y las redes neuronales recurrentes (RNN), han demostrado ser útiles en este aspecto. Aunque el aprendizaje profundo aún se encuentra en desarrollo en esta área, ya se ha comprobado que proporciona resultados de mayor precisión que los métodos de aprendizaje automático convencionales (He et al. 2024).

La **Tabla 12** resume los métodos identificados por He et al. (2024) como los de mejor funcionamiento en el campo de los movimientos en masa.

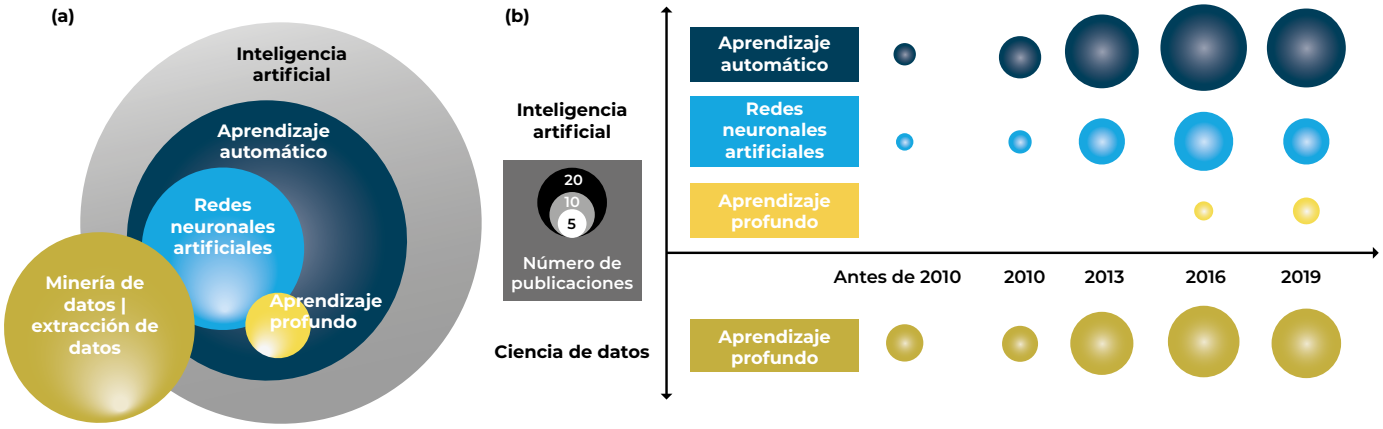
Tabla 12. Modelos con el mejor funcionamiento para cada aplicación en movimientos en masa

Campo	Modelos con mejor desempeño
Detección de movimientos en masa	Máquina de vectores de soporte, red neuronal convolucional, red neuronal recurrente y modelos híbridos relacionados
Mapeo de susceptibilidad y amenaza a movimientos en masa	Máquina de vectores de soporte, regresión logística, bosque aleatorio, red neuronal convolucional, red neuronal recurrente y modelos híbridos relacionados
Predicción de desplazamiento de movimientos en masa	Memoria a corto y largo plazo, transformer y modelos híbridos

Fuente: He et al. (2024).

En el área de la **gestión del riesgo sísmico** la IA está revolucionando el mapeo de riesgos al permitir análisis más precisos y dinámicos. Al procesar grandes volúmenes de datos y reconocer patrones, la IA puede refinar los modelos de amenaza, ofreciendo mapas que se actualizan en tiempo real a medida que surgen nuevos datos (Plevris 2024). Se han utilizado tanto métodos únicos como híbridos. En el caso de los métodos únicos, se han empleado sistemas evolutivos para predecir el nivel de riesgo potencial de los edificios debido a amenaza sísmica, redes neuronales y tecnologías de aprendizaje profundo. Por otro lado, los métodos híbridos combinan diferentes enfoques para ofrecer evaluaciones más robustas. Por ejemplo, se han generado sistemas de inferencia basados en SVM evolutivo para integrar modelos de IA (Tan et al. 2020). La Figura 4 (a) muestra una ilustración de la interrelación entre técnicas de IA y ciencia de datos en sismología. Los algoritmos de aprendizaje automático, como redes neuronales artificiales (ANN), programación genética (GP), mapas autoorganizados (SOM), máquinas de vectores de soporte (SVM) y árboles de decisión (DT), se utilizan para entrenar y encontrar determinaciones implícitas para eventos sísmicos. El aprendizaje profundo, uno de los algoritmos más avanzados en el ámbito del aprendizaje automático, emplea el concepto de redes neuronales artificiales (ANN) para aprender representaciones generalizadas de conjuntos de datos en diferentes dominios y definir relaciones no lineales complejas entre variables. Las capacidades sobresalientes del aprendizaje automático en conjuntos de datos secuenciales lo convierten en una opción óptima para el problema de la asociación de fases en sismología, adecuado para el análisis en tiempo real de redes sísmicas (Jiao y Alavi 2020). La **Figura 4** (b) resume los estudios basados en IA publicados en sismología entre 1999 y 2019, mostrando que las ANN son los métodos de aprendizaje automático más utilizados en este campo, con un creciente interés en el uso de técnicas de aprendizaje profundo (Jiao y Alavi, 2020).

Figura 4. Estudios existentes de IA y ciencia de datos en sismología. (a) Ilustración de la interrelación entre las técnicas de IA y ciencia de datos en sismología. (b) Resumen de los estudios basados en IA publicados en sismología durante 1999-2019

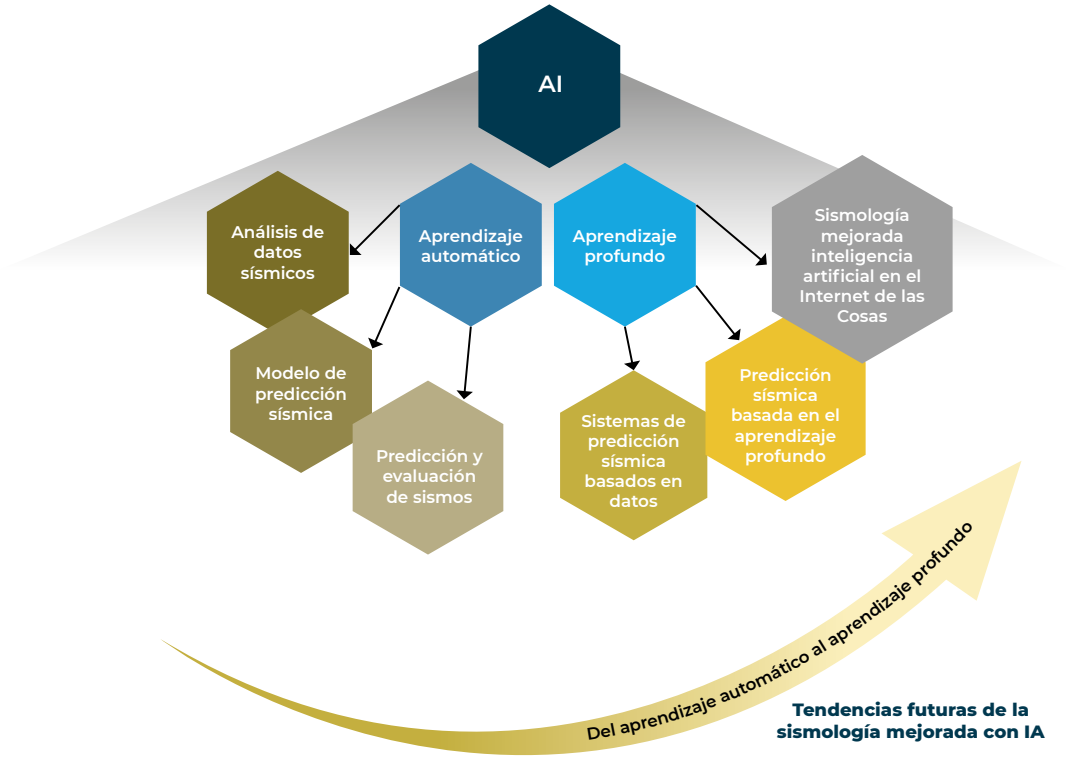


Fuente: Jiao y Alavi (2020).

Los enfoques de aprendizaje supervisado y no supervisado han atraído una considerable atención en la investigación de algoritmos de IA aplicados a la sismología. Aunque la investigación sísmica basada en aprendizaje automático (ML) se ha centrado principalmente en el uso de métodos de aprendizaje supervisado, es probable que los métodos de aprendizaje no supervisado desempeñen un papel crucial en la sismología en el futuro cercano (Jiao y Alavi 2020). **La Figura 5** muestra la perspectiva del análisis sísmico basado en IA y destaca el aprendizaje profundo (DL) como una de las tendencias futuras para los modelos de predicción sísmica. Según Jiao y Alavi (2020), aunque los sistemas sísmicos desarrollados con métodos de DL aún están en sus inicios, el mayor avance en la sismología mejorada con IA probablemente se logrará mediante la combinación del DL con razonamiento complejo



Figura 5. Perspectiva y tendencias futuras de la sismología mejorada con IA, desde el Aprendizaje Automático (ML) hasta el Aprendizaje Profundo (DL)



Fuente: Jiao y Alavi (2020).

En el tema de los sistemas de alerta temprana de sismos la integración de la IA promete revolucionar estos sistemas al tener el potencial de mejorar su precisión y rapidez. Un ejemplo, de un sistema de alerta temprana de sismos basado en IA es DeepShake, desarrollado por investigadores de la Universidad de Stanford (Datta et al. 2022). Este sistema utiliza redes neuronales espaciotemporales profundas para mejorar la detección de sismos. Durante el terremoto de magnitud 7.1 que afectó a Ridgecrest el 5 de julio de 2019, DeepShake emitió alertas específicas a todas las estaciones dentro de su red 5 segundos antes de la llegada de las ondas sísmicas con una intensidad superior a MMI IV (Plevris 2024). Otro ejemplo es el sistema EarthX, en el cual investigadores utilizaron tecnología de IA para desarrollar un sistema de monitoreo de sismos en tiempo real, capaz de procesar simultáneamente datos de más de 100 estaciones sísmicas en las regiones de Sichuan y Yunnan, en el Sitio Experimental de Sismos de China. Este sistema cuenta con detección y recogida automática de fases sísmicas (Zhang et al. 2020).

El diseño sismorresistente enfrenta limitaciones debido a la creciente complejidad de las estructuras modernas y la variabilidad de las condiciones sísmicas. Aquí es donde la IA desempeña un papel crucial, al ofrecer herramientas avanzadas para procesar grandes volúmenes de datos y optimizar sistemas complejos de manera más eficiente. Esto resulta en soluciones de diseño innovadoras que equilibran seguridad, costos y sostenibilidad. La IA está revolucionando este campo mediante simulaciones que

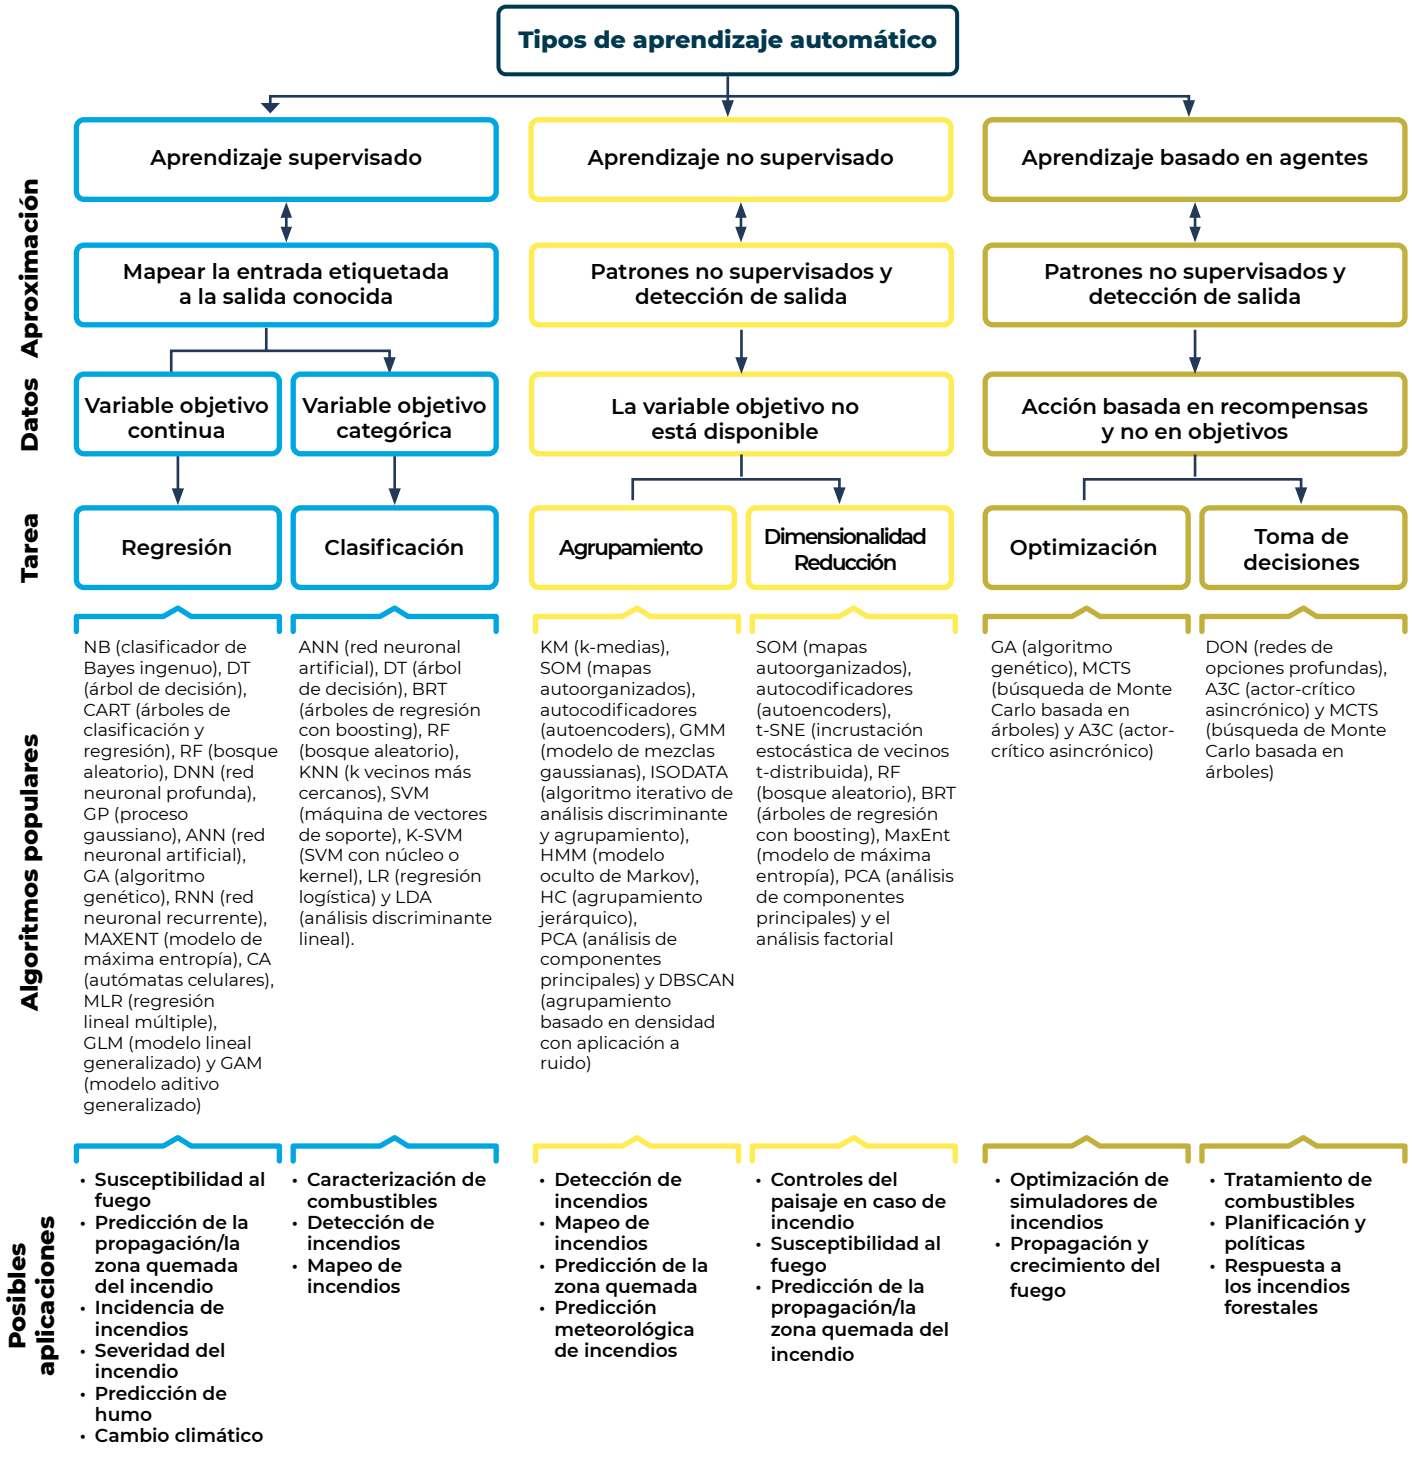
mejoran la disipación de energía en distintos escenarios sísmicos, y optimizan materiales y formas estructurales, logrando reducciones de costos de entre el 18 y el 26% gracias al uso de grandes conjuntos de datos (Plevris 2024). Además, la IA facilita el desarrollo de diseños generativos, que ofrecen múltiples opciones para que los ingenieros exploren alternativas innovadoras que optimizan el rendimiento sísmico mientras reducen el uso de materiales y costos de construcción. A futuro, la integración de la IA en el diseño resistente a terremotos promete transformar la construcción y el mantenimiento de estructuras en regiones sísmicamente activas, proporcionando soluciones personalizadas que consideran factores locales y contextuales (Datta et al. 2022).

En el caso de los **incendios**, P. Jain et al. (2020) proponen la clasificación de métodos de ML que se muestra en la **Figura 6**, encontrando que la aplicación de métodos de aprendizaje automático (ML) en la ciencia y gestión de incendios forestales ha crecido desde los años 90, utilizando principalmente métodos tradicionales como Bosques Aleatorios (RF), Máquinas de Soporte Vectorial (SVM) y Redes Neuronales (ANNs), debido a su simplicidad e interpretabilidad. Sin embargo, áreas clave como la analítica predictiva y prescriptiva han recibido menos atención, lo que abre oportunidades para aplicar ML en la optimización de la gestión de incendios. Además, el aumento de datos espacio-temporales, como los de sensores remotos, favorece el uso de aprendizaje profundo (DL) y aprendizaje basado en agentes para mejorar la eficiencia y precisión en la gestión de incendios. El uso de DL ha mostrado grandes capacidades como muestran Bjånes et al. (2021) en una aplicación desarrollada en dos áreas de Chile encontrando que este método puede generar mapas de susceptibilidad a los incendios con métricas de funcionamiento muy altas en comparación con otros métodos.



Imagen: Adobe Stock

Figura 6. Diagrama que muestra los principales tipos de aprendizaje automático (ML), tipos de datos y tareas de modelado en relación con algoritmos populares y posibles aplicaciones en la ciencia y gestión de incendios forestales.



Fuente: P. Jain et al., (2020).

La **Tabla 13** presenta una recopilación de casos en los que se han aplicado métodos IA para evaluar la amenaza, vulnerabilidad y riesgo en diversos contextos. Los ejemplos abarcan desde la detección de vulnerabilidad sísmica en edificaciones mediante imágenes satelitales y algoritmos de aprendizaje profundo, hasta el monitoreo del crecimiento urbano con redes neuronales convolucionales. Cada caso incluye detalles como el objetivo del proyecto, datos de entrada, unidad de análisis, algoritmos utilizados y un resumen de los resultados obtenidos. Esta diversidad de aplicaciones resalta el potencial de la IA para mejorar la precisión y eficiencia en la evaluación de riesgos, abordando problemáticas complejas como inundaciones, pobreza, huracanes y movimientos en masa, al tiempo que ofrece información crítica para la gestión de riesgos de desastres y la planificación urbana.

Tabla 13. Casos de aplicación de métodos de IA en la evaluación de amenaza, vulnerabilidad y riesgo

Nombre del Projecto y fuente	Descripción	Objetivo	Datos de entrada	Unidad de análisis	Algoritmo usado	Resumen de resultados
Vulnerabilidad sísmica de edificaciones en la ciudad de Guatemala (GFDRR 2018)	Detección de la vulnerabilidad sísmica de edificios en áreas urbanas de la Ciudad de Guatemala, utilizando imágenes de satélite, drones y vistas de calles en 360° para identificar hogares de alto riesgo de colapso durante un sismo.	Identificar rápidamente los hogares con vulnerabilidad sísmica.	Imágenes de drones (eBee, RGB, 4 cm), datos de elevación en nube de puntos, imágenes de vistas de calles (Trimble MX, 30 megapíxeles), capa de carreteras de OpenStreetMap	Píxel/ objeto (edificio)	Aprendizaje profundo	El método permitió examinar 5,000 viviendas e identificar alrededor de 500 que requieren una inspección adicional y posible refuerzo. Capturó el 85% de los edificios con 'piso blando' identificados por ingenieros.
Vulnerabilidad de edificios en St. Lucia ante huracanes (GFDRR 2018)	Evaluación de la vulnerabilidad de estructuras individuales en St. Lucia frente a un huracán de Categoría 5, utilizando las características físicas de los edificios, como el material del techo y su forma y tamaño.	Estimar la vulnerabilidad de los techos ante huracanes en estados insulares pequeños del Caribe.	Imágenes de drones (eBee, RGB, 4 cm), datos de elevación en nube de puntos, imágenes a nivel de calle (Trimble MX, 30 megapíxeles), datos de referencia: contornos de edificios de OpenStreetMap descargados del geonodo Charim	Edificio/ píxel	Modelo de campo aleatorio condicional combinado con MpGlue	Se estimó la destrucción de cada estructura en St. Lucia utilizando las variables que mejor predijeron los daños en Dominica. El volumen, la forma y el tipo de techo fueron variables influyentes: los techos grandes con inclinación pronunciada y láminas metálicas recubiertas de PVF2 mostraron mejores resultados. El algoritmo predijo con mayor facilidad la forma del techo (a cuatro aguas vs. dos aguas) en comparación con el material, debido a la cámara de drones de tres bandas.

Nombre del Projecto y fuente	Descripción	Objetivo	Datos de entrada	Unidad de análisis	Algoritmo usado	Resumen de resultados
Monitoreo del crecimiento urbano a través del índice de espacio de piso (GFDRR 2018)	Imágenes satelitales regulares y libres de nubes, combinadas con algoritmos de aprendizaje automático, se utilizan para monitorear el crecimiento urbano horizontal y vertical. Este estudio utiliza huellas de edificios y datos de altura obtenidos mediante colaboración comunitaria para entrenar un modelo de aprendizaje automático para el monitoreo urbano en Dar es Salaam.	Monitorear el crecimiento urbano, con enfoque en el área construida y la altura de los edificios	Imágenes satelitales (RGB, 3.7 m), modelo de superficie digital (DSM) extraído de imágenes satelitales estereoscópicas (0.8 m)	Píxel	Redes neuronales convolucionales aprendizaje profundo	Se combinó información de referencia de OSM con métodos de aprendizaje automático. Las huellas de edificios se extrajeron con una precisión del 77%; el número correcto de pisos se predijo para el 23% de los edificios. Se encontraron dificultades en áreas densamente construidas (informales).
Mapeo de la Pobreza en Sri Lanka (GFDRR 2018)	Estudio que investiga la idoneidad de características derivadas de imágenes satelitales de alta resolución para estimar la pobreza a nivel local en Sri Lanka.	Estimar niveles de pobreza	Imágenes satelitales (RGB, < 0.5 m); Características basadas en objetos: número de edificios, número de vehículos, fracción de vías pavimentadas, píxeles de sombra (altura de edificios), tipo/alcance de cultivos, tipo de techo. Características basadas en píxeles:índice de vegetación; PanTex (densidad de asentamientos), textura	Pixel/objeto (unidad administrativa)	Aprendizaje profundo (redes neuronales convolucionales) - Máquinas de vectores de soporte e identificación visual	• El análisis puede explicar el 60-61% de la variación en una pequeña área (en comparación con el 15% al usar análisis de luces nocturnas). • La densidad de edificios, área construida y sombras fueron algunas de las características más influyentes que describen variaciones en la pobreza. • Tasas de error normalizadas de 0.25-0.5 de las tasas de pobreza al aplicar el modelo a áreas geográficamente adyacentes.
Mapeo de Asentamientos Informales (GFDRR 2018)	Este estudio, realizado por Graesser et al. en 2012, mapeó asentamientos informales en cuatro ciudades importantes utilizando un algoritmo de ML automatizado para clasificar imágenes satelitales.	Identificación de asentamientos informales	Imágenes satelitales (RGB, < 0.5 m), características basadas en píxeles (índices de vegetación, GLCM PanTex, texturas).	Píxel	Árboles de Decisión	Las características de textura en imágenes satelitales submétricas son adecuadas para distinguir áreas formales de informales. La precisión del algoritmo de ML fue del 85–92% para las cuatro ciudades estudiadas.

Nombre del Projecto y fuente	Descripción	Objetivo	Datos de entrada	Unidad de análisis	Algoritmo usado	Resumen de resultados
Estudio de Pobreza de Stanford (GFDRR 2018)	Este estudio utiliza imágenes de satélite para predecir el porcentaje de hogares por encima de la línea de pobreza en Uganda, dado que el mapeo de la pobreza es costoso y difícil de actualizar.	Mapeo de la pobreza	• Modelo de aprendizaje profundo entrenado en ImageNet. • Imágenes de luces nocturnas de NOAA. • Imágenes de Google Maps	Pixel (rejilla de 1 km x 1 km), objeto (distritos)	Red neuronal convolucional totalmente conectada y clasificador de regresión logística	El método propuesto puede predecir los niveles de pobreza con un 72% de precisión, comparable a resultados de la regresión logística usando características basadas en encuestas.
Catani, (2021) Jain et al. (2023)	Analizar imágenes satelitales para detectar cambios en el uso del suelo y vegetación		Imágenes satelitales, datos climáticos, mapas de uso del suelo		Aprendizaje Profundo	Identificación de cambios en los patrones de uso del suelo y cobertura vegetal para monitoreo de la deforestación, planificación del uso del suelo
Riesgo						
Nombre del Projecto y fuente	**Descripción**	**Objetivo**	**Datos de entrada**	**Unidad de análisis**	**Algoritmo usado**	**Resumen de resultados**
Predicción de Daños por Inundaciones (GFDRR 2018)	Este proyecto investiga cómo la inclusión de variables adicionales puede mejorar la transferibilidad de los modelos de predicción de daños por inundaciones.	Evaluación de daños por inundaciones	Profundidad del agua, Tipo de edificio, Área de huella del edificio, Área de piso, Edad del edificio, Sótano, Tamaño del hogar, Velocidad del flujo, Duración de la inundación, Periodo de retorno, Experiencia de inundación, Medidas de precaución	Tabular (datos de encuestas)	Redes bayesianas y bosques aleatorios (regresión)	Los modelos entrenados con datos heterogéneos (es decir, eventos de inundación con diversas características) mostraron un mejor rendimiento. Se enfatiza la importancia de adquirir un conjunto de entrenamiento heterogéneo para los modelos de daños por inundaciones.
Resiliencia Sísmica Potenciada por Machine Learning para San Francisco (GFDRR 2018)	Modela el daño estructural causado por terremotos utilizando un algoritmo propietario que predice el daño estructural. Este modelo utiliza múltiples fuentes de datos para estimar el impacto de los terremotos en la ciudad de San Francisco.	Modelar el daño estructural por terremotos	Características del suelo, parámetros de amenaza sísmica, características de Los edificios (material, número de pisos, área, etc.)	Tabular (datos de encuesta)	Algoritmo propietario de OneConcern	Se realizaron predicciones de daño a nivel de bloque censal, proporcionando información situacional en tiempo real antes, durante y después de un evento sísmico. Esto permite visualizar datos localizados detallados mientras se mantiene el anonimato de los bloques.

Nombre del Projecto y fuente	Descripción	Objetivo	Datos de entrada	Unidad de análisis	Algoritmo usado	Resumen de resultados
Evaluación de Daños por Ciclón (GFDRR 2018)	El Banco Mundial y UAViators recolectaron imágenes de UAV después de que el ciclón Pam golpeara Vanuatu en 2015. Se utilizó la imagenología de UAVs en lugar de satélites. Los voluntarios de Humanitarian Open Street Map (HOT) y la Digital Humanitarian Network anotaron los daños en las imágenes.	Evaluación de daños	Imágenes ópticas de UAV	Píxel	Aprendizaje profundo	Se desarrolló un pipeline combinando la anotación de daños crowdsourced y aprendizaje profundo con un 63% de precisión.
Tounsi y Temimi, (2023) Jain et al. (2023)	Analizar datos de redes sociales para evaluar la percepción pública del cambio climático.		Datos de redes sociales (por ejemplo, tuits, publicaciones y mensajes relacionados con el cambio climático)		Procesamiento del Lenguaje Natural	Análisis de sentimientos y opiniones públicas sobre el cambio climático para involucrar al público en la acción y defensa climática.
Oh et al. (2020) Jain et al. (2023)	Mapear y monitorear cambios en el uso del suelo y el desarrollo urbano		Imágenes satelitales, mapas de uso del suelo, datos de planificación urbana		Visión por Computadora	Identificación de cambios en el uso del suelo y desarrollo urbano para planificación y gestión del uso del suelo, guiar el desarrollo urbano.
Amenaza						
Nombre del Projecto y fuente	**Descripción**	**Objetivo**	**Datos de entrada**	**Unidad de análisis**	**Algoritmo usado**	**Resumen de resultados**
Mapeo Global de amenaza de movimientos en masa (GFDRR 2018)	Se entrenó un algoritmo que vincula factores de susceptibilidad a movimientos en masa (pendiente, geología, redes viales, zonas de fallas y pérdida de bosque) a eventos históricos de movimientos en masa. Este modelo se aplica a datos de precipitación de la misión de Medición Global de Precipitación (GPM) a intervalos de tres horas. Si una región se clasifica como altamente susceptible, se emite una advertencia de “nowcast”.	Mapeo de amenaza de movimientos en masa	Elevación, fallas y regiones geológicas, redes viales, cobertura forestal, precipitación	0.1°	Árbol de decisión	El modelo habría emitido un “nowcast” para eventos históricos de movimientos en masa con una tasa de falsos positivos inferior al 3% y una tasa de verdaderos positivos de hasta el 60%.

Nombre del Projecto y fuente	Descripción	Objetivo	Datos de entrada	Unidad de análisis	Algoritmo usado	Resumen de resultados
Mapeo de Extensión de Inundaciones (GFDRR 2018)	Proyecto desarrollado por Orbital Insight en 2017 que utilizó Radar de Apertura Sintética (SAR) como entrada para un algoritmo de clasificación de imágenes.	Mapeo de la extensión de inundaciones.	Imágenes satelitales ópticas, Imágenes SAR (a través de nubes), modelos de elevación digital (DEMs), imágenes geolocalizadas de fuentes de datos de crowdsourcing.	Pixel.	Aprendizaje profundo	La combinación de diversos tipos de datos espaciales a gran escala ayudó a estimar la extensión de inundaciones. Las imágenes geolocalizadas de crowdsourcing pueden ayudar a verificar la precisión del mapeo de inundaciones.
Linardos et al. (2022) Jain et al. (2023)		Predecir patrones climáticos futuros y cambios	Modelos climáticos, datos climáticos históricos, imágenes satelitales		Aprendizaje Automático	Proyecciones de temperatura, precipitación y otras variables climáticas para informar políticas climáticas, guiar estrategias de adaptación.
Lawal et al. (2021) Jain et al. (2023)		Predicción de inundaciones	Datos de sensores (precipitación, nivel de río)		Aprendizaje Automático	Mapas de amenaza de inundaciones y alertas para Sistemas de predicción y alerta de inundaciones.
Park et al. (2020) Jain et al. (2023)		Predicción de incendios forestales	Datos satelitales y meteorológicos		Aprendizaje Profundo	Mapas de amenaza de incendios y alertas para sistemas de predicción y alerta de incendios forestales
Wang et al. (2021) Jain et al. (2023)		Identificación de áreas en riesgo de movimientos en masa	Datos satelitales y meteorológicos		Visión por Computadora	Mapas de amenaza de movimientos en masa y alertas para sistemas de predicción y alerta de movimientos en masa
Mosavi et al. (2018) Jain et al. (2023)		Predicción de inundaciones	Datos de sensores (precipitación, nivel de río)		Aprendizaje Automático	Mapas de amenaza de inundaciones y alertas para sistemas de predicción y alerta de inundaciones
Tengtrairat et al. (2021) Jain et al. (2023)		Identificación de áreas en riesgo de movimientos en masa	Datos satelitales y meteorológicos		Visión por Computadora	Mapas de riesgo de movimientos en masa y alertas para sistemas de predicción y alerta de movimientos en masa

2.2.2. Respuesta ante desastres

En la etapa de respuesta ante desastres, los principales enfoques de investigación abarcan el análisis del entorno de desastre, el rescate de emergencia y la evacuación de personas. Los métodos aplicados incluyen robótica, redes neuronales artificiales (ANN), lógica difusa (FL) y máquinas de soporte vectorial (SVM), entre otros. Esta fase implica la gestión de diversos tipos de desastres, como inundaciones, sismos, movimientos en masa y eventos de precipitación. La investigación se centra en optimizar las respuestas a situaciones de crisis y mejorar la efectividad de las operaciones de rescate y evacuación. Por ejemplo, en el caso de las inundaciones se han utilizado vehículos aéreos no tripulados para obtener datos de alta resolución que permiten la detección de áreas inundadas en paisajes urbanos complejos mediante algoritmos de inteligencia artificial (Tan et al. 2020).

Métodos como DL han sido utilizados para identificar las áreas más afectadas por un desastre y proporcionar información para la coordinación de acciones de respuesta (Ivić 2019). Algoritmos como redes neuronales feedforward multicapa, redes neuronales de función de base radial (RBFNN) y bosques aleatorios (Random Forests) se han utilizado para abordar problemas complejos de predicción y clasificación en diversas áreas según el daño detectado del análisis de imágenes satelitales, aprovechando las capacidades de cada algoritmo para identificar patrones y realizar análisis avanzados a partir de grandes volúmenes de datos (Ivić 2019).



Imagen: Adobe Stock

En cuanto a la evaluación de daños, los modelos de inteligencia artificial se utilizan principalmente para determinar la gravedad de los desastres y elaborar mapas de daños. Por ejemplo, Rodríguez et al. (2011) desarrollaron un sistema de soporte de decisión basado en reglas difusas y lo compararon con otros métodos como la regresión lineal múltiple y SVM para evaluar la severidad de desastres. Kou et al. (2014) propusieron un sistema de evaluación de desastres que integra lógica difusa, encuestas y métodos de toma de decisiones multicriterio, mostrando alta precisión y adaptabilidad (Tan et al. 2020).

Otra área innovadora en la respuesta a desastres es el monitoreo de redes sociales mediante el uso del procesamiento de lenguaje natural (PLN), un subcampo de la IA que permite la interacción entre computadoras y el lenguaje humano. El PLN analiza grandes volúmenes de datos no estructurados, como publicaciones en redes sociales (por ejemplo Twitter/X), para identificar información relevante sobre desastres en curso. Esta tecnología ayuda a los equipos de respuesta a localizar áreas afectadas, monitorear el sentimiento de las personas y comprender sus necesidades en tiempo real, lo que facilita una asignación eficiente de recursos. Por ejemplo, durante el huracán Harvey en 2017, la Guardia Costera de Estados Unidos utilizó PLN para localizar a personas que necesitaban ayuda, mejorando así su capacidad de respuesta. En general, el PLN desempeña un papel crucial al proporcionar información en tiempo real y ayudar a los equipos a tomar decisiones más informadas y efectivas (Jain et al. 2023). La **Tabla 14** muestra ejemplos del uso de esta tecnología durante la fase de respuesta.

Tabla 14. Aplicaciones del procesamiento de lenguaje natural (PLN) en la fase de respuesta

Aplicación de PLN	Descripción	Ejemplo
Análisis de Sentimientos	Evalúa el sentimiento de las publicaciones en redes sociales relacionadas con desastres, como positivo o negativo, para informar los esfuerzos de respuesta.	Análisis de tweets durante el Huracán Harvey para identificar áreas con el sentimiento más negativo y orientar los esfuerzos de respuesta en consecuencia (Tounsi y Temimi 2023)
Reconocimiento de Entidades Nombradas	Identifica personas, lugares y organizaciones específicos mencionados en publicaciones en redes sociales relacionadas con desastres.	Identificación de los nombres de refugios y centros de evacuación mencionados en publicaciones en redes sociales durante un incendio forestal (Sufi 2022).
Modelado de Temas	Identifica temas o tópicos comunes discutidos en publicaciones en redes sociales relacionadas con desastres.	Identificación de temas frecuentemente mencionados, como “cierre de carreteras” o “órdenes de evacuación” durante un huracán (Anthopoulos y Kazantzi 2022).
Extracción de Información	Extrae piezas específicas de información de publicaciones en redes sociales relacionadas con desastres, como solicitudes de asistencia o informes de daños.	Identificación de solicitudes de asistencia o informes de personas desaparecidas en publicaciones en redes sociales durante una inundación (Sufi y Khalil 2024).

Fuente: H. Jain et al. (2023).

2.3. RETOS



Imagen: Adobe Stock

Aunque los nuevos conceptos, tecnologías y aplicaciones relacionadas con la IA han traído numerosos beneficios y avanzan rápidamente con un gran potencial en la gestión de riesgos de desastres, también enfrentan desafíos. Algunos de estos desafíos, como los mencionados por Xu y Xue (2024) y H. Jain et al. (2023) se presentan a continuación:

- La introducción de nuevas tecnologías y aplicaciones requiere que el **personal** relevante reciba formación para mejorar sus habilidades y competencias. Sin embargo, el proceso de capacitación puede requerir tiempo y recursos, y debe resolverse la contradicción entre la oferta y la demanda de talento.

- Algunas de estas nuevas tecnologías requieren un considerable respaldo de datos, pero compartir datos y **proteger la privacidad** sigue siendo un desafío. Garantizar la seguridad y la legalidad de los datos mientras se facilita su uso y acceso requiere la cooperación entre el gobierno y las instituciones de investigación científica. Los sistemas de IA dependen de grandes volúmenes de datos, incluidos datos personales y sensibles. El **uso ético de los datos** es esencial para proteger la privacidad y prevenir el uso indebido de la información personal.

- La tecnología de IA es cada vez más crucial en la predicción y alerta temprana de desastres. Sin embargo, debido a sus características de “caja negra”, su **incertidumbre** puede llevar a errores de juicio, lo cual requiere más investigación y soluciones.

- Algunas tecnologías y aplicaciones nuevas tienen **costos** elevados y necesitan una inversión considerable. Para regiones con menos recursos o países en desarrollo, puede resultar difícil asumir estos costos, lo cual genera una aplicación desigual de la tecnología.

- Es importante garantizar una **comprensión y uso adecuados** por parte del público de los nuevos conceptos, tecnologías y aplicaciones.

- Necesidad de **datos de alta calidad, el potencial de sesgos y errores** en los modelos de inteligencia artificial, y la importancia de la supervisión. Los sistemas de IA dependen de grandes volúmenes de datos para realizar predicciones y recomendaciones. Sin embargo, si los datos utilizados para entrenar los modelos de IA están sesgados, esto puede conducir a resultados sesgados. Por ejemplo, si los datos utilizados para entrenar un sistema de IA solo incluyen datos históricos de ciertas regiones o poblaciones, es posible que no reflejen las experiencias de otros territorios o grupos. Esto podría resultar en predicciones y recomendaciones inexactas que podrían afectar desproporcionadamente a las poblaciones vulnerables.

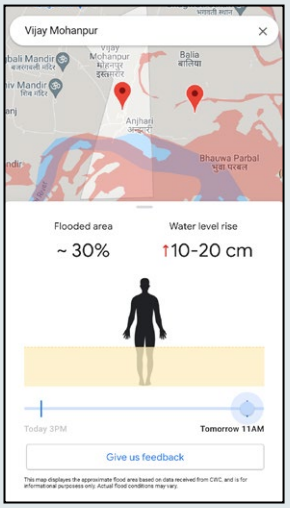
- Estos modelos pueden ser altamente **complejos**, lo que dificulta que los responsables de la formulación de políticas y las partes interesadas comprendan su funcionamiento y cómo interpretar sus resultados.

- La **falta de transparencia** en los algoritmos utilizados para desarrollar y entrenar modelos de IA también puede complicar la identificación de posibles fuentes de sesgo.

- Las estrategias de reducción de riesgo impulsadas por IA pueden tener **consecuencias no intencionadas** que podrían afectar negativamente a las comunidades o ecosistemas. Por ejemplo, si un sistema de IA recomienda la construcción de un dique para proteger contra el aumento del nivel del mar, esto podría tener consecuencias no deseadas para los ecosistemas marinos.

Caja 1. Sistema de alerta temprana de inundaciones de Google

Google Research ha desarrollado un sistema avanzado de alerta temprana de inundaciones utilizando modelos de inteligencia artificial (IA) que procesan datos públicos de diversas fuentes. Este sistema permite emitir alertas con hasta siete días de anticipación, brindando información crítica y accesible sobre inundaciones a través del Flood Hub de Google. Esta plataforma está diseñada para satisfacer las necesidades de gobiernos, organizaciones locales de ayuda y personas directamente en riesgo, consolidando información y proporcionando datos locales relevantes de forma gratuita y disponible públicamente. Las alertas también se publican en Google Search, Google Maps y notificaciones de Android, facilitando así el acceso a una mayor cantidad de personas (Google 2024a).



Fuente: https://blog.google/technology/ai/expanding-our-ml-based-flood-forecasting/

El sistema de pronóstico se basa en dos componentes principales: el Modelo Hidrológico, que predice posibles desbordamientos de ríos procesando datos como precipitaciones y otra información meteorológica y de cuenca; y el Modelo de Inundación, que simula el comportamiento del agua en las llanuras de inundación. Ambos modelos son integrados mediante un enfoque de IA que proporciona pronósticos finales (Google, 2024). La arquitectura de este sistema está basada en un modelo codificador-decodificador LSTM (Long Short-Term Memory), donde un codificador LSTM procesa datos históricos meteorológicos y geofísicos, y un decodificador LSTM proyecta el pronóstico de los próximos siete días (Nearing et al. 2024).

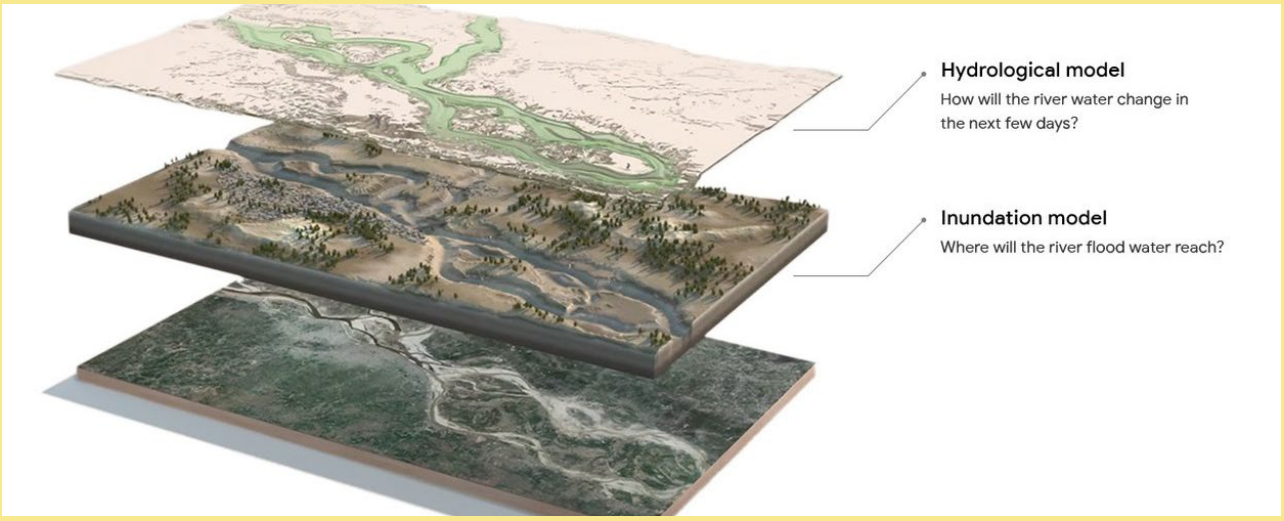




Imagen: Adobe Stock

El primer piloto del sistema de pronóstico se llevó a cabo en la región de Patna, India, en el estado de Bihar, uno de los más propensos a inundaciones en el país. Trabajando con funcionarios locales y utilizando datos en tiempo real, se desarrolló un sistema de pronóstico de inundaciones que fue incorporado en Google Public Alerts en 2018, permitiendo advertir a la población local sobre los riesgos inminentes. En 2019, se amplió la cobertura de pronóstico a nivel nacional y se extendió a Bangladesh, cubriendo un total de 360 millones de personas. Durante ese período, el sistema proporcionaba pronósticos con hasta 48 horas de anticipación, pero dependía de la disponibilidad de datos locales, lo cual limitaba su expansión a otros países (Google 2024b).

Ante estas limitaciones, Google cambió su enfoque hacia un modelo global basado en IA, que permitiera superar la dependencia de datos locales. Este nuevo enfoque requirió fuentes de datos globales para entrenar el modelo utilizando redes LSTM, con el objetivo de predecir inundaciones en regiones que no cuentan con mediciones locales de caudal. Así, en 2022, Google lanzó la plataforma Flood Hub, que proporcionó acceso a pronósticos en 20 países, incluyendo 15 en África, donde la capacidad de pronóstico había estado previamente restringida (Google 2024b).

En 2023, la plataforma Flood Hub se expandió aún más, añadiendo cobertura en 60 nuevos países en África, la región de Asia-Pacífico, Europa, y América del Sur y Central. Esta expansión permitió cubrir a 460 millones de personas a nivel mundial, ofreciendo pronósticos gratuitos y en tiempo real para muchas comunidades vulnerables en países en desarrollo. Gracias a los avances en el modelo global basado en IA, ahora se dispone de un acceso equitativo al pronóstico de inundaciones, comparable en regiones de África y Europa (Google 2024b).

SECCIÓN 3



Imagen: Adobe Stock

MODELOS MATEMÁTICOS USADOS EN LAS PLATAFORMAS DE CÁLCULO DE RIESGO DE DESASTRES

3.1. INTRODUCCIÓN



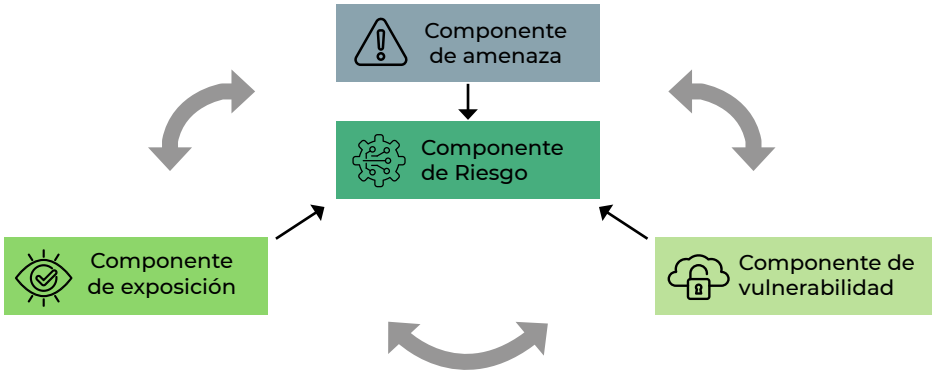
Imagen: Flickr - BID Ciudades Sostenibles / Nassau Bahamas

El riesgo se refiere al resultado final de combinar la magnitud de una consecuencia con su frecuencia de ocurrencia, mientras que los impactos se centran únicamente en las consecuencias, sin considerar la frecuencia. El objetivo principal de la cuantificación del riesgo es calcular las pérdidas económicas y/o humanas (BID 2019). A continuación, se presenta el marco conceptual utilizado en la metodología del Banco Interamericano de Desarrollo (BID 2019) que será utilizado para analizar las capacidades de cálculo de las plataformas de cálculo de riesgo que han sido evaluadas en este documento.

Un modelo de riesgo debe incluir los siguientes componentes, mostrados en la **Figura 7**:

1 Evaluación de amenazas	2 Evaluación de exposición	3 Evaluación de vulnerabilidad	4 Evaluación de riesgo
Consiste en analizar la(s) amenaza(s) en términos de extensión espacial, intensidad, duración y frecuencia. Su objetivo es precisar dónde y cómo podría ocurrir cada amenaza natural.	Implica la creación de una base de datos georreferenciada de todos los activos físicos (infraestructura, edificaciones, cultivos, etc.) y sociales (población) que puedan verse afectados por la amenaza natural junto con sus características.	Examina la propensión de los activos expuestos a sufrir daños frente a amenazas naturales. Esto requiere estudiar las características estructurales y sociales que determinan su resistencia o fragilidad ante eventos adversos.	Integra los tres componentes anteriores (amenaza, exposición y vulnerabilidad) para calcular el nivel de riesgo resultante.

Figura 7. Componentes de la evaluación de riesgo



Fuente: BID (2019).

Cada uno de estos módulos opera de manera individual, con metodologías y criterios específicos. Sin embargo, un modelo de riesgo eficaz debe garantizar la interconexión entre módulos, asegurando la compatibilidad en los formatos de datos y la coherencia en los métodos utilizados.

Por ejemplo, el módulo de exposición debe contar con una representación espacial que le permita interactuar con el módulo de amenaza, identificando qué activos o población están en riesgo. Asimismo, debe incluir características de los activos expuestos que sean relevantes para el módulo de vulnerabilidad, permitiendo evaluar el daño potencial. De igual forma, el módulo de vulnerabilidad debe expresarse en función de la intensidad de la amenaza y ser coherente con los atributos representados en el módulo de exposición.

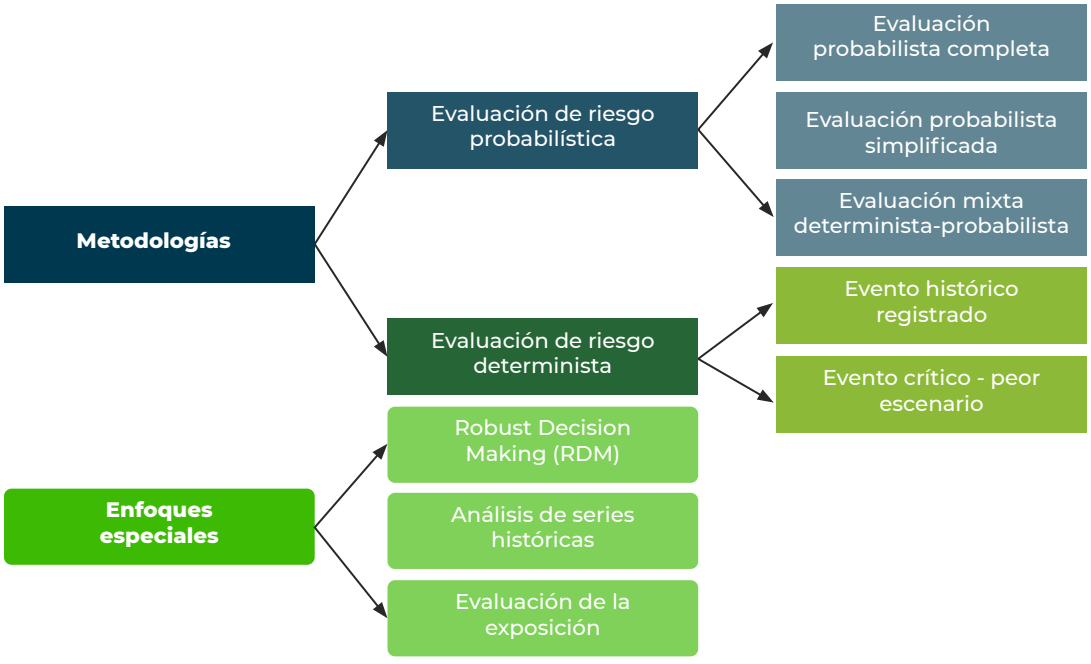
El módulo de riesgo actúa como el centro de integración del modelo, combinando matemáticamente los tres módulos para calcular métricas de riesgo. Estas métricas pueden incluir pérdidas económicas (en valores absolutos o porcentuales) y pérdidas sociales (vidas perdidas, personas lesionadas o afectadas). Dependiendo del enfoque metodológico, estas métricas pueden adoptar diferentes interpretaciones y extenderse a otros indicadores (BID 2019).

La evaluación de la incertidumbre desempeña un papel crucial en el análisis de riesgo. En términos generales, la incertidumbre se clasifica en dos tipos principales:

1. **Incertidumbre natural o aleatoria:** Derivada de la variabilidad inherente en los procesos naturales.
2. **Incertidumbre epistémica:** Resultado de la falta de conocimiento o información sobre el sistema en estudio.

El enfoque más común en el análisis de riesgo aborda estos tipos de incertidumbre por separado mediante un análisis probabilista, el cual permite obtener una distribución de probabilidad de los resultados de riesgo con base en las variaciones de la incertidumbre epistémica. **La Figura 8** presenta la clasificación de los métodos de evaluación de riesgo propuesta por el BID (2019). Las metodologías deterministas se basan en el análisis de un único evento, ya sea histórico o crítico, mientras que las probabilistas se dividen en tres subcategorías según la manera en que abordan la incertidumbre en el análisis. La **Tabla 25** resume cada metodología, y para una descripción detallada, el lector puede consultar el documento metodológico del BID (2019). En este capítulo, se analizarán las metodologías probabilísticas y determinísticas, excluyendo los enfoques especiales, ya que el objetivo del documento es evaluar plataformas de cálculo de riesgo con enfoques cuantitativos, principalmente probabilísticos.

Figura 8. Métodos de evaluación de riesgo según BID (2019)



Fuente: BID (2019).

Las plataformas de cálculo de riesgo analizadas en este documento emplean distintos enfoques matemáticos para la estimación del riesgo, los cuales se pueden clasificar dentro de los métodos presentados en la **Figura 8**. Algunas de estas plataformas incorporan métodos específicos para cuantificar la incertidumbre, mientras que otras no. Además, algunas utilizan curvas de vulnerabilidad, mientras que otras emplean curvas de fragilidad.

Este capítulo examina los enfoques matemáticos utilizados en las plataformas para el cálculo del riesgo probabilista. La primera sección introduce las diferencias conceptuales entre las curvas de vulnerabilidad y fragilidad, y analiza su aplicación en las plataformas estudiadas. Las siguientes tres secciones presentan los principales enfoques probabilistas para la evaluación del riesgo y describen las capacidades de las plataformas evaluadas en relación con estas metodologías. Finalmente, la quinta sección sintetiza en tablas los métodos de evaluación probabilista disponibles en cada plataforma, así como las técnicas de cuantificación de la incertidumbre que ofrecen. El **Anexo A** complementa esta sección al detallar los métodos utilizados por cada plataforma.

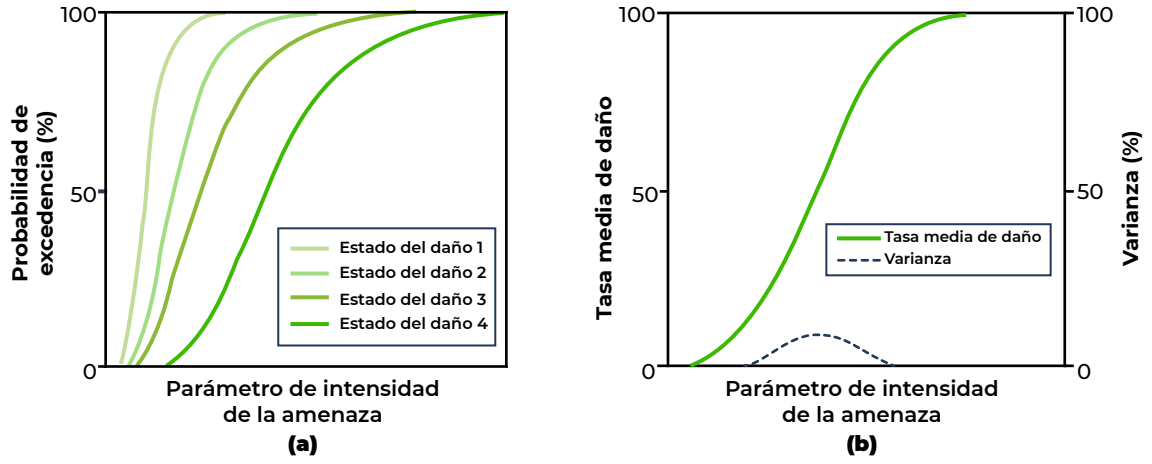
3.2. CURVAS DE VULNERABILIDAD Y DE FRAGILIDAD



Imagen: Flickr - BID Ciudades sostenibles / Tegucigalpa Honduras

Para evaluar el daño físico que un elemento estructural puede sufrir debido al contacto directo con una amenaza, se emplean principalmente dos enfoques (**ver Figura 9**): **curvas de vulnerabilidad** y **curvas de fragilidad** (Nirandjan et al. 2024). Estas curvas permiten modelar la relación entre la intensidad de una amenaza y el daño potencial de los activos expuestos. Existen también otros métodos, como las matrices e índices (Papathoma-Köhle et al. 2022); sin embargo, estos no serán abordados en este documento, ya que no son comúnmente utilizados en las plataformas de cálculo de riesgo probabilístico.

Figura 9. Ejemplo de curva de fragilidad (panel izquierdo) ejemplo de curva de vulnerabilidad (panel derecho)



Fuente: The World Bank (2019).

Las curvas de vulnerabilidad vinculan niveles específicos de intensidad de una amenaza (por ejemplo, profundidad de inundación, velocidad del viento) con la posible afectación física de un activo. El daño se expresa en términos absolutos, como costos monetarios de reparación, o en términos relativos mediante la tasa media de daño o MDR (Mean Damage Ratio por sus siglas en inglés), definida como la relación entre el costo esperado de reparación y el costo total de reemplazo de la estructura (The World Bank 2019). En contraste, las curvas de fragilidad describen la probabilidad de que un activo alcance o supere un determinado estado de daño dado un nivel de intensidad de la amenaza. Los estados de daño pueden ser cualitativos y descriptivos, como “leve”, “moderado” o “extenso”, y son utilizados con mayor frecuencia en estudios sísmicos, mientras que en el análisis de inundaciones se utilizan más comúnmente las curvas de vulnerabilidad (Papathoma-Köhle et al. 2022; Nirandjan et al. 2024).

Un aspecto crucial en la modelación del riesgo es la conversión de curvas de fragilidad a curvas de vulnerabilidad, lo que permite cuantificar los daños económicos. La transformación se basa en la distribución acumulada del costo esperado dado un estado de daño $E(C\backslash dsi)$ y la probabilidad de que un activo alcance un determinado estado de daño $P(dsi\backslash im)$ dado un nivel de intensidad de la amenaza. La función que define la vulnerabilidad se expresa como se muestra en la **Ecuación 1**.

Ecuación 1

$$E(C\backslash im)=\sum_{i=1}^{n} E(C\backslash dsi)\cdot P(dsi\backslash im)$$

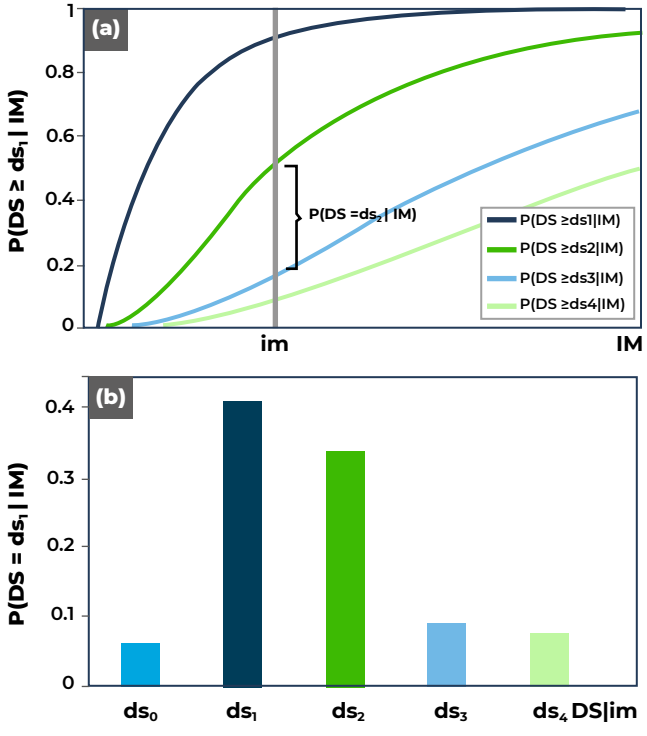
Donde n corresponde al número de estados de daño y el estado de daño "ninguno" no se considera en la suma de los estados de daño. Si se dispone de un rango de valores para $(E(C\backslash dsi)$, este se utiliza para definir los límites superior e inferior de la curva de vulnerabilidad; en caso contrario, se calcula la varianza de la vulnerabilidad mediante la **Ecuación 2**.

Ecuación 2

$$\mathrm{var}(C\backslash im)=\sum_{i=1}^{n}(E(C\backslash dsi)-E(C\backslash im))^2\cdot P(dsi\backslash im)$$

La probabilidad de que un edificio alcance un estado de daño específico se calcula utilizando curvas de fragilidad, donde cada barra en la distribución de probabilidades de daño se define como la diferencia entre dos curvas de fragilidad sucesivas para un nivel de intensidad dado (The World Bank 2019). La repetición de este proceso para distintos niveles de intensidad permite construir la curva de vulnerabilidad correspondiente.

Figura 10. Cálculo de las probabilidades de daño a partir de las curvas de fragilidad para un nivel específico de medida de intensidad, im. a) Curvas de fragilidad correspondientes a n = 4 estados límite de daño. b) Columna de probabilidades de daño para diferentes estados de daño dado un nivel de intensidad (adaptado de D'Ayala et al. 2015)



Fuente: The World Bank (2019).

Notas: Estados de daño: ds0 = Sin daño, ds1 = Daño leve, ds2 = Daño moderado, ds3 = Daño extenso, ds4 = Colapso.

Las funciones de vulnerabilidad y fragilidad se derivan del análisis estadístico de valores de pérdida o daño, los cuales pueden registrarse, simularse o estimarse en función de distintos niveles de severidad de la amenaza. En la práctica, las estadísticas de pérdida o daño pueden obtenerse a partir de la observación de eventos pasados (enfoques empíricos), estudios analíticos o numéricos, juicios de expertos, o una combinación de estos métodos (enfoque híbrido). Los enfoques empíricos, basados en encuestas posteriores a un evento para evaluar el desempeño de diferentes clases de activos, se consideran generalmente la fuente más confiable de datos sobre pérdidas y daños, ya que se fundamentan en observaciones reales (Pregnolato et al. 2015).

La **Tabla 15** resume los tipos de representación de la vulnerabilidad empleados por las plataformas de cálculo de riesgo analizadas en este documento. Se observa que la mayoría utiliza curvas de vulnerabilidad, aunque algunas cuentan con la capacidad de aplicar ambos enfoques en el cálculo.

Tabla 15. Tipo de representación de la vulnerabilidad utilizado por las plataformas de cálculo de riesgo

Tipo de representación de la vulnerabilidad utilizado	CAPRA	HAZUS	RiskScape	OASIS LMF	IN-CORE	CLIMADA	CATSIM	RiskChanges	FloodRisk	Delft-FIAT	HEC-FDA	OpenQuake
Curva de vulnerabilidad	✓	✓ [1]	✓	✓	X	✓	✓	✓	✓	✓	✓	✓
Curva de fragilidad	✓	✓ [2]	✓	X	✓	X	X	X	X	X	X	✓

Nota:
1. Enfoque utilizado por HAZUS para inundaciones.
2. Enfoque utilizado por HAZUS para tsunami, sismo y huracanes.

3.3. EVALUACIÓN PROBABILISTA COMPLETA EN LAS PLATAFORMAS EVALUADAS

La evaluación probabilista completa del riesgo proporciona información detallada sobre las posibles pérdidas y sus probabilidades de ocurrencia. En la mayoría de los casos los enfoques completamente probabilistas modelan de manera probabilista la amenaza y la vulnerabilidad, pero también existen avances en la cuantificación de incertidumbre en el componente de exposición (Mistry y Lombardi 2023).

Las fases del proceso de análisis se resumen a continuación, para información detallada de la metodología consultar BID (2019).

1 Modelación probabilista de la amenaza

Se construye un modelo probabilista de todas las amenazas relevantes, considerando incertidumbre y cambio climático en el caso que aplique.

2 Base de datos georreferenciada de exposición

Se elabora un registro detallado de edificaciones, infraestructura y población expuesta a las amenazas.

3 Modelación probabilista de la vulnerabilidad

Se evalúa la vulnerabilidad estructural y social de los elementos expuestos, incorporando incertidumbre en los análisis.

4 Integración de módulos y cálculo del riesgo

Se asegura la compatibilidad de los módulos y se aplica un modelo matemático probabilista para estimar pérdidas directas e indirectas.

5 Cálculo de métricas de riesgo

Se obtienen métricas como la Pérdida Anual Esperada (PAE), la Pérdida Máxima Probable (PMP) y la Probabilidad de Excedencia de Pérdidas.

El método se basa en la teoría de la probabilidad y utiliza ecuaciones matemáticas (como el Teorema de la Probabilidad Total) para calcular la probabilidad de pérdida en función de diferentes escenarios de amenaza y se obtiene la curva de excedencia de pérdidas, que permite estimar la frecuencia de pérdidas extremas.

Este tipo de enfoque es utilizado por **Hazus Huracanes** en donde las consecuencias de un huracán en una ciudad o región se estima mediante un conjunto probabilístico de eventos, cuya extensión varía según la geografía. El modelo de simulación de la trayectoria de la tormenta se inicia muestreando aleatoriamente una posición inicial, fecha, hora, dirección y velocidad de traslación de una de las tormentas tropicales dadas en la base de datos HURDAT[10]. El número de tormentas que se simularán en cualquier año se obtiene muestreando de una distribución binomial negativa con un valor medio de 8.4 tormentas por año y una desviación estándar de 3.56 tormentas por año (FEMA 2022a). El modelo de pérdidas es un modelo físico que calcula las pérdidas económicas directas utilizando una combinación de técnicas de costos explícitas e implícitas (FEMA 2022a).

El modelo de viento de Hazus Huracanes sigue un enfoque probabilista basado en la metodología de amenaza-carga-resistencia-daño-pérdida, desarrollada desde un marco de riesgo individual. El desempeño de los edificios frente a vientos extremos se formula probabilísticamente mediante conceptos de fiabilidad estructural. Se estima la probabilidad de falla de elementos individuales (como ventanas o puertas) comparando la carga del viento con la resistencia del elemento. A través de simulaciones en distintos tipos de edificios, se calculan las probabilidades de daño y se establecen relaciones entre la intensidad del viento y el daño físico. La pérdida anual promedio por huracanes considera todas las pérdidas futuras causadas por la amenaza de huracán que resulten de posibles eventos de amenaza con diferentes magnitudes y períodos de retorno promediados por año (FEMA 2022a).

Un enfoque completamente probabilista puede aplicarse en plataformas como **CAPRA, RiskScape, OASIS FML, CLIMADA, IN-CORE, OpenQuake y Delft-FIAT**. En teoría, también podría implementarse en RiskChanges y FloodRisk, ya que son de código abierto y pueden adaptarse en Python. No obstante, estas herramientas no se considerarán como completamente probabilistas porque no fueron originalmente diseñadas para realizar este tipo de cálculo con cientos o miles de simulaciones.

CAPRA, RiskScape, OASIS FML, CLIMADA, IN-CORE, OpenQuake y Delft-FIAT tienen la capacidad de realizar cálculos de impacto o daño utilizando grandes cantidades de eventos de amenaza con una probabilidad asignada, lo que permite el procesamiento posterior de los datos de daño para construir la curva de excedencia de pérdida. CAPRA, OASIS FML, CLIMADA, IN-CORE y OpenQuake tienen métodos propios para la cuantificación de incertidumbre que pueden ser consultados en el **Anexo A**. Estos métodos implican ejecuciones repetidas del modelo con parámetros de entrada variables.

[10] https://www.aoml.noaa.gov/hrd/hurdat/Data_Storm.html

3.4. EVALUACIÓN PROBABILISTA SIMPLIFICADA DE RIESGO EN LAS PLATAFORMAS EVALUADAS



Imagen: Adobe Stock

En un cálculo de riesgo probabilista simplificado, las pérdidas se calculan de forma discreta para valores específicos de intensidad de amenaza con un periodo de retorno asociado. Estas pérdidas se reportan individualmente y permiten determinar directamente la pérdida anual esperada (PAE). Sin embargo, la curva de excedencia de pérdidas solo puede estimarse mediante extrapolación, a diferencia de un cálculo totalmente probabilista, que proporciona una distribución completa de pérdidas. En general, los enfoques simplificados no incorporan incertidumbre en el módulo de vulnerabilidad y utilizan estimaciones de daño medio. El cálculo de la PAE se basa en la curva de amenaza, que contiene las tasas de excedencia (el inverso del periodo de retorno) para diferentes intensidades de amenaza, combinadas con las pérdidas esperadas para cada intensidad (BID 2019). Para información detallada de la metodología consultar BID (2019).

Las herramientas descritas en la sección 2 pueden calcular el daño utilizando un enfoque probabilista simplificado para un número determinado de periodos de retorno y curvas de vulnerabilidad o fragilidad (ver **Tabla 15** para información sobre el tipo de representación de la vulnerabilidad de cada plataforma de cálculo), con excepción de **InaSAFE**[11] **y FloodRise** que no ejecutan cálculos de riesgo económico y por lo tanto no serán considerados en este capítulo.

[11] En la documentación de InaSAFE se describen algunos métodos simplificados para calcular daños utilizando herramientas disponibles de QGIS (InaSAFE, 2023) pero para los fines de este documento esos métodos no se considerarán.

La ecuación utilizada en esta metodología corresponde a una discretización que convierte las probabilidades de excedencia en probabilidades de ocurrencia y calcula las pérdidas promedio entre periodos de retorno consecutivos. Finalmente, estas pérdidas se multiplican para obtener la PAE (BID 2019). La documentación de **FloodRisk** hace una explicación detallada del método (Albano et al. 2017). Se utilizan funciones de daño relativo que expresan los daños como una proporción del valor total de los activos (0 = sin daño a 1 = destrucción total). Estas funciones de daño se pueden representar como curvas de intensidad-daño que combinan el tipo de uso del suelo o elemento expuesto y la intensidad. El parámetro de intensidad depende de la amenaza analizada, por ejemplo, FloodRisk utiliza la profundidad de flujo (Albano et al. 2017c) .

Una vez que se calculan los daños para eventos con varios periodos de retorno aplicando la curva de vulnerabilidad a los elementos expuestos, se determina la PAE de la siguiente manera (Albano et al. 2017c):

Ecuación 3

$$PAE = \sum_{i=1}^{n} \Delta P_i D_i$$

donde:

ΔP_i es el incremento de la probabilidad de excedencia.

D_i es el daño promedio de dos eventos con probabilidades de excedencia P_i y P_{i+1}. Para eventos con periodos de retorno i desde 1 hasta n periodos de retorno.

Este método es utilizado por **RiskChanges**[12] (Van Westen y Bakker 2015), **CATSIM** (IIASA 2024a) y **Delf-FIAT**, aunque en el caso de este último la documentación no es clara sobre si el software calcula la PAE o solo el impacto para eventos, aunque la documentación aclara que puede utilizarse en conjunto con Excel y Python para posprocesamiento de resultados e incluso ser utilizada en análisis probabilísticos complejos en un entorno de Python (Deltares 2024a). En el caso de **OpenQuake** este enfoque también puede aplicarse para el cálculo de riesgo basado en eventos con un periodo de retorno asociado, con la opción de considerar o no la incertidumbre de parámetros (ver detalles en el **Anexo A**).

Aunque **CAPRA y CLIMADA** fueron diseñadas para análisis probabilístico de riesgo utilizando métodos de cuantificación de incertidumbre y simulación de cientos o miles de eventos, pueden hacer los cálculos por evento o grupos de eventos con una probabilidad asignada. En el caso de **RiskScape** la herramienta distingue entre 3 enfoques para el cálculo de riesgo que se explican en detalle en el Anexo A, siendo

[12] Cabe anotar que la documentación de la herramienta web en su sitio web no presenta información de los algoritmos utilizados para los cálculos, la documentación que se consultó para identificar el método corresponde a un informe de avance de proyecto desarrollado por Van Westen & Bakker (2015).

uno de ellos el basado en eventos con una probabilidad de excedencia asignada. En lo que se refiere a **OASIS LMF l**a herramienta ha sido diseñada para el cálculo de riesgo completamente probabilístico por lo que en caso de requerirse un análisis con la aplicación de la Ecuación 3 para un conjunto limitado de escenarios, es posible que sea preferible utilizar herramientas más simples, aunque la herramienta pueda realizar el cálculo. Algo similar ocurre con **HEC-FDA**, una herramienta diseñada para el análisis de riesgo por inundación que integra la evaluación de sistemas de protección y la incertidumbre asociada. Aunque puede analizar un número determinado de eventos con una probabilidad asociada, su objetivo principal no es este, sino la cuantificación de la incertidumbre en los componentes hidrológico, hidráulico y de vulnerabilidad dentro del análisis de riesgo por inundación, mediante métodos de Montecarlo.

La aplicación de la Ecuación 3 es el enfoque utilizado por **Hazus** para inundaciones, que aclara en su documentación que no aborda la incertidumbre, aunque reconoce su importancia (FEMA 2022b) y advierte que los resultados del modelo no deben considerarse cifras exactas y deben utilizarse en consecuencia. Sin embargo, el Comité de Inundaciones de FEMA considera que las decisiones de planificación tomadas con el beneficio de los resultados de los modelos serán mejores que las decisiones tomadas sin ninguna consideración de la ciencia (FEMA 2022b). Para el caso de tsunami y sismo Hazus utiliza curvas de fragilidad en el análisis. **IN-CORE** también utiliza curvas de fragilidad para realizar los cálculos de daño. Primero, se obtiene una fragilidad basada en el tipo de amenaza y los atributos del edificio (o cualquier otro elemento expuesto). Con base en la fragilidad, se calcula la intensidad de la amenaza en la ubicación del edificio. Con esta información, se calcula la probabilidad de exceder cada estado límite, junto con la probabilidad de daño. En el caso de la amenaza sísmica, la información del suelo se puede utilizar para modificar las probabilidades de daño e incluir el daño debido a la licuefacción (IN-CORE 2024).



Imagen: Adobe Stock

3.5. EVALUACIÓN MIXTA DETERMINISTA PROBABILISTA

Para la implementación de este enfoque, se debe definir qué componentes del modelo de riesgo serán tratados de manera probabilista (ya sea totalmente o de forma simplificada) y cuáles de manera determinista.

Existen dos casos principales:

1 Amenaza probabilista y vulnerabilidad determinista

Permite obtener la curva de excedencia de pérdidas (CEP), ya sea directamente si el análisis es totalmente probabilista o mediante una aproximación (proxy) si es probabilista simplificado. La vulnerabilidad se modela sin incertidumbre ni variabilidad.

2 Amenaza determinista y vulnerabilidad probabilista

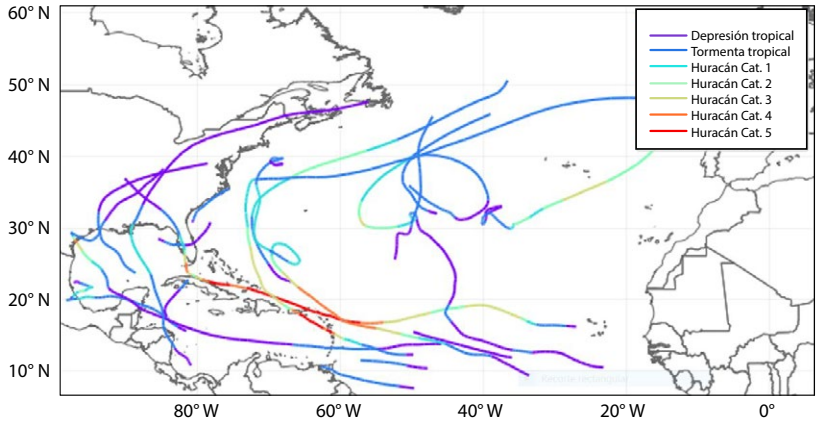
No permite obtener la CEP, solo resultados puntuales de riesgo. La estimación de pérdidas se basa en modelos estructurales detallados, teoría de confiabilidad estructural, elementos finitos y simulaciones de Monte Carlo, entre otros métodos.

Las métricas de riesgo dependen del enfoque adoptado. Si se obtiene la CEP, se aplican las métricas estándar del análisis probabilista. En su ausencia, se pueden estimar probabilidades de daño, probabilidad de falla y otros indicadores específicos del sector y la amenaza evaluados. Para información detallada de la metodología consultar BID (2019).

Las herramientas que tienen la capacidad de hacer una evaluación probabilista completa como **Hazus Huracanes, CAPRA, OASIS FML, CLIMADA, IN-CORE y OpenQuake** pueden implementarse para realizar evaluaciones mixtas determinista-probabilista y probabilistas simplificadas. Herramientas como **RiskScape** y **Delft-FIAT** aunque en sus casos de uso y manuales se refieren primordialmente a aplicaciones probabilistas simplificadas pueden utilizarse para análisis mixtos ya que por medio de código adicional (Python) podrían hacer consideraciones de la incertidumbre del componente de vulnerabilidad.

En su documentación online CLIMADA presenta un ejemplo de su uso en una implementación mixta determinista-probabilista considerando la amenaza probabilista y la vulnerabilidad determinista. Cabe mencionar que CLIMADA cuenta con el módulo *Unsequa* para considerar la incertidumbre de cualquier componente del modelo de riesgo, y puede ser utilizado de diferentes formas y niveles de complejidad para cuantificar incertidumbre. En el ejemplo, se utilizan las funciones de CLIMADA que permiten analizar ciclones tropicales utilizando tanto datos históricos como simulaciones sintéticas para evaluar el riesgo de estos eventos extremos (ETH Zurich 2017a). Su módulo TCTracks tiene acceso a datos de ciclones tropicales provenientes de la base de datos IBTrACS, que recopila registros históricos desde la década de 1950 (ver **Figura 11**).

Figura 11. Ejemplo de tormentas históricas descargadas por CLIMADA



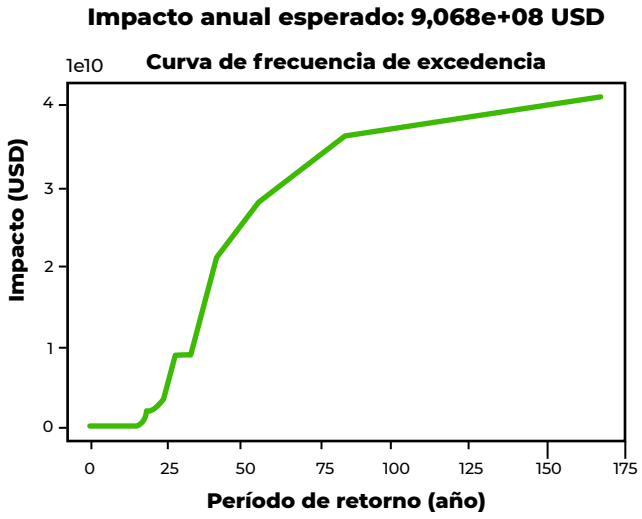
Fuente: ETH Zurich (2017a).

Sin embargo, como los registros históricos son limitados y solo una pequeña fracción de los ciclones toca tierra cada año, esta información es insuficiente para evaluar con precisión el riesgo de eventos raros. Para superar esta limitación, CLIMADA genera ciclones sintéticos basados en los registros históricos mediante procesos de Wiener (un tipo de caminata aleatoria dirigida). Esto permite crear grandes conjuntos de datos que ayudan a estimar la probabilidad de ciclones extremos poco frecuentes. Con CLIMADA, los usuarios pueden:

1. Cargar datos históricos de ciclones desde IBTrACS mediante la función from_ibtracs_netcdf(), que descarga y almacena los datos para su análisis.
2. se elabora un registro detallado de edificaciones, infraestructura y población expuesta a las amenazas.
3. se evalúa la vulnerabilidad estructural y social de los elementos expuestos, incorporando incertidumbre en los análisis.

El tutorial de CLIMADA de análisis de ciclones tropicales en Puerto Rico (ETH Zurich 2017a) muestra el uso de este tipo de información en el análisis de riesgo (aunque con un número pequeño de eventos para rapidez de cálculo en el tutorial), que luego de ser utilizada con una base de exposición creada a partir de LitPop[13] y funciones de vulnerabilidad contenidas en CLIMADA permite obtener la curva de excedencia de impacto y la PAE (reportada por CLIMADA en inglés como expected anual damage) como se muestra en la **Figura 12**.

Figura 12. Curva de excedencia de daño



Fuente: ETH Zurich (2017a).

3.5. RESUMEN

La **Tabla 16** resume los métodos de evaluación probabilista que pueden ser utilizados por cada herramienta y la **Tabla 17** resume los métodos de cuantificación de incertidumbre disponibles, que pueden utilizarse para evaluación completamente probabilista. Para mayor información sobre los métodos de cada herramienta puede consultarse el **Anexo A**.

[13] Litpop corresponde al conjunto de datos de exposición global para la evaluación del riesgo de desastres implementado en el software CLIMADA. https://www.research-collection.ethz.ch/handle/20.500.11850/331316

Tabla 16. Métodos de evaluación probabilista que pueden ser utilizados por cada herramienta

		Métodos probabilistas
Método	**Descripción**	
Evaluación probabilista del riesgo	Una evaluación probabilista del riesgo tiene como objetivo abordar algunas de las incertidumbres que son inherentes al riesgo de desastres. Estas incertidumbres proceden de (i) la limitada disponibilidad de datos históricos, (ii) del hecho de que los sucesos catastróficos son muy infrecuentes. (iii) que se tiene una ventana de observación pequeña de los desastres y (iv) que las tendencias climáticas están cambiando, entre otros factores (ERN-AL,s.f.a). En una evaluación probabilista los componentes que integran el riesgo (principalmente la amenaza y la vulnerabilidad) son modelados y luego integrados matemáticamente de forma probabilista reconociendo e incorporando formalmente la incertidumbre en todo el modelo. Así el modelo puede representar estadísticamente la probabilidad de todos los sucesos posibles, incluso aquellos que no han ocurrido aún, lo cual lo transforma en un modelo prospectivo. Este tipo de evaluación puede aplicarse tanto a proyectos individuales como a grandes portafolios (por ej. ciudades, sistemas/redes, a nivel regional e incluso de país). Siempre y cuando se realicen los ajustes necesarios al modelo para responder a los diferentes niveles de detalle requerido en cada caso. Si bien se describen tres tipos de análisis probabilistas, cabe notar que es posible aplicar otros tipos al combinar varios de sus elementos de distintas maneras. Por ejemplo, se puede crear modelos donde algunas componentes son tratados de forma completamente probabilista, otros de forma probabilistas simplificado y otros de forma determinista.	**Evaluación totalmente probabilista:** para el la teoría probabilista y estadística; así mismo, comportamiento y la respuesta estructural re de la intensidad de la amenaza, exposición y las incertidumbres en el modelo. El tratamien probabilidades de pérdidas. Con base en dich pérdida anual esperada (PAE) y las pérdidas m **Evaluación probabilista simplificada:** en est de la amenaza. Los periodos de retorno se de estadístico de mediciones instrumentales de eventos pasados y (iii) el análisis estadístico d para tratar de cubrir todo el espectro de even Periodos de retorno de la amenaza considera (curvas de vulnerabilidad o fragilidad usadas requerimientos para calcular el riesgo utilizan se propagan en el modelo. Esto todavía perm periodos de retorno para un análisis adecuad de los resultados de los periodos de retorno e Unido como un ejemplo). Este enfoque es ma más en los detalles de cada componente. **Evaluación mixta probabilista-determinista** otros de manera determinista. Por ejemplo, s solo algunos periodos de retorno (probabilist de manera determinista y la vulnerabilidad d que algunos de los módulos no cumplen con incertidumbres aleatorias no se propagan en obtener la PAE y un proxy de la CEP y PMP ap de la amenaza. Este método puede utilizarse modelos de elementos finitos y resulta impra modelación de modelos de riesgo complejos

Nota:
1. Método utilizado por Hazus para huracanes.
2. Método utilizado por Hazus inundaciones, sismos y tsunamis.
3. Se requiere desarrollo de código para implementar los métodos por parte del usuario en RiskScape.
4. Se requiere desarrollo de código para implementar los métodos por parte del usuario en Delft-FIAT.

de evaluación de riesgo

Herramienta	CAPRA	HAZUS	RiskScape	OASIS LMF	IN-CORE	CLIMADA	CATSIM	RiskChanges	FloodRisk	Delft-FIAT	HEC-FDA	OpenQuake
módulo de amenaza, se generan decenas, cientos o miles de eventos estocásticos siguiendo todos estos eventos se utilizan en el cálculo de riesgo. Para el módulo de vulnerabilidad, el eciben un tratamiento probabilista total para integrar los eventos estocásticos y los valores vulnerabilidad para calcular daños esperados y sus probabilidades asociadas, propagando nto totalmente probabilista de los cálculos del riesgo da como resultado la distribución de na distribución, se obtienen las métricas de riesgo: la curva de excedencia de pérdidas (CEP), la máximas probables (PMP).	✓	✓ [1]	✓ [3]	✓	✓	✓				✓ [4]	✓	✓
te caso, en lugar de usar simulaciones estocáticas, se modelan solo algunos periodos de retorno efinen a través de diferentes metodologías. Algunas de las más frecuentes son: (i) el análisis e eventos que generan las amenazas (precipitación, terremotos); (ii) el análisis geomorfológico de le registros históricos (encuestas, artículos de periódicos). Los periodos de retorno son elegidos ntos posibles, desde eventos recurrentes hasta eventos esporádicos. Las pérdidas para los ados son estimados al combinar estos resultados de la amenaza con el módulo de vulnerabilidad de forma probabilista). No obstante, debido a que el módulo de amenaza no cumple con los ndo el método totalmente probabilista, las incertidumbres aleatoras asociadas a la amenazano nite calcular la PAE si se utilizan varios periodos de retorno (en general se requieren cinco o más do). Es posible obtener una aproximación o proxy de la CEP y PMP mediante una extrapolación estimados pero esto incorpora incertidumbres adicionales al modelo (véase el manual de Reino ás apropiado para infraestructuras individuales dado que el método de cálculo permite ahondar	✓	✓ [2]	✓ [3]	✓	✓	✓	✓	✓	✓	✓ [4]	✓	✓
a: en este método algunos componentes del riesgo son modelados de manera probabilista y suelen darse los siguientes casos: (i) la amenaza se modela de manera probabilista y se utilizan a simplificado) y la vulnerabilidad se evalúa de manera determinista, o (ii) la amenaza se modela le manera probabilista, un enfoque común para evaluar el riesgo por deslizamientos. Dado los requerimientos para calcular el riesgo utilizando el método totalmente probabilista, las el modelo. Para el primer caso, y de manera similar al caso probabilista simplificado, se puede olicando una extrapolación de los valores de pérdida correspondientes a los periodos de retorno para estimar la respuesta de infraestructura complejas donde, por ejemplo, se requieren áctico modelar un gran número de escenarios de la respuesta estructural. Así mismo, en la s, es más viable utilizar una combinación de los métodos probabilistas y deterministas.	✓	✓ [2]	✓ [3]	✓	✓	✓	✓	✓	✓	✓ [4]	✓	✓

Tabla 17. Resumen de los métodos de cuantificación de incertidumbre disponibles en herramientas para evaluación completamente probabilista

Métodos probabilistas de evaluación de riesgo	
Herramienta	**Enfoque para la cuantificación de incertidumbre en el análisis de riesgo completamente probabilista**
Hazus Huracán	Las consecuencias de un huracán se estiman mediante un conjunto probabilístico de eventos. El modelo de simulación de la trayectoria de la tormenta se inicia muestreando aleatoriamente una posición inicial, fecha, hora, dirección y velocidad de traslación de una de las tormentas tropicales dadas en la base de datos HURDAT. El número de tormentas que se simularán en cualquier año se obtiene muestreando de una distribución binomial negativa con un valor medio de 8.4 tormentas por año y una desviación estándar de 3.56 tormentas por año (FEMA 2022b). El modelo de pérdidas es un modelo físico que calcula las pérdidas económicas directas utilizando una combinación de técnicas de costos explícitas e implícitas (FEMA 2022b). El modelo de viento de Hazus Huracanes sigue un enfoque probabilista basado en la metodología de amenaza-carga-resistencia-daño-pérdida, desarrollada desde un marco de riesgo individual. El desempeño de los edificios frente a vientos extremos se formula probabilísticamente mediante conceptos de fiabilidad estructural. Se estima la probabilidad de falla de elementos individuales (como ventanas o puertas) comparando la carga del viento con la resistencia del elemento. A través de simulaciones en distintos tipos de edificios, se calculan las probabilidades de daño y se establecen relaciones entre la intensidad del viento y el daño físico. La pérdida anual promedio por huracanes considera todas las pérdidas futuras causadas por la amenaza de huracán que resulten de posibles eventos de amenaza con diferentes magnitudes y períodos de retorno promediados por año (FEMA 2022b).
CAPRA	Teorema de la probabilidad total para calcular la tasa de excedencia de pérdidas, considerando la incertidumbre en la intensidad del evento y en la respuesta estructural. $$\mathrm{v}(p) = \sum_{i=1}^{Eventos} \Pr\left(P > p \,\middle|\, \text{Evento } i\right) \cdot F_A\left(\text{Evento } i\right)$$ La tasa de excedencia de los valores de pérdida v(p) está dada en función de $\Pr(P > p \mid Evento\ i)$ la probabilidad de excedencia de pérdida dado que ocurre el evento i, y $F_A\ (Evento\ i)$ la frecuencia anual de ocurrencia del evento i. $$\mathrm{PAE} = \sum_{i=1}^{Eventos} E\left(P \,\middle|\, \text{Evento } i\right) F_A\left(\text{Evento } i\right)$$ La PAE es la pérdida anual esperada donde $E\left(P \,\middle|\, \text{Evento } i\right)$ es la pérdida esperada del evento i, y $F_A\left(Evento\ i\right)$ es su frecuencia anual de ocurrencia.
OASIS LMF	Conjunto de eventos representativo de todos los posibles eventos que pueden ocurrir, junto con su intensidad y probabilidad durante un período de tiempo suficientemente largo como para abarcar una distribución completa. $$p_{id} = p^{f}_{i} * p^{v}_{d}$$ Donde: $\boldsymbol{p_{id}}$ es la probabilidad de que ocurra una intensidad $\boldsymbol{i}$ y cause un daño $\boldsymbol{d}$. $\boldsymbol{p^{f}_{i}}$ es la masa de probabilidad para el intervalo de intensidad. $\boldsymbol{p^{v}_{d}}$ es la masa de probabilidad para el intervalo de daño. Este cálculo de P_{id} se realiza para cada combinación de evento, área de amenaza ($peril$) y función de vulnerabilidad. Luego, P_{id} se suma a través de los intervalos de intensidad: $$p_d = \sum_i p_{id}$$ Esto da como resultado pd, que es la probabilidad de un intervalo de daño d para cada evento, área de amenaza y función de vulnerabilidad. **1. Integración Determinística** $$x_{\varepsilon Y} = \mathrm{tiv}_Y * d_{\varepsilon Y}$$

Métodos probabilistas de evaluación de riesgo	
Herramienta	**Enfoque para la cuantificación de incertidumbre en el análisis de riesgo completamente probabilista**
	Donde: x_{EY} es la pérdida en un evento E y cobertura Y. tiv_Y es el valor total asegurado. d_{EY} es el factor de daño. **2. Muestreo aleatorio (Montecarlo)**
CLIMADA	Análisis determinístico y probabilístico y análisis de incertidumbre y sensibilidad con métodos de Montecarlo. $x_{ij} = val_j f_{imp}(h_{ij} \mid y_j)$ Donde: x_{ij} y h_{ij} son, respectivamente, el daño y la intensidad de la amenaza debido al evento i en la ubicación j, val_j el valor de exposición en la ubicación j, y_j son los parámetros de exposición j que caracterizan su vulnerabilidad y f_{imp} la función de daño. $\sum EAI_j = \sum_{\bar{\imath}=1}^{N_{hist}} \sum_{\hat{\imath}} x_{\hat{\imath}} F(E_{\bar{\imath}}) = \sum_{i=1}^{Nev} x_{ij} F(E_i)$ EAI_j es el daño anual esperado del elemento j, donde X es la variable aleatoria de daño, E su expectativa, E_i es un evento y F su frecuencia (anual). N_{hist} es el número de eventos históricos, $\bar{\imath}$ representa un evento histórico, $\hat{\imath}$ representa a todos los miembros del conjunto del evento $\bar{\imath}$, y Nev representa el número total de eventos.
HEC-FDA	Cuantificación de incertidumbre en riesgo por inundación mediante simulación de Montecarlo para muestreo de curvas incluyendo el funcionamiento de obras de protección contra inundaciones. $E[X] = \int_{-\infty}^{\infty} x f_x(x)\,dx = \int_{-\infty}^{\infty} (1 - F_x(x))dx \qquad F_x(x) = P(x \le x)\; y\; 1 - F_x(x) = P(X \ge x)$ Donde: X = consecuencias, como por ejemplo el daño causado por la inundación, pérdida de vidas, o costos de atención de emergencia. $E[X]$ = valor esperado de las consecuencias x = valor de las consecuencias $f_x(x)$ = función de densidad de la probabilidad de X $F_x(x)$ = función de distribución acumulada de X
OpenQuake	Cálculo con base en escenarios, eventos probabilísticos, basado en PSHA clásico **1. Escenarios** $LR = \frac{\sum_{n=1}^{m} LR_n \mid \mathrm{IML}}{m}$ LR es la tasa de pérdida media para cada activo en todas las simulaciones posibles del evento, donde m representa el número de campos de movimiento del suelo simulados y IML niveles de medida de intensidad. **2. Eventos probabilísticos** $\lambda(L_n) = \frac{NE_L}{TSES}$ λ representa la tasa de excedencia de la ratio de pérdida respectivo, NE_L representa el número de excedencias de la pérdida dada, y $TSES$ representa el período de tiempo de todos los conjuntos de eventos estocásticos. $PE(L_n) = 1 - exp - \lambda_n \times t$ $PE(L_n)$ la probabilidad de excedencia del conjunto de pérdidas en un período de tiempo dado



SECCIÓN

4

Imagen: Adobe Stock

MÉTODOS QUE INCORPORAN VULNERABILIDAD SOCIAL Y/O GOBERNANZA EN LOS ANÁLISIS DE RIESGO

4.1. INTRODUCCIÓN



Imagen: Adobe Stock

Un enfoque holístico proporciona información fundamental que complementa las evaluaciones de riesgo de desastres, ayudando a los tomadores de decisiones a entender las causas específicas de las pérdidas significativas en grupos vulnerables (Nkwunonwo et al. 2015). La necesidad de incluir factores sociales, económicos, ambientales y físicos en las evaluaciones de vulnerabilidad está integrada en el Marco de Acción de Hyogo y enfatizada en el Marco de Sendai para la Reducción del Riesgo de Desastres 2015-2030, que establece la comprensión de los riesgos de desastre en todas sus dimensiones como una prioridad (United Nations General Assembly 2015).

La cuantificación de la dimensión física de la vulnerabilidad puede realizarse mediante métodos empíricos y analíticos (Sterlacchini et al. 2014). Sin embargo, cuando se consideran las múltiples dimensiones de la vulnerabilidad, surgen desafíos en la medición de aspectos que no se pueden cuantificar fácilmente. Birkmann (2006) sugiere que los indicadores e índices pueden utilizarse para medir la vulnerabilidad desde una perspectiva integral y multidisciplinaria, capturando tanto los impactos físicos directos (exposición y susceptibilidad) como los impactos indirectos (fragilidad socioeconómica y falta de resiliencia). La importancia de los indicadores radica en su potencial uso para la gestión de riesgos, ya que son herramientas útiles para (i) identificar y monitorear la vulnerabilidad a lo largo del tiempo y el espacio, (ii) desarrollar una mejor comprensión de los procesos subyacentes a la vulnerabilidad, (iii) desarrollar y priorizar estrategias para reducir la vulnerabilidad y (iv) determinar la efectividad de estas estrategias (Rygel et al. 2006). Sin embargo, el desarrollo, prueba e implementación de indicadores que capturen la complejidad de la vulnerabilidad continúa siendo un desafío.

Aunque el desarrollo extensivo de herramientas de geoprocesamiento y análisis estadístico ofrece un marco sólido para la construcción de indicadores, la disponibilidad desigual de datos en distintas regiones geográficas y los desafíos asociados con la captura de los determinantes de vulnerabilidad en comunidades específicas hacen que la creación de indicadores e índices de vulnerabilidad sea una tarea compleja y desafiante.

El proceso para la construcción de indicadores comienza con el desarrollo de un marco teórico que proporciona la base conceptual necesaria. A continuación, se seleccionan las variables relevantes que deben representar las múltiples dimensiones de la vulnerabilidad. En caso de datos faltantes, se procede con la estimación de los mismos para completar la información necesaria. Posteriormente, se realiza un análisis multivariante para explorar las relaciones entre las variables. Este proceso generalmente incluye la normalización de datos para asegurar la comparabilidad entre diferentes conjuntos. Luego, se lleva a cabo la ponderación y agregación de las variables para construir el indicador final. Finalmente, se evalúan la robustez y la sensibilidad del indicador, y se puede realizar un análisis de incertidumbre (OECD y JRC, 2008). Existen diversos métodos para cada uno de estos pasos. Por ejemplo, en el análisis multivariante se pueden utilizar técnicas como el análisis de componentes principales, el análisis factorial, el coeficiente alfa de Cronbach y el análisis de clústeres entre otros. En cuanto a la ponderación, se pueden emplear métodos como el análisis de componentes principales o el análisis jerárquico, entre otros (OECD y JRC 2008).

Los métodos estadísticos generalmente están disponibles en paquetes de funciones de R o Python, así como en software de información geográfica (SIG) como QGIS y ArcGIS. Sin embargo, el mayor desafío radica en la construcción de indicadores que se ajusten a la disponibilidad de información y que capturen de manera adecuada las dimensiones específicas de la vulnerabilidad en cada comunidad.

En este capítulo se presenta una revisión de las herramientas gratuitas disponibles para la construcción de indicadores de vulnerabilidad. Sin embargo, cabe destacar que no existe un marco único y universalmente aceptado para la construcción de los indicadores.

4.2. MÉTODOS INCORPORADOS EN EL PLUG IN THE OPENQUAKE



Imagen: Adobe Stock

El plugin OpenQuake Integrated Risk Modelling Toolkit (IRMT) es una herramienta desarrollada por GEM[14] que se integra con QGIS para una evaluación integral del riesgo sísmico y cualquier otro tipo de riesgo. Facilita la creación de indicadores que permiten evaluar características socioeconómicas relacionadas con la vulnerabilidad y el riesgo. El plugin también integra la capacidad de respuesta de las poblaciones y combina medidas de riesgo físico y social. Permite a los usuarios desarrollar un flujo de trabajo integrado para la construcción de métricas que evalúan las características sociales que afectan el riesgo sísmico, proporcionando una plataforma basada en SIG para la creación de indicadores e índices compuestos, lo que fomenta evaluaciones comparativas (GEM 2024c).

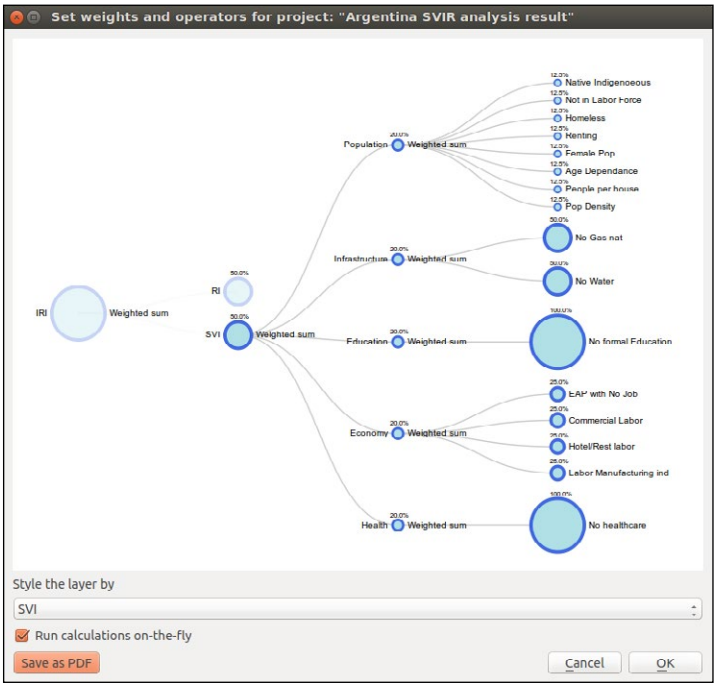
El OpenQuake IRMT facilita la integración de indicadores compuestos de características socioeconómicas con medidas de riesgo físico, como estimaciones de pérdidas humanas o económicas, provenientes del OpenQuake Engine (OQ-engine) o de otras fuentes. El plugin puede ser utilizado para cualquier tipo de desarrollo de indicadores (GEM 2024c).

[14] https://www.globalquakemodel.org/products

El plugin OpenQuake IRMT ofrece varias capacidades para la creación y gestión de indicadores compuestos en el análisis de riesgo. Los usuarios pueden definir procedimientos de ponderación y agregación para los indicadores, que pueden ser simples (ponderación igual) o más complejos (ponderaciones específicas, agregación lineal o geométrica). Además, proporciona una interfaz gráfica dinámica, que facilita la creación y edición de modelos compuestos mediante un árbol de ponderación y agregación (ver **Figura 13**). Esta interfaz permite a los usuarios desarrollar modelos de manera visual y sencilla.

La estructura de árbol permite el desarrollo de modelos jerárquicos de riesgo integrado. El punto de partida es un nodo raíz que corresponde al desarrollo de un modelo jerárquico que puede ser: 1) un Índice Integrado de Riesgo (IRI) que es función de la agregación de un Índice de Vulnerabilidad Social (IVS) y un Índice de Riesgo (IR); o 2) un Índice de Vulnerabilidad Social (IVS) que es el resultado de la agregación de varios subindicadores definidos por el usuario (por ejemplo, Economía, Educación y Medio Ambiente, etc.). El árbol se puede modificar dinámicamente agregando o eliminando nodos, invirtiendo variables, estableciendo un peso a cada variable o nodo y eligiendo los operadores que se utilizarán para combinar variables.

Figura 13. Estructura de árbol para el desarrollo de indicadores compuestos



Fuente: GEM (2024c).

El plugin soporta dos tipos principales de modelos compuestos para indicadores:

1. **Modelos Deductivos:**
   Generalmente usan menos de diez indicadores normalizados y agregados.
2. **Modelos Jerárquicos:**
   Utilizan de diez a veinte indicadores, agrupados en subíndices (por ejemplo, población, economía) que se agregan para formar un índice compuesto final (por ejemplo, índice de vulnerabilidad social).

Los usuarios pueden modificar el árbol de indicadores compuestos agregando o eliminando nodos, asignando pesos, y eligiendo operadores para combinar variables. Los cambios se reflejan inmediatamente en los cálculos y visualizaciones.

Los cálculos de riesgo físico y los índices compuestos se pueden ejecutar directamente en QGIS, con los resultados mostrados como capas vectoriales.

El plugin ofrece operadores básicos para combinar variables, y los usuarios pueden definir fórmulas personalizadas para el cálculo de los indicadores. Las técnicas de ponderación pueden basarse en modelos estadísticos o enfoques participativos.

4.3. PLUGINS THE QGIS PARA ANÁLISIS MULTICRITERIO

QGIS, una plataforma de software libre para Sistemas de Información Geográfica (SIG), es ampliamente utilizada para realizar análisis multicriterio (MCA), una metodología comúnmente empleada en la creación de indicadores de vulnerabilidad y riesgo. En QGIS, el MCA se puede realizar directamente utilizando las capacidades de cálculo entre capas vectoriales o ráster, o mediante el uso de plugins especializados que facilitan la creación de indicadores y el análisis de datos complejos. Entre los más destacados se encuentran el Spatial Sustainability Assessment Model (SSAM) y el Weighted Multi-Criteria Analysis (WMCA).

4.3.1. Spatial Sustainability Assessment Model (SSAM)[15]

SSAM es un plugin de QGIS diseñado para la evaluación de sostenibilidad en entornos geográficos, utilizando criterios ambientales, económicos y sociales. Implementa el algoritmo TOPSIS, que genera un ranking basado en la distancia al peor punto y la proximidad a un punto ideal para cada criterio. Los pesos pueden ingresarse directamente o mediante una tabla de comparación por pares, lo que permite al usuario definir un vector de pesos final de manera repetible y verificable. SSAM produce tanto salidas geográficas como gráficas, mostrando mapas de los resultados del análisis multicriterio y valores numéricos de sostenibilidad mediante barras, burbujas y puntos.

SSAM también implementa el algoritmo DOMLEM basado en la teoría “dominance based rough set”, permitiendo al usuario conocer las reglas decisionales derivadas del algoritmo TOPSIS y tener una mejor visión del ranking de sostenibilidad mostrado en mapas y gráficos. Este enfoque incrementa significativamente la transparencia y la capacidad de análisis.

El plugin utiliza archivos vectoriales geográficos (*shapefiles*), donde los datos gráficos representan las unidades de evaluación y los datos alfanuméricos describen los indicadores ambientales, económicos y sociales. Los algoritmos del plugin permiten tratar estos indicadores por separado y calcular tres índices diferentes, cuya combinación lineal da un índice general de sostenibilidad para cada unidad geográfica.

El usuario puede emplear una amplia variedad de indicadores o un conjunto de datos preparado por él mismo. Los indicadores a utilizar dentro de un análisis corresponden a los atributos que el usuario asigne en el archivo base (*shapefile*) de su análisis. Debido a esta flexibilidad, aunque el plugin fue creado para análisis de sostenibilidad podría ser adaptado para el cálculo de indicadores de riesgo considerando múltiples criterios socio-económicos.

4.3.2. Weighted Multi-Criteria Analysis (WMCA)[16]

El plugin WMCA es otra herramienta clave en QGIS para realizar análisis multicriterio ponderado. Este plugin permite a los usuarios asignar pesos específicos a diferentes criterios y calcular una evaluación combinada basada en esos pesos. El plugin muestra los valores de los píxeles de un ráster al usuario, permitiendo asignar pesos a cada ráster y calificaciones a cada clase dentro de ellos. Fue desarrollado para realizar análisis multicriterio ponderados, especialmente en estudios ambientales como análisis de fragilidades o favorabilidades, zonificación ambiental y otros tipos de zonificación.

[15] http://maplab.alwaysdata.net/doc/html/index.html

[16] https://github.com/romariocarvalhoneto/Weighted-Multi-Criteria-Analysis---WMCA

SECCIÓN 5



Imagen: Adobe Stock

CAMBIO CLIMÁTICO Y CÁLCULOS DE RIESGO

5.1. INTRODUCCIÓN



Imagen: Adobe Stock

La incorporación del cambio climático en la estimación del riesgo exige metodologías robustas que permitan estimar con los impactos futuros potenciales sobre la infraestructura y la población. En este contexto, la modelación de riesgo bajo diferentes escenarios climáticos se vuelve fundamental para informar estrategias de adaptación y resiliencia.

En esta sección, se presenta la revisión de los enfoques de las plataformas presentadas en la sección 2 para incorporar el cambio climático en los cálculos de riesgo, con un enfoque particular en la plataforma CLIMADA.

5.2. ESTIMACIÓN DE RIESGO INCORPORANDO CAMBIO CLIMÁTICO EN LAS PLATAFORMAS


Imagen: Adobe Stock

Entre todas las plataformas revisadas, CLIMADA es la única que cuenta con métodos específicos para el análisis del cambio climático en la evaluación del riesgo. Esto la convierte en una herramienta particularmente útil para la toma de decisiones en contextos de incertidumbre climática, ya que permite evaluar no solo los riesgos actuales, sino también su evolución bajo diferentes trayectorias de emisiones.

Sin embargo, esto no significa que las demás plataformas multiamenaza o de inundaciones sean incapaces de incorporar el cambio climático en sus cálculos de riesgo. Siempre que la modelación de la amenaza incluya escenarios climáticos proyectados, es posible evaluar el riesgo incorporando el impacto del cambio climático en cualquiera de ellas. La evaluación de amenaza futura requerirá proyecciones o escenarios relacionados con cambio climático, los cuales deben ser generados a partir de modelos climáticos que permitan estimar cambios en variables clave como la precipitación, la temperatura y el nivel del mar.

En el caso de las inundaciones, por ejemplo, los métodos para analizar las proyecciones de precipitación y convertirlas en caudales que puedan ser utilizados en modelos hidrodinámicos para generar capas de amenaza bajo escenarios de cambio climático pueden agruparse en tres enfoques principales, como se muestra en la **Tabla 18**. Estos enfoques incluyen el uso de proyecciones basadas

en modelos climáticos a los cuales se aplican técnicas de escalamiento o downscaling para refinar proyecciones globales a escalas locales. A través de este tipo de metodologías, es posible generar escenarios de amenaza que, al ser combinados con escenarios de crecimiento económico, urbano y poblacional, permiten una evaluación del riesgo considerando la incertidumbre del clima futuro y facilitan la formulación de estrategias de adaptación y mitigación.

Es importante mencionar que no existe una metodología consensuada para estimar la amenaza de inundación bajo la influencia del cambio climático (Wasko et al. 2021), sino una gran cantidad de métodos reportados en la literatura que varían ampliamente según la escala, el propósito de los análisis y el lugar de aplicación. La selección del método adecuado depende de factores como la disponibilidad de datos, la resolución espacial y temporal requerida, así como la incertidumbre inherente a las proyecciones climáticas.

Tabla 18. Metodologías para la incorporación del cambio climático en el análisis de inundaciones

Método	Descripción	Ventajas	Desventajas
Enfoques heurísticos basados en razonamientos físicos	Estiman cambios en la precipitación utilizando principios físicos, como un aumento promedio global del 2% $°C^{-1}$ para lluvias promedio y del 6–7% $°C^{-1}$ para eventos extremos debido a la mayor capacidad de la atmósfera para retener humedad.	Simples de aplicar; basados en principios físicos comprensibles.	No capturan la complejidad de los cambios futuros; pueden ser demasiado generales para casos específicos.
Proyección de tendencias históricas	Extrapolan tendencias observadas en datos históricos, asumiendo que las relaciones causales observadas, como la no estacionariedad en las precipitaciones, se mantendrán constantes en el futuro.	Aprovechan datos observados y pueden reflejar cambios ya en curso.	Asumen que las relaciones observadas permanecen constantes; pueden confundirse con otros factores, como urbanización.
Proyecciones basadas en modelos climáticos globales	Utilizan modelos climáticos para simular cambios futuros a gran escala, que luego se escalan a nivel local mediante métodos estadísticos o dinámicos para estimar crecientes de diseño.	Representan procesos físicos complejos a escala global; permiten análisis detallados con múltiples escenarios.	No capturan procesos clave a escala local; pueden introducir sesgos; requieren escalamiento y recursos computacionales

Fuente: Wasko et al. (2021).

Aunque CLIMADA puede procesar una capa de amenaza generada a través de cualquier método que considere el cambio climático, su desarrollo está alineado con la metodología de Economía de la Adaptación Climática (Souvignet et al. 2016), lo que la hace especialmente diseñada para evaluar el impacto económico del cambio climático y las posibles estrategias de adaptación. En las secciones siguientes, se presentará esta metodología junto con las capacidades específicas de CLIMADA para la evaluación del riesgo climático.

5.3. ENFOQUE DE CAMBIO CLIMÁTICO EN CLIMADA



Imagen: Adobe Stock

CLIMADA es la herramienta utilizada para la metodología de Economía de la Adaptación Climática (ECA, por sus siglas en inglés) desarrollada por la Universidad de Naciones Unidas UNU-EHS y el Banco de Desarrollo del Estado de la República Federal de Alemania KfW.

La ECA es un enfoque diseñado para identificar de manera flexible y sistemática las medidas de adaptación al cambio climático (CCA) más rentables en distintos sectores y proyectos. Su objetivo principal es responder a tres preguntas clave: ¿cuáles son los posibles daños relacionados con el clima en las próximas décadas?, ¿qué parte de esos daños puede evitarse y mediante qué medidas de adaptación?, y ¿qué inversiones se requieren para implementar dichas medidas, asegurando que los beneficios superen los costos? Este enfoque permite evaluar riesgos climáticos de manera estructurada, fomentando la transparencia y facilitando discusiones intersectoriales entre los diferentes actores involucrados. Además, puede aplicarse en distintos niveles, desde el nacional hasta el local, y en diversos sectores y tipos de amenazas climáticas (Souvignet et al. 2016).

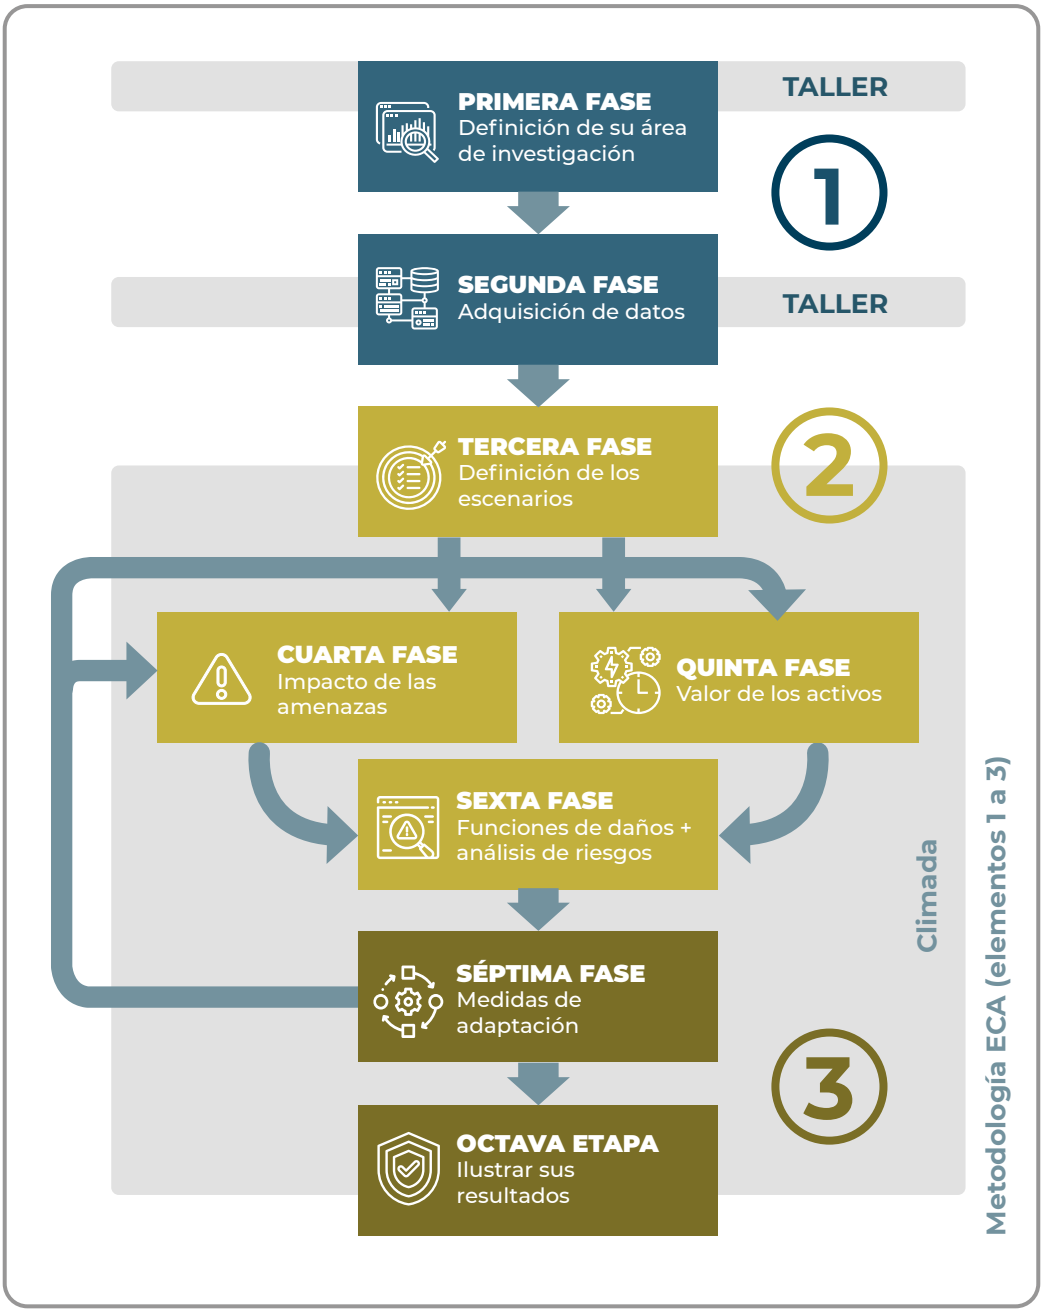
La ECA proporciona un marco práctico para que tomadores de decisión a nivel nacional y local evalúen de manera integral los riesgos climáticos que enfrentan sus economías, minimizando los costos de adaptación mediante estrategias eficientes. Basada en un enfoque robusto y científico, la metodología se compone de tres elementos principales como se muestra en la **Figura 14**: (1) identificación del riesgo climático, analizando amenazas, poblaciones y sectores vulnerables en una región determinada; (2) cuantificación del riesgo climático, evaluando los daños esperados en distintos escenarios climáticos y económicos; y (3) identificación y priorización de medidas de adaptación, utilizando análisis costo-beneficio para definir estrategias óptimas. Además, la ECA se divide en 8 fases como se muestra en la Figura 15. Las primeras dos fases establecen el área de estudio y gestionan la adquisición de datos clave. Posteriormente, se definen los escenarios climáticos y socioeconómicos presentes y futuros (Fase 3), se modelan las amenazas identificadas (Fase 4), se valoran los activos expuestos (Fase 5) y se generan funciones de daño para realizar el análisis de riesgo (Fase 6). En las fases finales, se simulan medidas de adaptación (Fase 7) y se presentan los resultados para la toma de decisiones (Fase 8). A lo largo del proceso, se utiliza CLIMADA como herramienta principal particularmente para las fases 3 a 8 (Souvignet et al. 2016).

Figura 14. Elementos de la metodología ECA



Fuente: Souvignet et al. (2016)

Figura 15. Fases de la metodología ECA



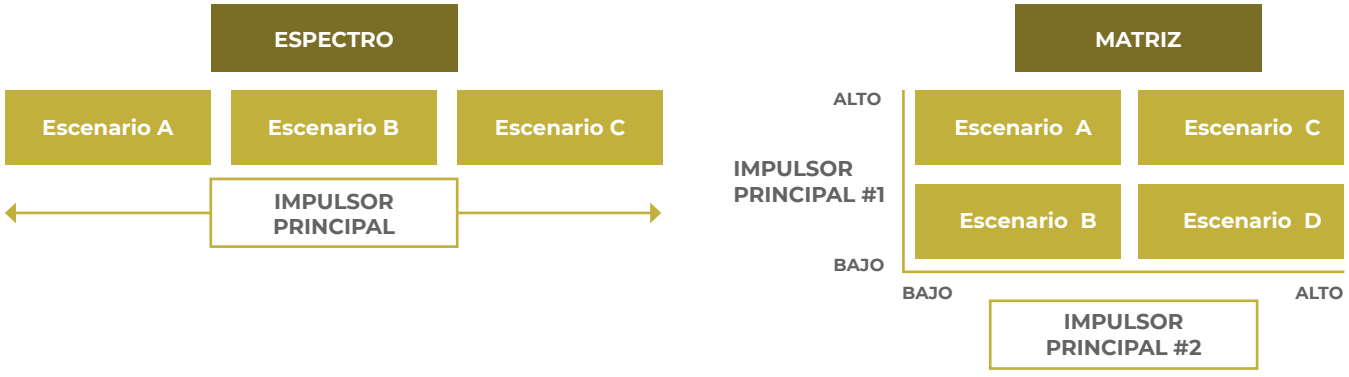
Fuente: Souvignet et al. (2016).

La fase 3 que involucra la construcción de escenarios comienza con la descripción consistente de posibles futuros, evaluando el impacto de la variabilidad y el cambio climático sobre la población y los activos en riesgo. Para ello, se siguen tres pasos clave (Souvignet et al. 2016):

Paso 1	Paso 2	Paso 3
Se analiza la situación actual y se identifican los factores clave que influirán en la magnitud y características de los impactos climáticos, como el crecimiento económico, la variabilidad climática, el aumento poblacional, y avances tecnológicos. Es importante que estos escenarios sean coherentes con los planes de desarrollo existentes y que se limite su número para facilitar el análisis.	Se define el horizonte temporal más adecuado, equilibrando la necesidad de proyecciones realistas con la incertidumbre inherente a escenarios de largo plazo. La documentación de ECA recomienda un período mínimo de 20 a 30 años, considerando diferentes horizontes (corto, mediano y largo plazo) para evaluar los efectos del cambio climático sobre activos e inversiones.	Se desarrollan los escenarios climáticos utilizando proyecciones basadas en modelos climáticos, estudios científicos y datos históricos. Estos escenarios pueden incluir eventos extremos como huracanes intensos, aumento del nivel del mar o cambios en la precipitación.

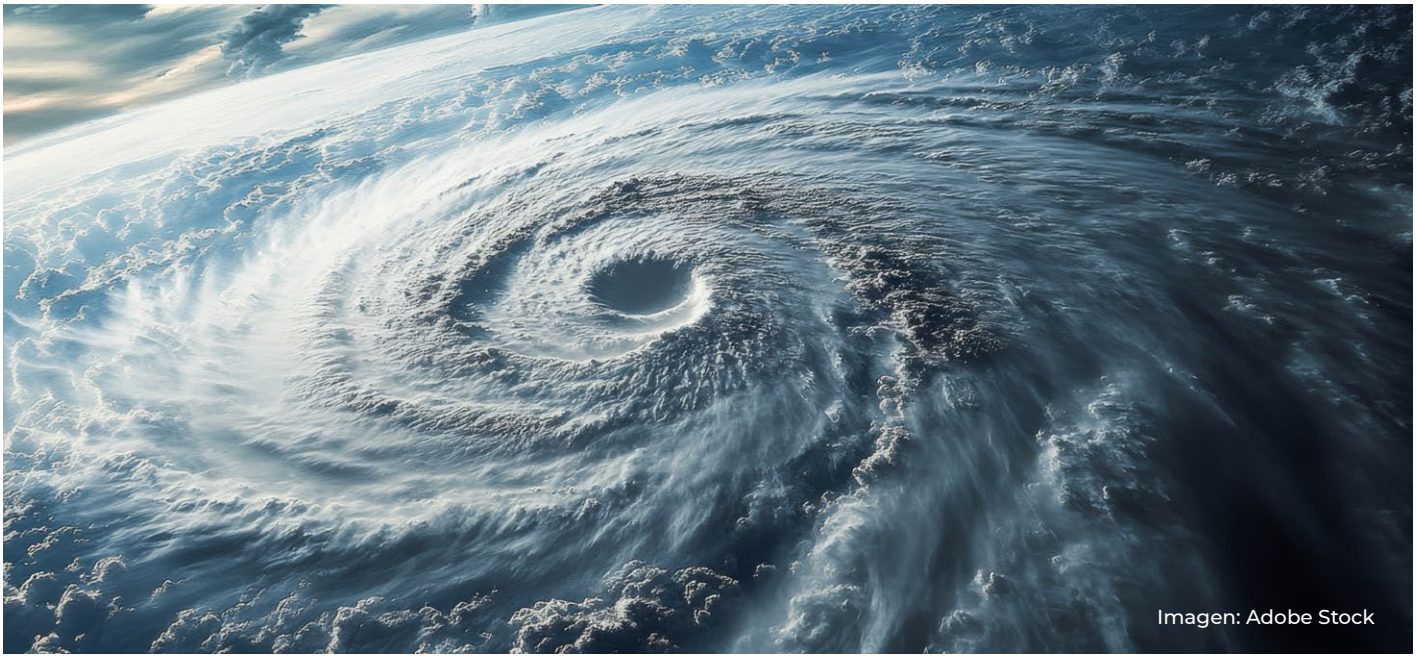
Finalmente, los escenarios climáticos y socioeconómicos se combinan en una matriz agregada (ver **Figura 16**) que facilita la comunicación con las partes interesadas y permite su integración en CLIMADA para la evaluación de medidas de adaptación.

Figura 16. Tipos de agregación de escenarios



Fuente: Souvignet et al. (2016).

5.3. MÉTODOS INCORPORADOS EN CLIMADA PARA CAMBIO CLIMÁTICO


Imagen: Adobe Stock

CLIMADA permite estimar el daño económico esperado como una medida del riesgo actual, así como el incremento derivado del crecimiento económico y el aumento asociado al cambio climático. La metodología de economía de la adaptación al clima, implementada en CLIMADA, proporciona a los tomadores de decisiones una base objetiva para comprender el impacto del clima y los fenómenos meteorológicos en sus economías, incluyendo un análisis costo-beneficio de medidas específicas para la reducción del riesgo (ETH Zurich 2025).

CLIMADA incorpora el cambio climático en el análisis de **ciclones tropicales** a través de la función *apply_climate_scenario_knu*, que implementa cambios en la intensidad y frecuencia de estos eventos basándose en los escenarios climáticos proyectados en el estudio de Knutson et al. (2015). Este estudio utiliza un downscaling dinámico de los escenarios CMIP5/RCP4.5 para estimar cómo la actividad de ciclones tropicales podría evolucionar hacia finales del siglo XXI. Para representar otros escenarios de concentración de gases de efecto invernadero (RCP), CLIMADA interpola los valores de RCP4.5 de acuerdo con su forzamiento radiativo relativo, permitiendo una aproximación simplificada de los efectos del cambio climático sobre los ciclones tropicales (ETH Zurich 2017b).

Es importante destacar que este método de implementación del cambio climático se centra exclusivamente en la modificación de la frecuencia e intensidad de los ciclones tropicales y no captura todos los factores que influyen en el daño causado por estos eventos. La estimación de pérdidas económicas asociadas a huracanes sigue siendo un desafío debido a la alta variabilidad en los registros históricos, ya que los eventos más destructivos suelen ser raros y dependen de condiciones específicas de impacto en tierra (ETH Zurich 2017b).

El módulo RiverFlood de CLIMADA permite generar datos de **inundaciones fluviales** a partir de simulaciones del proyecto ISIMIP (Inter-Sectoral Impact Model Intercomparison Project) (Sven Willner et al. 2024). Mediante el método from_nc(), se extraen datos sobre la profundidad del agua (en metros) y la fracción de área inundada en cada punto central. Estos datos provienen de modelos hidrológicos globales que utilizan distintos forzamientos climáticos.

Los datos de entrada necesarios para el módulo RiverFlood incluyen información espacialmente explícita sobre la profundidad de la inundación y la fracción inundada, disponibles en ISIMIP. Se distinguen dos rondas de simulación:

1 ISIMIP2a (1971-2010)

Utiliza 12 modelos hidrológicos globales (GHMs) con 4 conjuntos de datos climáticos de reanálisis. Los resultados incluyen la profundidad y fracción de inundación máxima anual, con resoluciones de 5 km y 10 km. Se consideran diferentes estándares de protección: sin protección, protección ante eventos de hasta 100 años de retorno y la capa Flopros (Scussolini et al. 2016) con estándares globales.

2 ISIMIP2b (2005-2100)

Emplea 6 GHMs y 4 modelos de circulación global (GCMs) para simular escenarios de cambio climático (RCP 2.6, 6.0 y 8.5). También incluye corridas históricas y preindustriales, manteniendo la misma resolución y estándares de protección que ISIMIP2a.

El método from_nc() permite definir los centroides para diferentes niveles espaciales (países, regiones o global).

Un ejemplo de aplicación de los métodos implementados en CLIMADA para considerar el cambio climático en el análisis de riesgo se observa en el cálculo de riesgo compuesto presentado por Stalhandske et al. (2024). En este estudio, se analizan 5000 años de impactos multiamenaza con efectos espaciales y espacio-temporales compuestos sobre activos físicos y población expuesta a las amenazas de ciclones tropicales (TC) e inundaciones fluviales del proyecto ISIMIP. La amenaza de ciclones tropicales en CLIMADA se basa en conjuntos de trayectorias de TC, que se combinan con un modelo paramétrico

de viento para simular un campo de viento bidimensional. En este trabajo, se utilizan las trayectorias de TC del archivo ISIMIP, generadas por un modelo estadístico-dinámico de ciclones tropicales, ajustadas para cuatro modelos climáticos globales (HadGEM2-ES, MIROC5, IPSL-CM5A-LR y GFDL-ESM2M) del archivo CMIP5, bajo los escenarios de calentamiento RCP2.6 y RCP6.0. En cuanto a las inundaciones fluviales, se derivan mapas globales espacialmente explícitos de áreas inundadas y profundidad de inundación a una resolución de 150'' mediante la implementación de CLIMADA, utilizando datos derivados de las simulaciones ISIMIP2. El conjunto de datos aplicado incluye simulaciones armonizadas de seis modelos hidrológicos globales (GHMs) participantes en ISIMIP2b para los escenarios RCP2.6, RCP6.0 y RCP8.5, aunque en este estudio solo se consideran RCP2.6 y RCP6.0 para mantener la coherencia con la modelación de ciclones tropicales.

Una de las incorporaciones más recientes a CLIMADA es una API (Interfaz de Programación de Aplicaciones) que permite acceder a datos de exposición y amenaza en una cuadrícula uniforme de 4 km, facilitando evaluaciones de riesgo de manera consistente. Actualmente, la API incluye conjuntos de datos de amenaza globales para ciclones tropicales, sequías, olas de calor, incendios forestales, inundaciones fluviales y rendimiento agrícola. Además, ofrece datos específicos para regiones, como tormentas invernales en Europa (Stalhandske et al. 2022). Entre los datos disponibles a través de la API se encuentran los mostrados en la **Tabla 19** que corresponden a los conjuntos de datos de amenaza para los cuales existe un atributo relacionado con escenarios de cambio climático.

Tabla 19. Conjuntos de datos de amenaza disponibles a través de la API de CLIMADA con atributos de cambio climático

Nombre	Descripción
Aqueduct_coastal_flood	Mapas globales probabilísticos de inundaciones costeras para climas históricos y futuros (~1 km de resolución). Disponibles para períodos de retorno de 2 a 1000 años en 2030, 2050 y 2080 bajo los escenarios RCP 4.5 y 8.5, considerando tres proyecciones de aumento del nivel del mar e incluyendo o excluyendo subsidencia.
Relative_cropyield	Simulaciones globales de producción de cultivos en términos relativos (4 km de resolución), incluyendo maíz, arroz, soya y trigo. Basado en modelos de cultivos y modelos climáticos corregidos por sesgo, facilitados por ISIMIP.
River_flood	Huellas globales de inundaciones fluviales (profundidad de agua y fracción de área inundada) con una resolución de 150 segundos (~4 km en el ecuador). Basado en la salida de CaMa Flood y modelos de circulación global. Disponible por país y escenarios climáticos futuros del IPCC.
Storm_europe	Huellas de tormentas invernales en Europa (ráfagas de viento en m/s). Datos disponibles de proyectos Copernicus WISC (1940-2014) y modelos CMIP6 (1980-2010 y 2070-2100). Cobertura solo para países europeos.
Tropical_cyclone	Huellas de viento de ciclones tropicales (m/s) con una resolución de 150 segundos (~4 km en el ecuador). Datos disponibles globalmente y por país, basados en registros históricos y eventos probabilísticos generados por modelos.
Wildfire	Conjunto de datos globales de incendios forestales con resolución de 4 km, basado en datos satelitales MODIS (2000-2021).

Fuente: ETH Zurich (2025a).

5.4. PUNTOS CLAVE PARA EL ANÁLISIS DE RIESGO BAJO CAMBIO CLIMÁTICO



Imagen: Adobe Stock

En síntesis, la integración del cambio climático en los cálculos de riesgo requiere considerar varios elementos metodológicos que inciden directamente en la calidad y utilidad de los resultados. A continuación, se resumen algunos aspectos clave a tener en cuenta al desarrollar este tipo de análisis, especialmente en contextos de planificación y toma de decisiones para la adaptación.

Puntos clave para el análisis de riesgo bajo cambio climático



Trabajar con múltiples escenarios climáticos:

Es fundamental evitar el uso de un único escenario. El análisis con un conjunto de trayectorias futuras permite capturar mejor la incertidumbre inherente a las proyecciones climáticas.



Considerar la escala de análisis:

La escala espacial y temporal del estudio debe ser coherente con el objetivo del análisis. Las decisiones sobre resolución afectan directamente la interpretación de resultados y la aplicabilidad de las medidas de adaptación.



Elegir cuidadosamente el método de downscaling:

Existen múltiples enfoques (estadísticos, dinámicos, híbridos) para llevar proyecciones globales a escalas locales. La selección debe basarse en la disponibilidad de datos, la región de estudio y los recursos técnicos.



Implementar análisis de sensibilidad en modelos de riesgo:

Es recomendable evaluar cómo los cambios en variables climáticas clave (como precipitación o temperatura) afectan la amenaza y, en consecuencia, el riesgo. Esto fortalece la robustez del análisis y ayuda a priorizar intervenciones.



Aprovechar plataformas que integren proyecciones climáticas con datos de exposición y vulnerabilidad:

Herramientas como CLIMADA permiten evaluar de forma integrada los impactos potenciales del cambio climático y las estrategias de adaptación, facilitando la toma de decisiones basada en evidencia.

SECCIÓN

6



Imagen: Adobe Stock

PRODUCTOS GLOBALES DE PRECIPITACIÓN DE LIBRE ACCESO

6.1. INTRODUCCIÓN


Imagen: Adobe Stock

La precipitación es una de las variables fundamentales para la evaluación del riesgo por inundación, movimientos en masa y sequías. Comprender su variabilidad temporal y espacial es esencial para abordar desafíos del modelamiento de la amenaza. El forzamiento atmosférico en modelos hidrológicos, que incluye la precipitación, puede provenir de reanálisis o de productos satelitales en áreas con escasez de datos de redes hidrometeorológicas. Con varias décadas de registros de alta resolución de datos de precipitación satelital casi globales, estos se han vuelto esenciales para analizar la frecuencia de inundaciones en regiones con poca información (Dis et al. 2018).

En este capítulo se exploran diversas fuentes de datos de precipitación, con énfasis en productos globales de libre acceso. Estos productos, generados a partir de satélites y modelos numéricos, proporcionan información valiosa para el monitoreo y la evaluación del clima, especialmente en regiones donde los datos in situ son escasos o inexistentes. Se realiza una revisión de los principales productos satelitales y de reanálisis, destacando sus características, aplicaciones y limitaciones.

6.2. PRODUCTOS SATELITALES DE PRECIPITACIÓN


Imagen: Adobe Stock

Los satélites utilizan la luz reflejada para detectar, recopilar, medir y registrar la energía electromagnética de la superficie terrestre. Los avances en la teledetección satelital la han convertido en una excelente fuente de datos, ya que puede proporcionar información meteorológica para apoyar la modelización hidrológica. Además, los datos de precipitación obtenidos mediante teledetección tienen el potencial de complementar los sistemas tradicionales de pluviómetros (Masood et al. 2023). Recientemente, los instrumentos de teledetección activa han mejorado considerablemente, proporcionando información detallada con una alta resolución espacial y temporal. Como resultado, ha aumentado tanto el número de productos de precipitación satelital disponibles como la calidad de los datos que generan (Tedla et al. 2024).

Algunos productos de precipitación basados en satélites superan a las tecnologías de medición en tierra en términos de resoluciones espaciales y temporales más altas. Sin embargo, aún presentan ciertos sesgos en comparación con el valor de la precipitación medida con pluviómetros (Q. Zhu et al. 2021).

Los productos satelitales de precipitación en casi tiempo real han demostrado un alto potencial para el monitoreo de inundaciones en cuencas donde no existe una amplia red de pluviómetros, lo que es fundamental para la implementación de un sistema de alerta temprana (Llauca et al. 2021), llegando a producir buenos resultados en el pronóstico de inundaciones con errores en un rango aceptable (Tedla et al. 2024).

También se ha explorado el uso de la precipitación satelital para derivar distribuciones de frecuencia de inundación como el trabajo desarrollado por Dis et al. (2018) en varias subcuencas de la cuenca del río Connecticut, concluyendo que los productos satelitales pueden ser valiosos para derivar frecuencias de inundación en regiones con escasos datos de medición terrestre.

En cuanto al uso de productos con alta resolución temporal, Q. Zhu et al. (2021) evaluaron y compararon estadísticamente la precisión de los productos de precipitación en comparación con observaciones de precipitación in situ a escala horaria encontrando los productos de precipitación satelital de alta temporalidad tienen un gran potencial para la predicción de inundaciones en áreas con datos in situ limitados. Futuros desarrollos deben centrarse en reducir las incertidumbres y mejorar la precisión de las simulaciones hidrológicas para prever mejor los desastres por inundaciones.

Sin embargo, los productos satelitales tienen las siguientes limitaciones:

- Pueden contener errores debido a estimaciones indirectas, incertidumbre en el muestreo y algoritmos utilizados. Las características de estos errores varían considerablemente en función de los climas, tormentas, estaciones y altitudes (Masood et al. 2023). Para utilizar de manera confiable los productos de precipitación satelital en la modelización hidrológica, es necesario validar y mejorar su rendimiento con antelación.

- Múltiples estudios han encontrado que el uso directo de los datos satelitales no es recomendable y que generalmente se requiere una corrección de sesgo (Tedla et al. 2024; Masood et al. 2023).

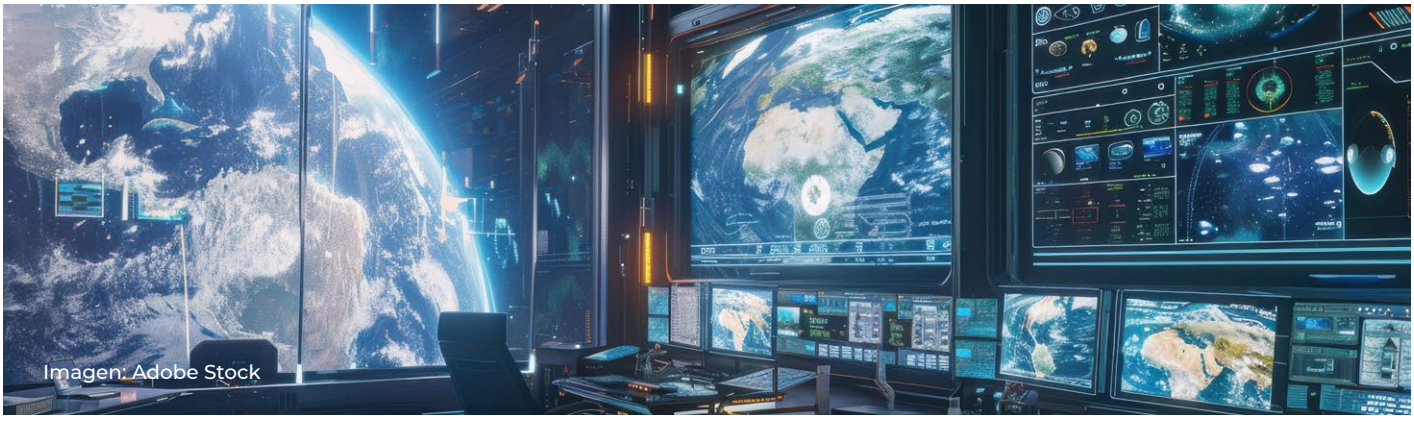
- Estudios como el desarrollado por Sapountzis et al. (2021) analizando el uso de productos satelitales en la evaluación de inundaciones súbitas, encontró que no es posible utilizar los productos satelitales sin calibración y validación previas. Sin embargo, el estudio mostró que la combinación de datos de precipitación satelital con datos de precipitación en tierra puede ser muy útil para el análisis de inundaciones repentinas en cuencas no monitoreadas.

- Los métodos de estimación se encuentran todavía en fase de desarrollo y están experimentando avances considerables continuamente. La estimación de la precipitación por teledetección es todavía un área de investigación relativamente joven, muchos de sus

productos adolecen de imprecisiones considerables (Nguyen et al. 2019). Estos inconvenientes se traducen en grandes incertidumbres que deben entenderse para aprovechar al máximo el potencial de los productos basados en satélites.

Las latitudes septentrional y meridional de aproximadamente 60° limitan la mayoría de los productos cuasiglobales debido a la creciente falta de fiabilidad de las lecturas de datos satelitales a medida que los satélites en órbita geoestacionaria (GEO) se acercan más a los polos (Nguyen et al. 2019).

Debido a estas limitaciones, es fundamental validar la precisión de los productos de precipitación satelital y su aplicabilidad en la zona en la cual serán utilizados. Este proceso de validación puede realizarse mediante análisis estadísticos basados en datos de pluviómetros terrestres y un marco adecuado de modelización hidrológica. El análisis estadístico determina la precisión y consistencia de los datos de precipitación satelital, mientras que la simulación hidrológica aclara su utilidad y aplicación (Masood et al. 2023).


Imagen: Adobe Stock

Por ejemplo, Trinh y Molkenthin (2021) antes de aplicar una técnica desagregación temporal utilizaron los productos de precipitación derivados de satélites para evaluar su precisión en comparación con las mediciones de pluviómetros, con el fin de seleccionar el producto más adecuado para el área de estudio. Posteriormente, desagregaron los datos diarios de pluviómetro a escalas subdiarias, dividiendo la precipitación diaria medida en las estaciones de monitoreo por la precipitación subdiaria acumulada derivada de los datos satelitales, y luego multiplicando este resultado por la precipitación subdiaria satelital. Dentro del procedimiento, también incluyeron un coeficiente de corrección para ajustar la precipitación satelital a una escala local. De este modo, la precipitación satelital en ubicaciones no monitoreadas puede corregirse utilizando la diferencia determinada entre los sitios monitoreados y los productos satelitales de los sitios circundantes.

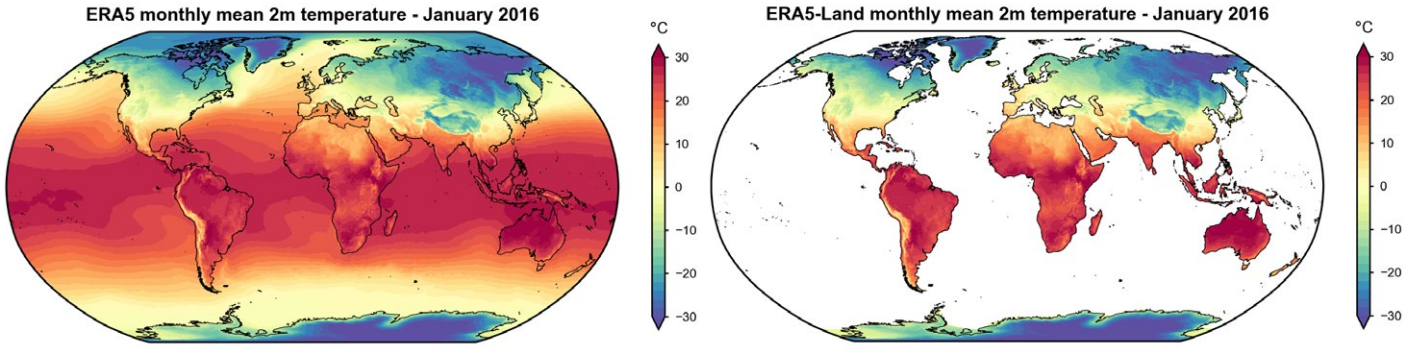
La **Tabla 20** resume las principales características de los productos de precipitación satelital para su potencial uso en la evaluación de amenaza.

Tabla 20. Productos de precipitación satelital

Producto	Resolución espacial más fina	Resolución temporal	Cobertura espacial	Cobertura temporal	Latencia	Información descriptiva
PERSIANN-CCS (CHRS)	0.04°×0.04°	Horaria	Cuasi-global (60°S–60°N; 180°W–180°E)	Enero, 2003 a la fecha	1 hora	Este producto categoriza las características de los parches de nubes en función de la altura de las nubes, la extensión superficial y la variabilidad de la textura estimada a partir de imágenes satelitales (Tedla et al. 2024).
CMORPH (NOAA)	0.07°×0.07° (8 km en el Ecuador)	30 minutos	Cuasi-global (60°S–60°N; 180°W–180°E)	Enero, 1998 a la fecha	18 horas	El Registro de Datos Climáticos (CDR) de Precipitación Satelital - CMORPH consiste en estimaciones de precipitación satelital que han sido corregidas por sesgo y reprocesadas utilizando la Técnica de Morfología del Centro de Predicción Climática (CPC) para crear un análisis de precipitación global de alta resolución.
IMERG (NASA)	0.1°×0.1°	30 minutos	90°S – 90°N; 180°W–180°E	Junio 2000 a la fecha	18 horas	Es el algoritmo más avanzado de la NASA para estimar la precipitación superficial a partir de datos satelitales. El Sistema de Procesamiento de Precipitación genera IMERG en tiempo real (Early y Late IMERG, con latencias de 6 y 18 horas, respectivamente), que se complementa con el IMERG de mayor calidad o de investigación (Final IMERG, con una latencia de 4 meses)(Huffman et al. 2020; NASA 2020).
Hydro-Estimator (NOAA Star)	0.045° ×0.045°	15 minutos	Global 65 S– 65 N	2002 a la fecha	Tiempo real (aprox. 1 hora)	Utiliza datos infrarrojos (IR) de los Satélites Meteorológicos Operativos Geoestacionarios (GOES) de la NOAA para estimar tasas de precipitación. Los productos del H-E se han utilizado en América Central para la alerta temprana de movimientos en masa y en la Guía de Inundaciones Repentinas de América Central (Scofield 1987; Scofield y Kuligowski 2003; Strauch 2009).

Producto	Resolución espacial más fina	Resolución temporal	Cobertura espacial	Cobertura temporal	Latencia	Información descriptiva
GSMaP (JAXA)	0.1°	Diaria	60 N-60 S	2014- a la fecha	4 horas	GSMaP consiste en cuatro tipos de productos: dos en tiempo real (GSMaP-NRT y GSMaP-Gauge NRT) y dos posteriores al tiempo real (GSMaP-Gauge y GSMaP-MVK). Para calcular la precipitación de GSMaP-Gauge NRT con un período de latencia de 4 horas, se utilizan los parámetros de error estimados para el producto posterior al tiempo real de GSMaP-Gauge. GSMaP-Gauge también emplea una combinación de datos de microondas pasivas (PMW) e infrarrojos (IR), junto con un análisis unificado basado en pluviómetros del conjunto de datos globales de precipitación diaria del Climate Prediction Center (CPC) (Masood et al. 2023).
CHIRPS (USGS y CHC)	0.05°	Diaria	50 N-50 S	1981-a la fecha	48 horas	CHIRPS es un conjunto de datos de precipitación cuasi-global que consiste en tres tipos de datos temporales (diarios, pentanales (cada 5 días) y mensuales) con dos tipos de resolución espacial (0.05° y 0.25°). Los datos diarios se consideran datos en tiempo real con un período de latencia de 2 días, mientras que los datos pentanales y mensuales se consideran conjuntos de datos posteriores al tiempo real con un período de latencia de 21 días. Su algoritmo se basa en la duración de nubes frías (CCD) y observaciones de pluviómetros para aproximar la precipitación (Masood et al. 2023).

6.3. PRODUCTOS DE REANÁLISIS



Fuente: European Comission, Copernicus, ECMWF, Climate Change Service
https://climate.copernicus.eu/sites/default/files/inline-images/era5_t2m_201601.png

Los productos de reanálisis se generan utilizando modelos numéricos impulsados por observaciones meteorológicas registradas, creando así una serie histórica de diversas variables climáticas. Estos conjuntos de datos suelen tener cobertura global y abarcan múltiples décadas (ver **Tabla 21** para un resumen de los productos más utilizados y sus atributos). Los datos de precipitación de reanálisis se han utilizado ampliamente en la modelización del riesgo de inundaciones a escalas continental y global. Sus principales ventajas son la amplia cobertura espaciotemporal y la facilidad de acceso. En áreas donde hay un número limitado de pluviómetros que proporcionan observaciones de alta calidad, los productos de reanálisis suelen ser la mejor o única fuente de insumos de precipitación para simulaciones de inundaciones y otras amenazas climáticas. Sin embargo, no se garantiza que representen con precisión eventos extremos ni que caractericen adecuadamente el riesgo de inundación (McClean et al. 2023).

Existen varios productos de reanálisis diferentes, y su calidad varía con las actualizaciones recurrentes. Al igual que los productos satelitales de precipitación, es fundamental evaluarlos cuidadosamente antes de ser utilizados. Por lo tanto, la validación en terreno de la precipitación de reanálisis es muy importante, pero también muy desafiante, especialmente en áreas donde las redes de pluviómetros son escasas. La comparación de los datos de reanálisis con precipitación medida con pluviómetros ha mostrado resultados variables dependiendo de los enfoques utilizados, regiones y escalas temporales, lo que implica que puede ser necesaria una evaluación de rendimiento específica para cada sitio (Wanzala et al. 2022a).

En estudios de riesgo de inundaciones que han utilizado datos de reanálisis se han reportado resultados satisfactorios mostrando un uso potencialmente positivo. Sin embargo, los datos de reanálisis globales o regionales aún no deben considerarse como un reemplazo para las observaciones locales de alta resolución. Las incertidumbres en la evaluación del riesgo de inundación utilizando datos de reanálisis deben ser adecuadamente cuantificadas y comunicadas, para asegurar que las decisiones no estén mal informadas (McClean et al. 2023).

Aunque algunos estudios han mostrado un mejor desempeño de ciertos productos en comparación con otros, como el estudio de (Wanzala et al. 2022b), que encontró que ERA5 tuvo un mejor rendimiento en Kenia, y en general se ha observado que ERA5 supera a otros productos de reanálisis (Carr et al. 2024), la literatura sugiere que es preferible utilizar múltiples productos, como ERA5, CFSR y MERRA-2, para capturar la gama completa de incertidumbre en la precipitación. Esto se debe a que cada uno de estos productos ha demostrado un mejor rendimiento en distintas áreas o bajo diferentes criterios de evaluación (McClean et al. 2023).

A partir del producto ERA5 se generó el conjunto de datos global de intensidad, duración y frecuencia (IDF) de precipitaciones, conocido como Parametrized eXtreme Rain (PXR), producido por Courty et al. (2019). Dentro de la evaluación de estas IDF globales Carr et al. (2024) encontraron que promete ser útil para evaluar el riesgo de inundaciones a escala urbana, tanto para eventos de baja como de alta frecuencia.

Tabla 21. Productos de reanálisis

Producto	Resolución	Cobertura	Periodo	Frecuencia	Información
ERA-5	~ 30 km	Global	1979–	Horaria	El producto de reanálisis 5 del Centro Europeo para Pronósticos Meteorológicos a Medio Plazo (ERA-5) reemplaza y mejora a ERA-Interim, que dejó de producirse en agosto de 2019. ERA-5 ofrece una mayor resolución espacial y temporal, junto con un sistema actualizado de modelado y asimilación de datos, lo que ha resultado en una mejor representación de la lluvia convectiva. Además, ha demostrado superar a varios otros productos de reanálisis.
MERRA-2	~ 55 km	Global	1980–	Horaria	El análisis retrospectivo de la era moderna para la investigación y aplicaciones 2 (MERRA-2) se basa en su predecesor, MERRA, y presenta sesgos reducidos en aspectos del ciclo del agua, entre otras mejoras. MERRA-2 utiliza productos de precipitación observados para corregir las previsiones y proporcionar mejores estimaciones.
CFSR	~ 35 km	Global	1979–2011	Horaria	El Sistema de Reanálisis del Pronóstico Climático del NCEP (CFSR) reemplaza la anterior reanálisis NCEP/NCAR y utiliza un sistema de análisis muy similar al de MERRA-2.
JRA-55	~ 60 km	Global	1958–	3-horas	El producto de reanálisis de la Agencia Meteorológica de Japón, JRA-55, reemplaza a JRA-25, incorporando una mayor resolución y una mejor asimilación de datos, entre otras mejoras.

Fuente: McClean et al. (2023).

SECCIÓN 7



Imagen: Adobe Stock

INFORMACIÓN GLOBAL DE LIBRE ACCESO PARA ANÁLISIS DE EXPOSICIÓN Y VULNERABILIDAD

En las siguientes secciones, se explorarán las fuentes de información global de libre acceso que son esenciales para el análisis de exposición y vulnerabilidad en el contexto de la gestión de riesgos de desastres.

7.1. EXPOSICIÓN



Imagen: Adobe Stock

A continuación, se resaltan algunos los modelos globales de exposición, que son esfuerzos internacionales para desarrollar bases de datos y metodologías que permitan una evaluación de los activos expuestos a nivel mundial. También se presenta la información disponible que puede ser utilizada para generar capas de exposición, proporcionando una visión de las herramientas y datos accesibles que facilitan la creación de mapas de exposición en diversas escalas geográficas.

7.1.1. Modelos globales

Existen varios esfuerzos internacionales para desarrollar modelos de exposición globales. Por ejemplo, (i) De Bono y Mora (2014) desarrollaron un modelo global de exposición de acceso abierto con una resolución espacial de 5 km, el cual se presentó inicialmente en el Informe de Evaluación Global (GEG-2013) con una actualización posterior (De Bono y Chatenoux 2015) creando la base de datos GEG-2015; (ii) la fundación Global Earthquake Model (GEM) introdujo la Base de Datos Global de Exposición (GED4GEM) (Gamba 2014). La base de datos de exposición más reciente producida por GEM es la versión v2023.1 (Yepes-Estrada et al. 2023), que proporciona una distribución espacial de edificios residenciales y población en tres resoluciones espaciales diferentes: nacional, límites administrativos de nivel 1 y nivel 2 (Mistry y Lombardi 2023); y (iii) en el marco de la biblioteca de funciones CLIMADA se generaron los métodos de LitPop y BlackMarble para producir capas de exposición globales (Eberenz et al. 2019). A continuación, se describen esos ejemplos en detalle.

El **GEG-2013** tiene como objetivo principal generar una evaluación global de los activos expuestos en áreas urbanas. Su propósito es proporcionar datos específicos de exposición que puedan utilizarse en evaluaciones de riesgo de tipo general y a gran escala. Este modelo considera únicamente los daños físicos directos a edificaciones urbanas, utilizando como fuentes principales de información los datos socioeconómicos nacionales y los modelos de distribución geográfica de la población y el Producto Interno Bruto (PIB). Una de las características más importantes del enfoque *top-down* adoptado por el GEG-2013 es que garantiza la comparabilidad entre países y territorios de todo el mundo, facilitando análisis consistentes a escala global (De Bono y Mora 2014).

El GEG-2013 se centra en los activos expuestos, definidos principalmente como el stock de edificios (tanto viviendas como edificaciones comerciales o industriales) y la población que habita o trabaja en ellos. Para ello, se utiliza un enfoque basado en el capital producido en áreas urbanas, donde se evalúa el valor económico de los activos sin considerar los efectos indirectos o secundarios, que quedan explícitamente fuera del alcance del informe GAR 2013. El modelo se apoya en datos del Banco Mundial y presenta una base de datos de exposición a nivel subnacional en una cuadrícula global de 5 x 5 km², adecuada para la evaluación probabilística de riesgos en áreas urbanas a nivel nacional. Este enfoque se implementa mediante la plataforma CAPRA (http://www.ecapra.org) (De Bono y Mora 2014).

La exposición en el GEG-2013 se representa como el valor de un grupo de edificios dentro de cada celda de 5 x 5 km². Para estimar las características de las edificaciones a nivel subnacional, se consideran cuatro sectores socioeconómicos, donde la distribución de los tipos de edificios se relaciona con la población que vive en cada tipología, y no con el número total de edificaciones por tipo constructivo. El valor del capital producido (activos) se distribuye por sector y tipo de edificio en cada celda de la cuadrícula, tomando en cuenta la densidad de ocupación y el costo unitario por sector. Su objetivo final es contribuir a la estimación probabilística del riesgo a escala global, presentando los resultados en términos relativos mediante clases de riesgo. Este enfoque permite comparar las pérdidas económicas potenciales entre distintos países y ofrecer un orden de magnitud de los impactos esperados (De Bono y Mora 2014).



Imagen: Flickr - BID Ciudades sostenibles / Natal, Brasil

GEG-2015 es la versión actualizada de GEG-2013. El GEG-2015 se compone de dos cuadrículas de exposición: una cuadrícula global de 5x5 km adecuada para evaluar riesgos en grandes áreas y una cuadrícula global costera de alta resolución de 1x1 km para riesgos a escala más fina, para evaluación de riesgo de tsunamis y marejadas ciclónicas. Cada registro del GEG-2015 representa una tipología estructural específica de edificio, asociada a un nivel de ingreso o sector, con una representación puntual en el centroide de la celda correspondiente. Una de las características más importantes del GEG-2015 es la inclusión de la población rural, que no se consideraba en la edición de 2013, multiplicando aproximadamente por 18 veces el número total de activos expuestos. Además, se realizaron mejoras significativas, como el uso de una máscara de áreas construidas mejorada, y correcciones de las limitaciones del modelo MODIS 500 en regiones densamente pobladas, como el sudeste asiático. También se actualizaron las capas base, incluyendo la base de datos de distribución de población y datos de construcción. Otra mejora clave fue la distribución geográfica del capital producido, ponderada mediante un nuevo indicador que considera la variación entre los valores del PIB a nivel nacional y subnacional (De Bono y Chatenoux 2015). **La Figura 17** presenta un ejemplo de la base de datos en una zona de prueba mostrando el stock total de capital.

El **Modelo Global de Exposición desarrollado por GEM** (Yepes-Estrada et al. 2023) es un mosaico de modelos locales y regionales que contiene información sobre el inventario de edificios residenciales, comerciales e industriales en la división administrativa más pequeña disponible de cada país. Incluye detalles como el número de edificios, ocupantes, características de vulnerabilidad, área promedio construida y costo promedio de reposición. Este modelo es desarrollado y mantenido por la Fundación GEM mediante un enfoque bottom-up a escala global, utilizando estadísticas nacionales, datos

socioeconómicos y conjuntos de datos locales. Los insumos utilizados provienen de instituciones nacionales, programas regionales o colaboraciones bilaterales, y se basan en los mejores datos y modelos disponibles públicamente. Este modelo permite identificar los tipos más comunes de construcción a nivel mundial, las regiones con altas proporciones de construcciones informales y las áreas que cuentan con una alta concentración de población e inventario de edificios. Los datos subyacentes utilizados para la creación de los mapas están disponibles para todas las regiones del mundo, agregados a nivel administrativo 1 bajo una licencia CC BY-NC-SA[17], o desagregados a un nivel de detalle mayor bajo solicitud, para lo cual se extienden licencias específicas dependiendo del uso requerido (GEM 2024b).

Figura 17. Ejemplo de la base de datos GEG-2015



Fuente: GAR15.

[17] La licencia Creative Commons Atribución-No Comercial-Compartir Igual (CC BY-NC-SA) permite a otros distribuir, remezclar, adaptar y crear obras derivadas de un material, siempre que se otorgue el crédito adecuado al autor original, no se utilice con fines comerciales y las nuevas creaciones se licencien bajo los mismos términos (https://creativecommons.org/licenses/by-nc-sa/4.0/).

El modelo de exposición de GEM se encuentra disponible como un Mapa Global de Exposición en formato shapefile que consta de cuatro capas que representan el número de edificios, el área construida, el valor total de reposición y la población total. Los mapas del número de edificios y del valor total de reposición están disponibles para descarga directa como archivos PNG en alta definición bajo la licencia CC BY-NC-SA 4.0[18], que exige atribución, uso no comercial y compartir derivados bajo la misma licencia. En casos de uso comercial o para obtener el conjunto completo de capas como shapefile, es necesario presentar una solicitud específica, donde se otorgará una licencia personalizada según el caso de uso. Para fines no comerciales, la licencia requiere dar el crédito correspondiente, incluir un enlace a la licencia y mencionar cualquier cambio realizado (GEM 2024b).

LitPop es una metodología diseñada para estimar la distribución espacial de valores de activos físicos a nivel global con alta resolución. Este enfoque utiliza datos de intensidad de luz nocturna y población como proxies para modelar la actividad económica, asignando indicadores macroeconómicos, como el producto interno bruto (PIB), a celdas geográficas específicas. LitPop proporciona una base homogénea y consistente para modelar impactos económicos directos en diferentes regiones del mundo. La metodología se basa en multiplicar la intensidad de luz nocturna por la densidad de población en cada celda geográfica, creando así un indicador que refleja la actividad económica en ese espacio. Posteriormente, este valor se utiliza para distribuir de manera proporcional el capital producido nacionalmente u otros indicadores macroeconómicos, como el PIB o el producto regional bruto (GRP). Este proceso permite obtener una representación espacial de los valores de activos físicos, adaptada a diferentes niveles de resolución según la calidad de los datos disponibles (Eberenz et al. 2019). La **Figura 18** y **Figura 19** muestran un ejemplo de LitPop con información generada con una resolución de aproximadamente 930 m.

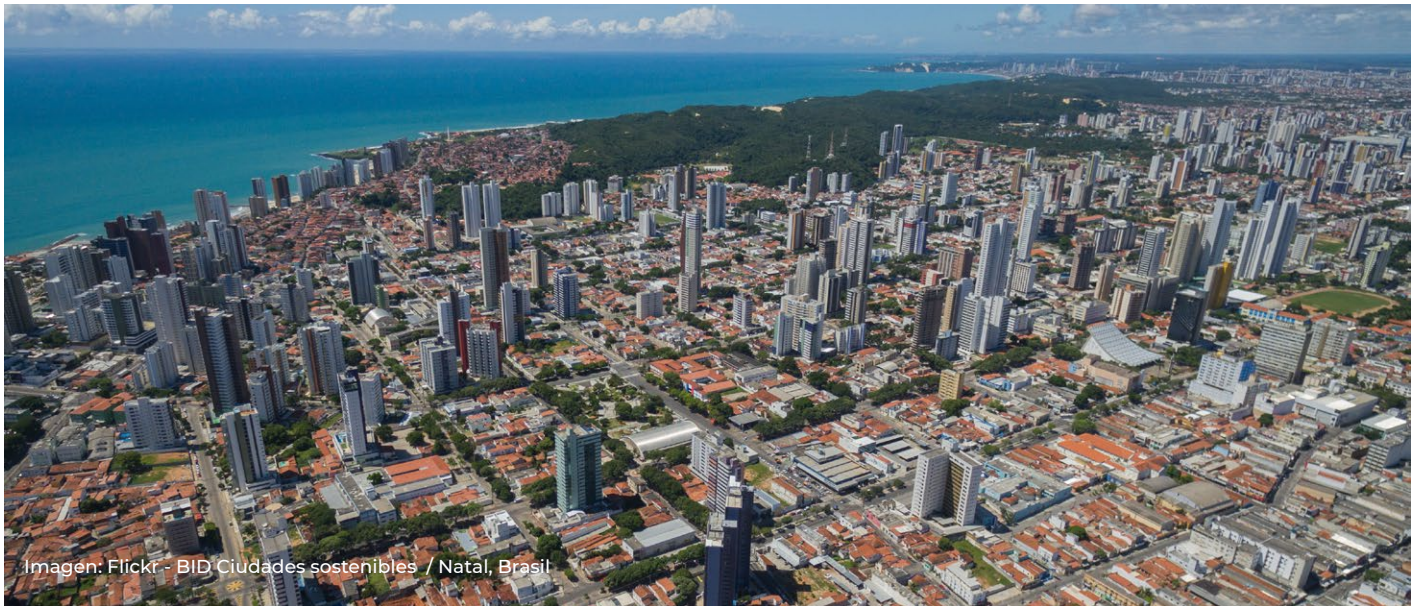
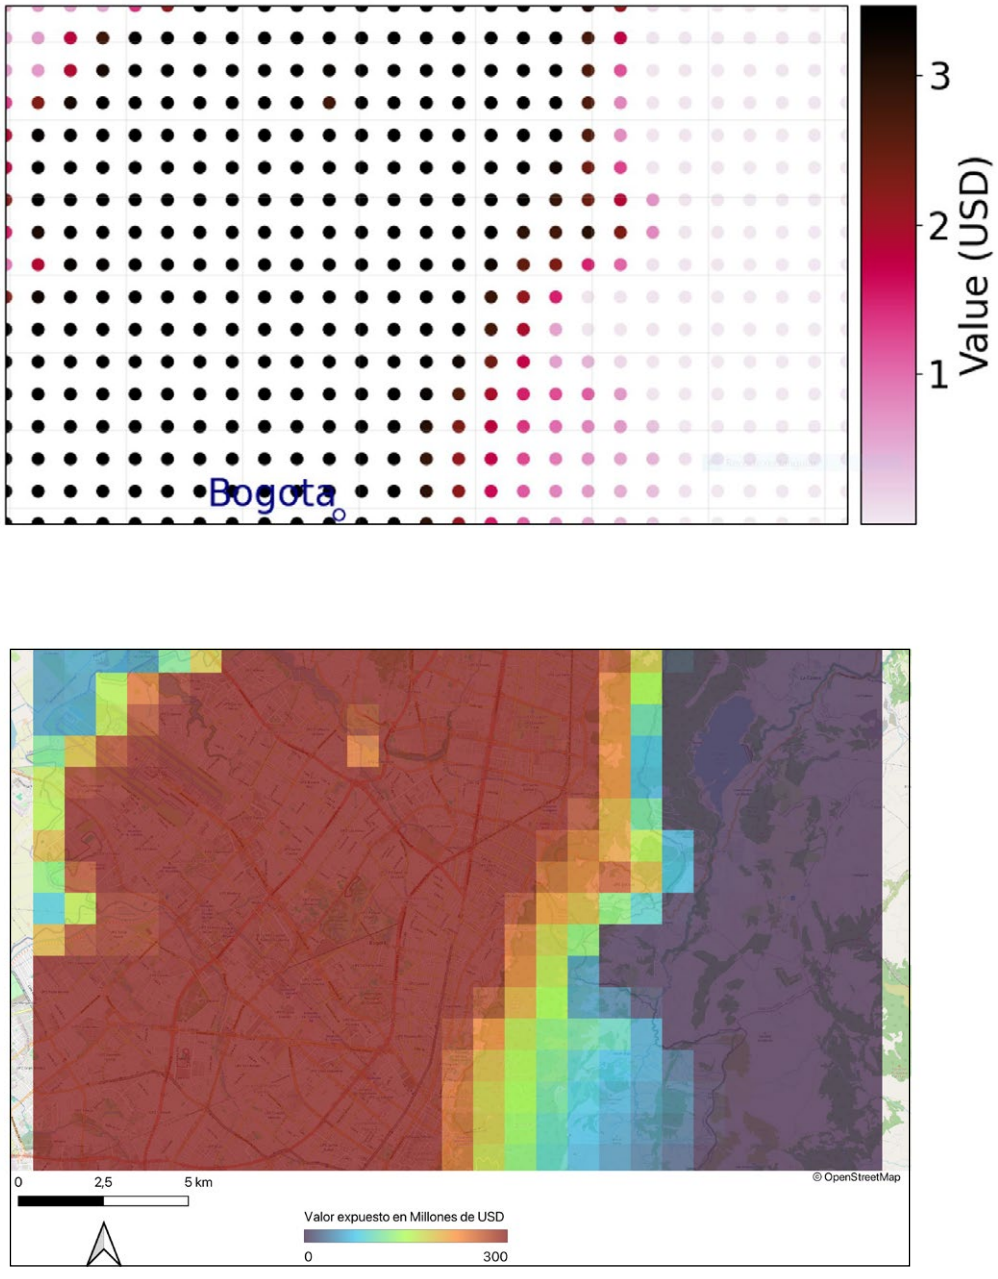


Imagen: Flickr - BID Ciudades sostenibles / Natal, Brasil

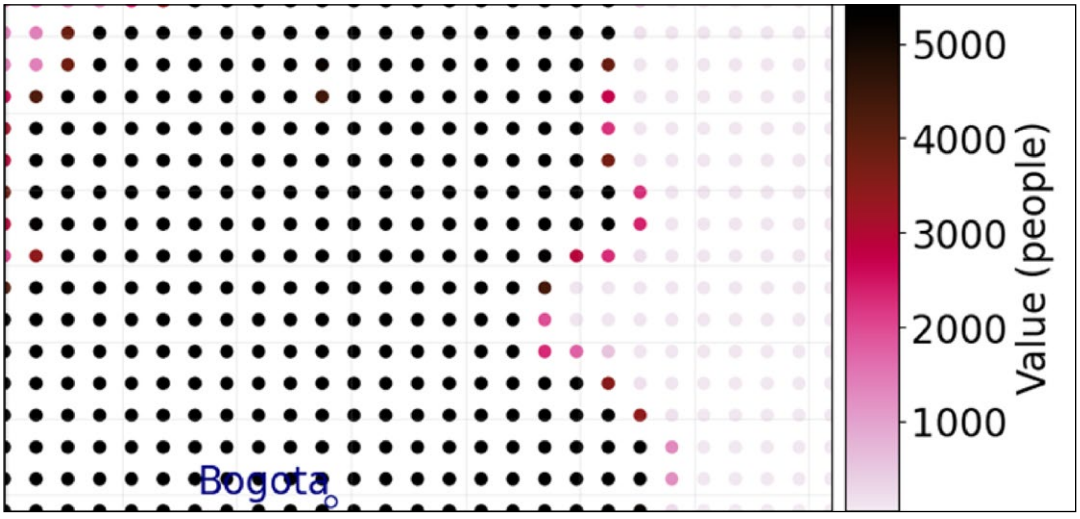
[18] La licencia Creative Commons Atribución-NoComercial-CompartirIgual 4.0 (CC BY-NC-SA 4.0) permite a otros compartir, copiar y adaptar el material siempre que se otorgue el crédito adecuado al autor original, no se utilice con fines comerciales y las obras derivadas se distribuyan bajo la misma licencia (https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es).

Figura 18. Valor de activos en millones de dólares LitPop generado con CLIMADA para el año de referencia 2025



Nota: capa generada para la misma área mostrada en la Figura 17. En la imagen superior se muestra la salida de CLIMADA con valores asignados a centroides y en la imagen inferior se muestra el raster exportado de CLIMADA.

Figura 19. Población LitPop generada con CLIMADA para el año de referencia 2025



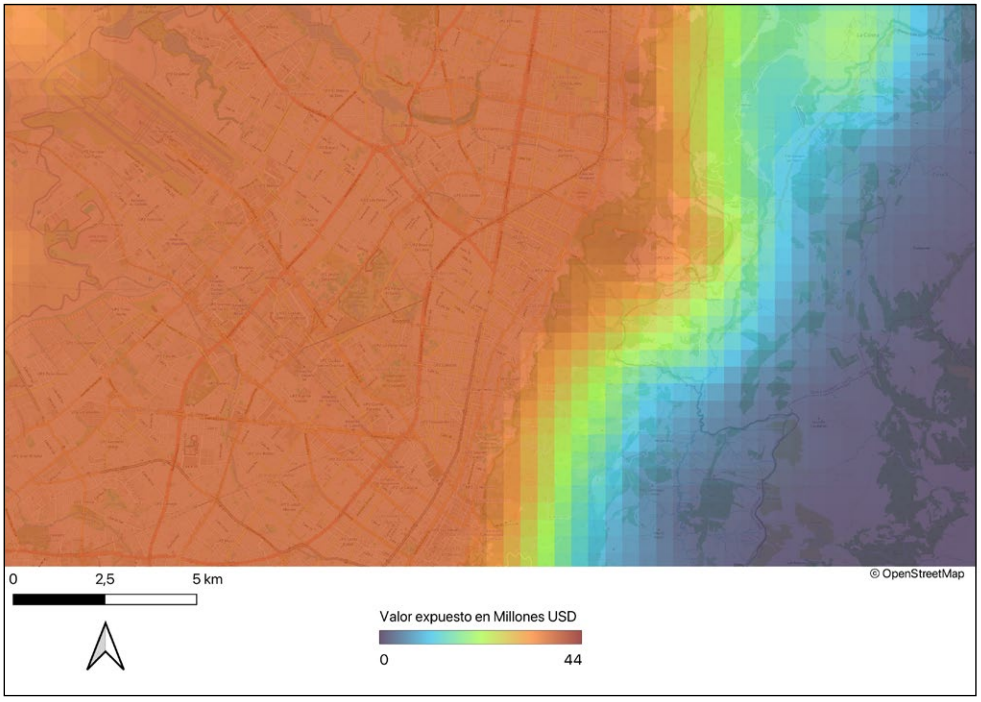
Nota: capa generada para la misma área mostrada en la Figura 17.

Aunque la información que se genera a través de LitPop es de una gran utilidad para análisis de riesgo a escalas gruesas, una de sus principales restricciones es la calidad y resolución de los datos de población y luz nocturna, los cuales varían significativamente entre países, afectando la precisión del modelo. Además, su enfoque top-down, aunque efectivo para análisis a gran escala, no considera las variaciones locales en los tipos de infraestructura y vulnerabilidades, limitando su aplicabilidad para evaluaciones detalladas a nivel local. Los datos de luz nocturna también presentan problemas como la saturación en áreas urbanas densas y el "blooming", donde la luz reflejada no corresponde necesariamente a actividad económica real. Finalmente, la falta de datos subnacionales detallados dificulta la validación directa del modelo en ciertos contextos, y su dependencia de indicadores nacionales como el PIB puede no captar completamente las desigualdades o particularidades regionales (Eberenz et al. 2019).

BlackMarble es una de las clases de exposición que genera CLIMADA y se utiliza para aproximar la exposición económica a nivel de países y provincias. Este modelo interpola valores de PIB y grupos de ingresos a partir de la intensidad de la luz nocturna en un año específico, permitiendo así una estimación espacialmente distribuida de la exposición económica. Para ello, BlackMarble utiliza imágenes satelitales de luz nocturna provenientes de diferentes fuentes. Entre 2012 y 2016, se emplean imágenes de la NASA con una resolución de 15 segundos de arco (~500 m), mientras que para los años entre 1992 y 2013 se usan imágenes de la NOAA con una resolución de 30 segundos de arco (~1 km). De forma predeterminada, los datos de la NASA se usan para años posteriores a 2013, y los de la NOAA para años anteriores, aunque existe una opción que permite seleccionar la fuente más cercana. Además, la resolución predeterminada es la de la imagen de entrada, pero puede ajustarse mediante interpolación. Los datos de PIB y grupos de ingresos se obtienen de la base de datos del Banco Mundial a través de la API *pandas-datareader*, y

cuando no hay valores disponibles, se consideran los más cercanos en el tiempo o se utilizan datos del repositorio de *Natural Earth*. La **Figura 20** muestra un ejemplo de Blackmarble con una resolución de aproximadamente 460 metros.

Figura 20. Valor de activos en millones de dólares Blackmarble generado con CLIMADA



La mayoría de los modelos de exposición disponibles proporcionan información suficiente para la evaluación de riesgos a escala nacional y global. Sin embargo, tienden a carecer de la resolución necesaria para realizar evaluaciones de riesgos a escala urbana con un alto nivel de confianza. El principal desafío para desarrollar un modelo de exposición de alta resolución radica en la información limitada disponible a nivel de activos (Mistry y Lombardi 2023). Sin embargo, hay un avance muy significativo en la generación de información a escala de detalle que puede ser utilizada para la construcción de capas de exposición como se muestra en la sección 8.1.2.

7.1.2. Información disponible que puede ser usada para generar capas de exposición

Para grandes áreas urbanas, los datos de exposición pueden obtenerse a partir de bases de datos de código abierto y propietarias, como OpenStreetMap (OSM), Google Earth y catastros generados a nivel local. Sin embargo, en áreas urbanas pequeñas y regiones rurales, estos datos suelen ser incompletos o

inexistentes, lo que hace necesaria la recopilación de información mediante sensores remotos y trabajo de campo. Investigaciones recientes han explorado el uso de modelos de exposición estocásticos, como el propuesto por Mistry y Lombardi (2023), que utiliza el método de muestreo de Monte Carlo para considerar la incertidumbre relacionada con la ubicación de los activos y sus atributos en el modelo de exposición. Este enfoque reconoce la complejidad y precisión que requieren los análisis de exposición, especialmente a escalas más detalladas. A continuación, se describen las principales fuentes de datos con cobertura global que pueden proporcionar información base para construir las bases de datos de elementos expuestos a escala local.

OpenStreetMap (OSM)[19] [20] es una plataforma de mapas colaborativa y gratuita que proporciona datos geoespaciales de todo el mundo, creados y mantenidos por una comunidad global de voluntarios. Estos datos se recopilan de manera abierta, lo que permite su uso y modificación bajo una licencia de contenido abierto. En términos de análisis de exposición, los datos de OSM ofrecen información detallada sobre infraestructuras, como carreteras, puentes, edificios, redes de transporte, y otros activos construidos (ver **Figura 21**, **Figura 22** y **Figura 23**). Estos datos pueden utilizarse para mapear la ubicación y características de los bienes expuestos. Además, OSM también proporciona información sobre elementos relevantes para la respuesta y recuperación ante desastres, como hospitales, estaciones de bomberos, escuelas y áreas de refugio.

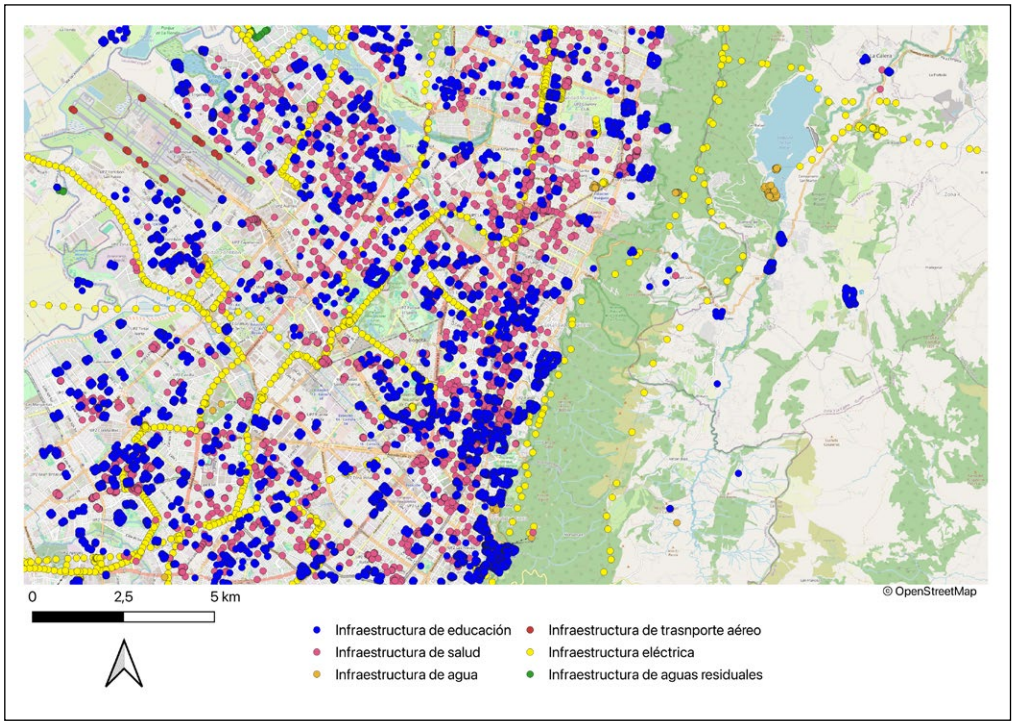


Imagen: Adobe Stock

[19] https://wiki.openstreetmap.org/wiki/About_OpenStreetMap

[20] https://www.hotosm.org/what-we-do

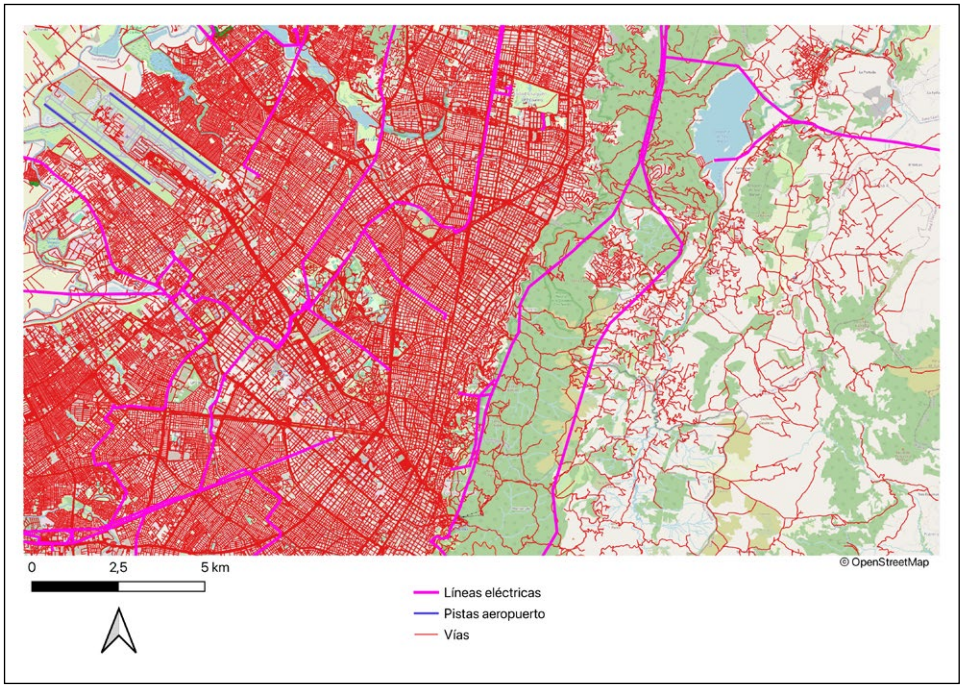
Figura 21. Extracción de diferentes tipos de infraestructura disponibles en OpenStreetMap en formato de punto



Fuente de datos de la infraestructura: OpenStreetMap contributors (2017).

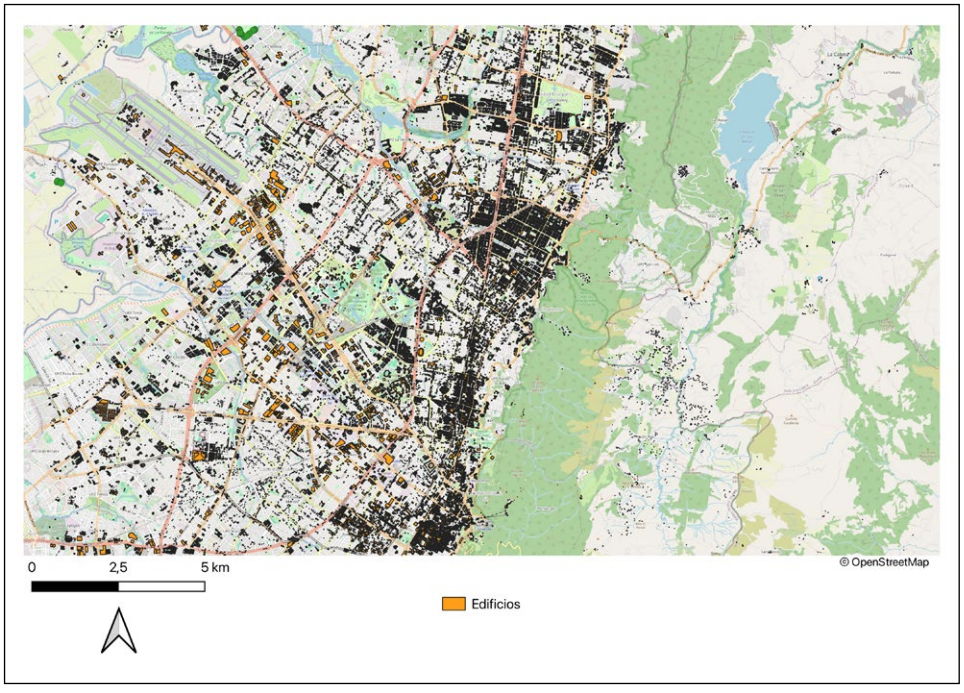
Humanitarian OpenStreetMap Team (HOT) es una organización que utiliza los datos de OpenStreetMap (OSM) para apoyar esfuerzos de respuesta y preparación ante desastres en áreas vulnerables, particularmente en regiones donde los datos geoespaciales son escasos o inexistentes. HOT trabaja en colaboración con comunidades locales y organizaciones humanitarias para recolectar, mejorar y actualizar datos geoespaciales, con el objetivo de crear mapas detallados que faciliten el análisis de exposición y la gestión de riesgos. El trabajo de HOT se centra en la creación de mapas en tiempo real durante situaciones de emergencia, así como en la mejora de la cobertura de OSM en zonas de alto riesgo. En estos casos, el equipo se enfoca en identificar las áreas más vulnerables y actualizar los datos de infraestructura, como edificios, carreteras, puentes y otras instalaciones críticas que pueden verse afectadas por un desastre. Además, HOT organiza campañas de mapeo en las que los voluntarios, utilizando imágenes satelitales y otras fuentes de datos, contribuyen a la creación de mapas que reflejan la situación actual del terreno. Esta información es crucial para realizar análisis de exposición, ya que permite a las autoridades y organizaciones humanitarias planificar y ejecutar respuestas más eficaces, identificar riesgos de manera precisa y coordinar intervenciones de manera eficiente.

Figura 22. Extracción de diferentes tipos de infraestructura disponibles en OpenStreetMap en formato de líneas



Fuente de datos de la infraestructura: OpenStreetMap contributors (2017).

Figura 23. Extracción de edificaciones disponibles en OpenStreetMap en formato de polígonos



Fuente de datos de edificaciones: OpenStreetMap contributors (2017).

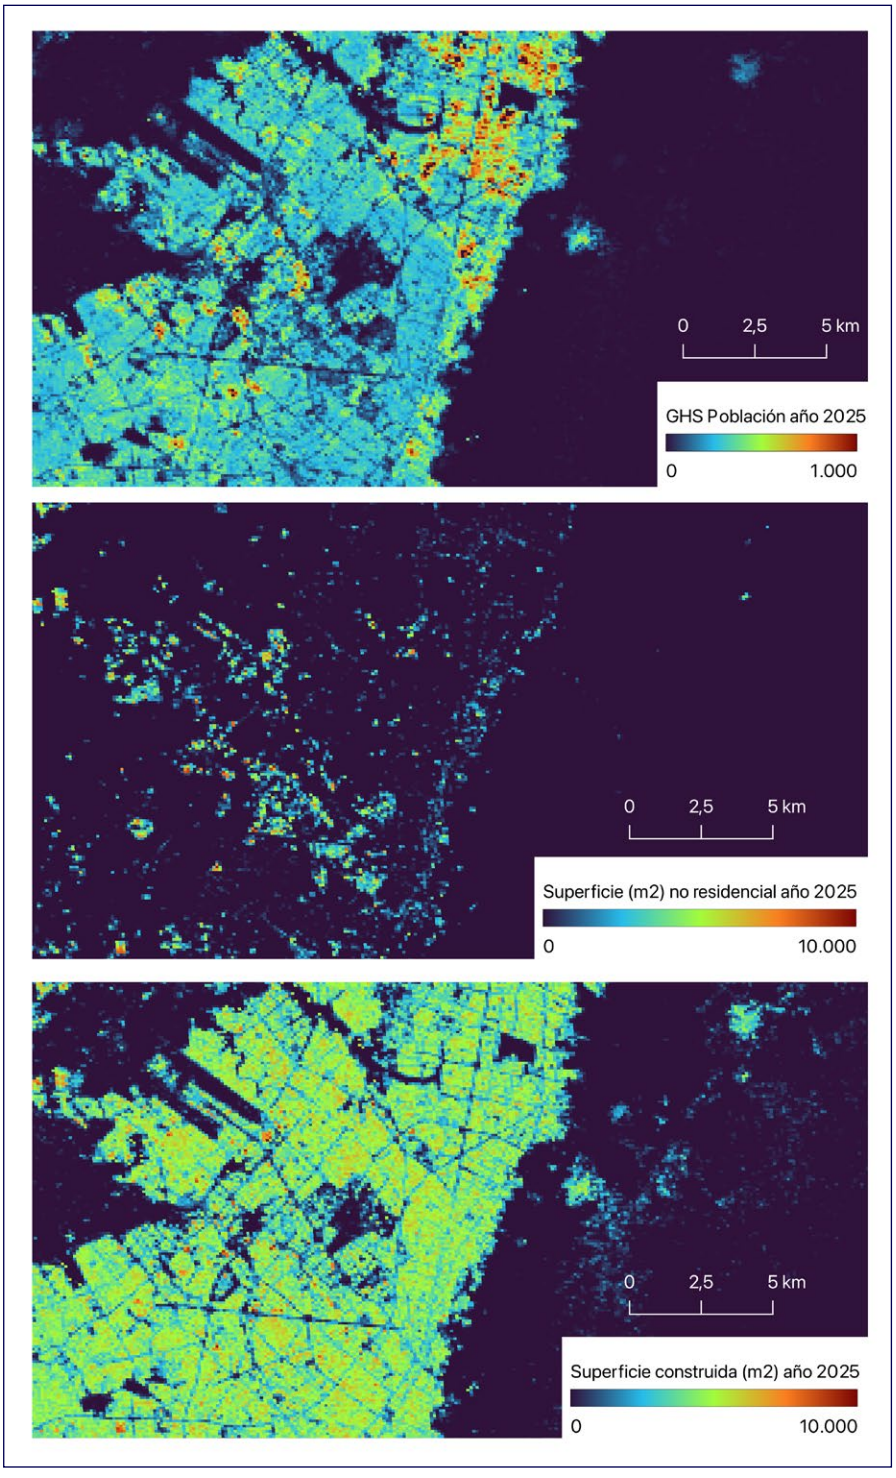
El Global Human Settlement Layer (GHSL)[21] es un proyecto desarrollado por la Comisión Europea que utiliza técnicas de teledetección para generar capas de datos geoespaciales relacionadas con la ocupación humana y el desarrollo urbano a escala global. Estos datos se basan en imágenes satelitales y otras fuentes de información geoespacial, y están diseñados para ofrecer una visión detallada de las áreas urbanas y de asentamientos humanos, lo que los hace útiles para el análisis de exposición en el contexto de la gestión de riesgos de desastres. Una de las principales características de GHSL es su capacidad para identificar las áreas construidas, proporcionando datos sobre la proporción de área edificada dentro de cada celda de la cuadrícula, lo que permite estimar la densidad y extensión de los asentamientos urbanos. Los datos más utilizados en el análisis de riesgos provienen de capas como GHS_BUILT_S2, que tiene una resolución de 10 metros y fue derivada de imágenes satelitales de Sentinel-2 (2018). Estos datos permiten mapear las áreas urbanas dentro de zonas afectadas por desastres, como inundaciones o terremotos, y calcular la exposición de las infraestructuras y la población a estos eventos. A diferencia de los datos de OpenStreetMap, que dependen de contribuciones voluntarias, GHSL utiliza una metodología basada en el procesamiento de imágenes satelitales, lo que proporciona una cobertura más uniforme, especialmente en áreas remotas o de difícil acceso. Sin embargo, la resolución espacial, aunque alta, aún puede presentar limitaciones para detectar estructuras más pequeñas o áreas con alta variabilidad en el desarrollo urbano, como las zonas rurales o semiurbanas (Copernicus 2024). La **Figura 24** muestra un ejemplo de las capas de población, superficie no residencial y superficie construida para el año 2025. La información disponible es multitemporal en el periodo 1975 – 2030.

WorldPop[22] es una iniciativa global que proporciona datos espaciales de alta resolución sobre la distribución de la población en todo el mundo. Utilizando una combinación de imágenes satelitales, censos nacionales y otros datos geoespaciales, WorldPop genera mapas de la población a nivel de cuadricula, lo que es crucial para realizar análisis de exposición en el contexto de riesgos de desastres. Estos mapas de población permiten estimar la densidad y distribución de las personas en áreas específicas. En términos de análisis de riesgo, WorldPop ofrece una capa de datos de alta resolución con estimaciones de la población en diferentes puntos geográficos, típicamente a nivel de 100 metros o menor, lo que permite una precisión espacial significativa. Además, la base de datos de WorldPop también permite realizar proyecciones de población futura, lo que facilita la planificación a largo plazo en términos de preparación ante desastres. La **Figura 25** muestra un ejemplo de la población para un tamaño de pixel de 100 metros.

[21] https://ghsl.jrc.ec.europa.eu/data.php

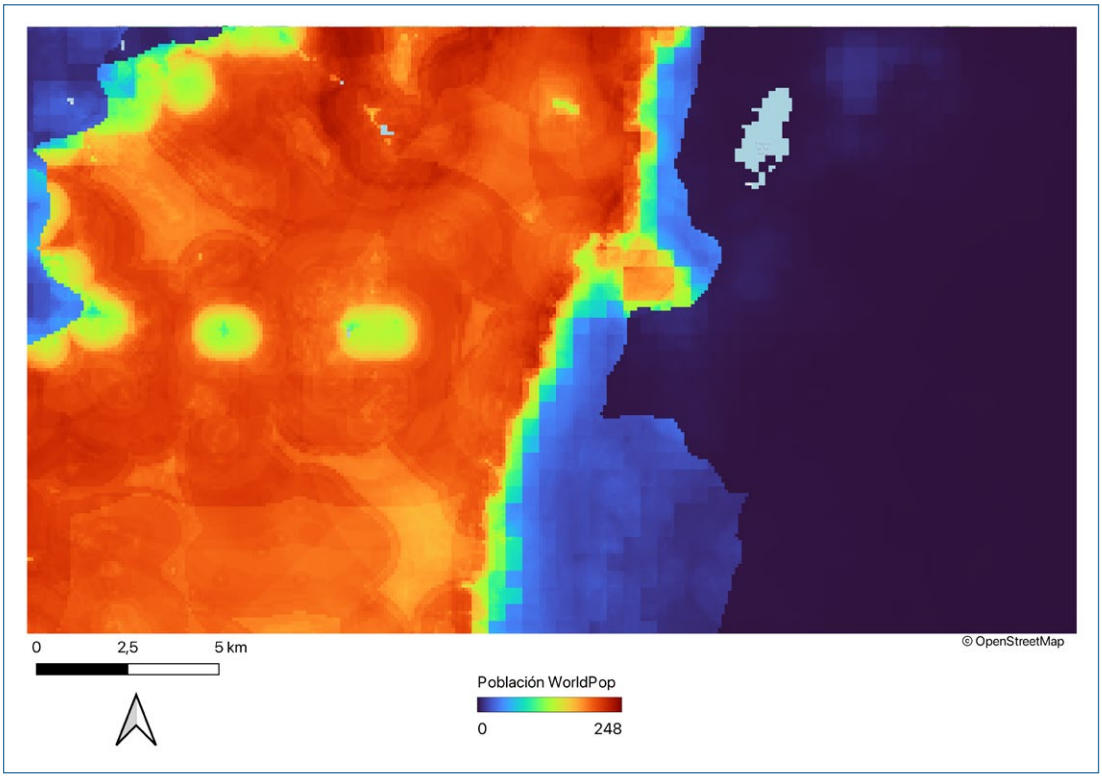
[22] http://worldpop.org.uk

Figura 24. Capas GHSL de población, superficie no residencial y superficie construida



Fuente:Pesaresi y Politis (2023).

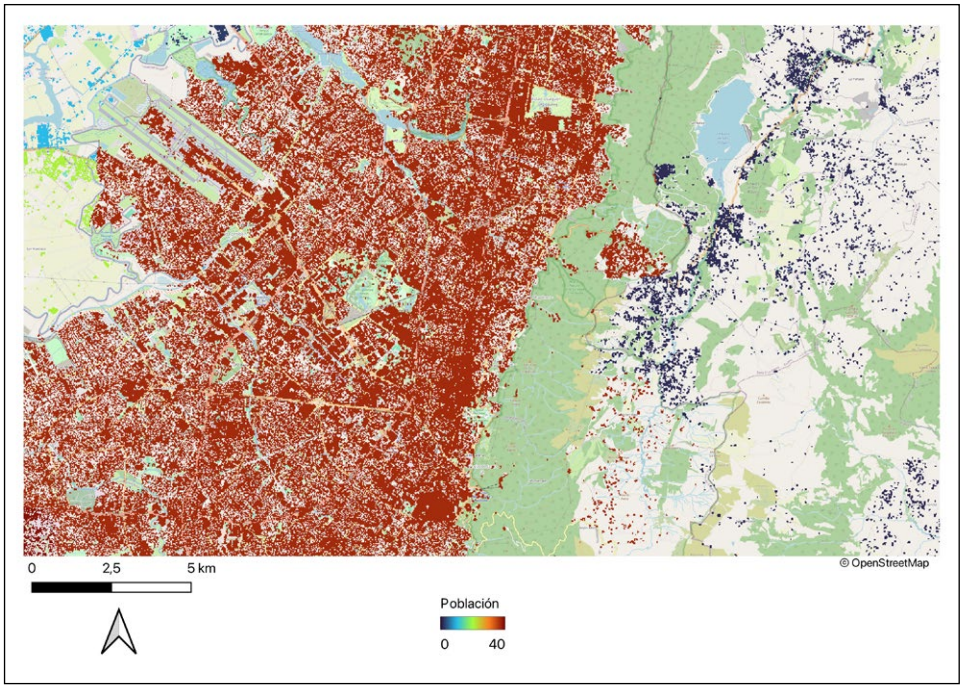
Figura 25. Población obtenida de WorldPop



Fuente: University of Southampton (2018).

Los mapas de **densidad de población de alta resolución elaborados por Meta** en colaboración con el Centro para la Red Internacional de Información sobre las Ciencias de la Tierra - CIESIN representan una herramienta innovadora para estimar la distribución poblacional. A través del uso de inteligencia artificial y el análisis de imágenes satelitales, estos mapas identifican la ubicación de edificios y distribuyen la población en cuadrículas de 30 metros. El proceso incluye la recopilación de datos censales, el análisis de imágenes mediante algoritmos de aprendizaje automático y la asignación de población según la densidad de construcción en cada mosaico. Gracias a este enfoque, se obtiene información demográfica, como la cantidad de niños, mujeres en edad fértil y adultos mayores. El acceso a estos datos es público y se encuentra disponible en plataformas Humanitarian Data Exchange (HDX) y Amazon Web Services (AWS) (META 2025). La Figura 26 muestra un ejemplo de la información de población elaborada por META. Los píxeles con valores corresponden a celdas de la cuadrícula donde se ha detectado la presencia de una estructura. Los valores de población se distribuyen uniformemente en cada una de estas celdas, representando una estimación de la población para el área censal.

Figura 26. Población elaborada por META



Fuente de datos de población: Humanitarian Data Exchange (HDX).

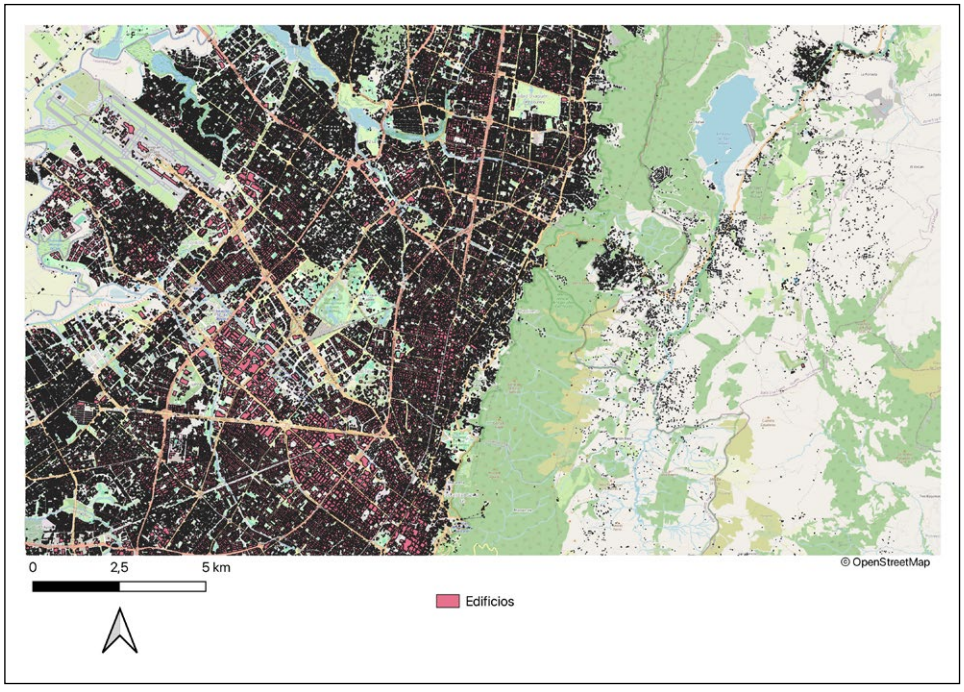
Microsoft AI Microsoft Bing Maps Building Footprints es una iniciativa global que proporciona datos abiertos sobre contornos de edificaciones en todo el mundo. Utilizando imágenes satelitales de alta resolución de fuentes como Maxar, Airbus e IGN France, se han detectado más de 1.4 mil millones de edificios entre 2014 y 2024. Estos datos son accesibles bajo la licencia ODbL (Open Database License)[23], lo que permite su descarga y uso gratuito. La actualización de diciembre de 2024 incluye aproximadamente 999 millones de polígonos de edificaciones en formato GeoJSON delimitado por líneas. Además, las coordenadas están referenciadas al sistema EPSG: 4326, asegurando compatibilidad con herramientas de análisis geoespacial (Microsoft 2024).

El proceso de extracción de datos consta de dos etapas: segmentación semántica mediante redes neuronales profundas (DNNs), que identifican los píxeles correspondientes a edificaciones en imágenes aéreas, y poligonización, donde dichos píxeles se convierten en geometrías. Para mejorar la calidad de los datos, se han implementado puntuaciones de confianza que varían entre 0 y 1, indicando la certeza de detección. Los datos son evaluados mediante métricas como Precisión, Recall e Intersección sobre Unión (IoU), y aunque la

[23] La Licencia de Base de Datos Abierta (ODbL, Open Database License) es una licencia que permite a los usuarios compartir, modificar y utilizar libremente una base de datos, siempre que mantengan la atribución adecuada, compartan las modificaciones bajo la misma licencia y mantengan abiertas las versiones derivadas (https://opendatacommons.org/licenses/odbl/).

calidad es alta en la mayoría de los casos, varía entre zonas urbanas densas y áreas rurales. Esta iniciativa respalda el ecosistema de OpenStreetMap (OSM) y es utilizada en aplicaciones humanitarias, como en la plataforma HOT Tasking Manager, donde se facilita la cartografía en regiones vulnerables. Los datos son accesibles a través de GitHub (Microsoft 2024). L**a Figura 27** muestra un ejemplo de las edificaciones para un área seleccionada.

Figura 27. Extracción de edificaciones disponibles en Microsoft Bing Maps

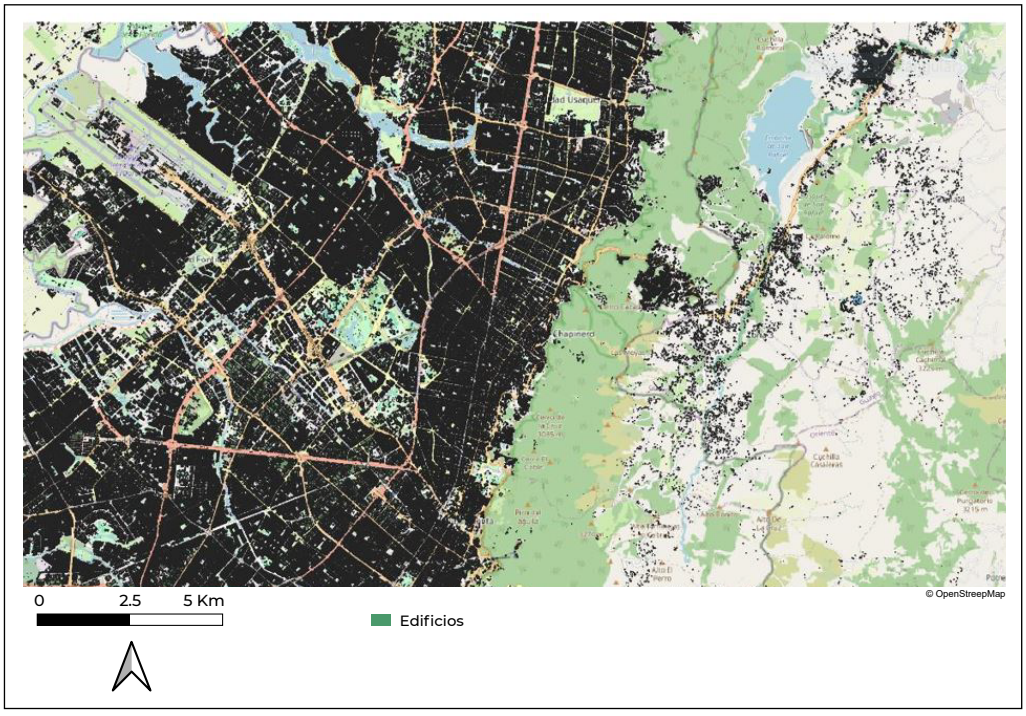


Fuente de datos de edificaciones: GlobalMLBuildingFootprints.

Google Building Footprints es un conjunto de datos de gran escala que proporciona los contornos de edificaciones derivados de imágenes satelitales de alta resolución. El proyecto, liderado desde la oficina de Google en Ghana, se enfoca en el continente africano y en las regiones del Sur Global, cubriendo áreas críticas como África, Asia del Sur, el Sudeste Asiático, América Latina y el Caribe. La versión actual, v3, abarca aproximadamente 1.8 mil millones de edificaciones distribuidas en un área de inferencia de 58 millones de km². El conjunto de datos incluye polígonos que describen la geometría de cada edificación, puntuaciones de confianza (rango 0.65 a 1.0) que indican la probabilidad de que un objeto identificado sea una construcción, y un Plus Code que representa el centroide de la edificación. Los datos están organizados en archivos CSV segmentados espacialmente por celdas S2 de nivel 4. Cada registro contiene información como latitud, longitud, área en metros cuadrados, geometría en formato WKT (POLYGON o MULTIPOLYGON) y el código Plus del centroide de la

edificación. El modelo de aprendizaje profundo utilizado en la detección ha pasado por varias mejoras desde su lanzamiento inicial, con actualizaciones significativas en las versiones v2 y v3. Además, se incluyen umbrales de puntuación de confianza para garantizar precisiones específicas del 80%, 85% y 90%, permitiendo un control más detallado de la calidad de los datos. Este conjunto de datos está disponible bajo dos licencias abiertas: Creative Commons Attribution (CC BY-4.0) y Open Database License (ODbL) v1.0, permitiendo flexibilidad en su uso siempre y cuando se respeten los términos establecidos (Google Research 2024). La Figura 28 muestra un ejemplo de las edificaciones para un área seleccionada.

Figura 28. Extracción de edificaciones disponibles en Google Building Footprints



Fuente de datos de edificaciones: Google Research.

Proyecto ML Road Detections. Microsoft, a través de Bing Maps, ha lanzado un conjunto de datos global sobre carreteras extraídas de imágenes satelitales de alta resolución, con un total de 48.9 millones de kilómetros de carreteras detectadas y 1,165,000 kilómetros de caminos previamente ausentes en OpenStreetMap (OSM). Este proyecto utiliza imágenes satelitales de Bing Maps, Maxar y Airbus, recopiladas entre 2020 y 2022, y pone a disposición los datos bajo la Licencia Abierta de Bases de Datos (ODbL), lo que permite su descarga y uso libre dentro de los términos establecidos.

El proceso de generación de estos datos se realizó en cuatro etapas. Primero, se aplicó segmentación semántica con redes neuronales convolucionales (CNN) para identificar pixeles correspondientes a caminos. Luego, estos resultados se transformaron en geometrías viales mediante procesos de generación y mejora de conectividad. Posteriormente, se excluyeron caminos redundantes que ya existían en OSM, y finalmente, se clasificaron los datos para descartar elementos de baja confianza y definir tipos de carretera. El modelo utilizado, basado en arquitecturas UNet y ResNet, fue entrenado con 20,000 imágenes etiquetadas de diversas regiones, incluyendo montañas, desiertos y áreas costeras, para asegurar una representación geográfica variada. La calidad de los datos fue validada con métricas específicas, como una precisión por píxel del 85.24% y una similitud de longitud media de camino (APLS) del 87.53%, garantizando la conectividad del sistema vial generado. Antes de la publicación, un clasificador adicional confirmó que los caminos ausentes en OSM tenían una precisión mínima del 95%. Este esfuerzo tiene como objetivo principal fortalecer el ecosistema de OpenStreetMap, promoviendo la colaboración comunitaria para mejorar la calidad y cobertura de los mapas viales a nivel global. Microsoft también fomenta las contribuciones de la comunidad bajo acuerdos de licencia que respeten los derechos de autor y el uso adecuado de los datos (Microsof 2024). La **Figura 29** muestra un ejemplo de las vías para un área seleccionada.

Figura 29. Vías del Proyecto ML Road Detections



Fuente de datos de las vías: RoadDetections.

7.2. VULNERABILIDAD



Imagen: Flickr - Ciudades Sostenibles BID /Nassau, Bahamas

Las curvas de vulnerabilidad permiten establecer relaciones entre el nivel de daño o pérdida y la intensidad de un evento. Existen esfuerzos por generar información de **curvas de vulnerabilidad a nivel global** basándose en datos globales y metodologías de modelado, como el realizado por Huizinga et al. (2017), quienes desarrollaron una serie de curvas de vulnerabilidad para evaluar los efectos de inundaciones en edificios en todo el mundo. Su investigación se centró en la creación de un conjunto de curvas de vulnerabilidad genéricas que pudieran aplicarse a diferentes tipos de edificios, desde viviendas hasta infraestructuras comerciales e industriales. Las curvas de Huizinga utilizan parámetros como la altura de la inundación, el tipo de construcción y el material de las estructuras para estimar el daño esperado en función de estos factores. El trabajo de Huizinga et al. (2017) se basa en datos globales y una metodología estandarizada para crear curvas de vulnerabilidad que sean lo más representativas posible para una variedad de contextos. Estas curvas están diseñadas para ser aplicadas a nivel global, lo que las hace útiles en análisis de riesgo que se realicen en regiones con poca información específica a nivel local o nacional.

En la actualidad, diversas plataformas de modelado de riesgos integran **curvas de vulnerabilidad** para calcular las pérdidas económicas y los impactos sociales derivados de fenómenos naturales. Curvas de vulnerabilidad pueden ser encontradas en las funciones de CLIMADA, la base de datos de vulnerabilidad ERN-Vulnerabilidad de CAPRA, en HAZUS y funciones de fragilidad pueden encontrarse dentro de la base de datos de IN-CORE.

Global Earthquake Model Foundation (GEM) tiene una amplia base de datos de funciones de vulnerabilidad para ser utilizadas en la evaluación de riesgo sísmico con una detallada documentación. GEM ha desarrollado más de 1500 funciones que consideran una amplia gama de combinaciones de materiales de construcción, alturas, sistemas de resistencia lateral y niveles de diseño sísmico. La fragilidad y la vulnerabilidad se derivan mediante análisis no lineales en el tiempo, aplicados a osciladores equivalentes de un solo grado de libertad y utilizando un extenso conjunto de registros de movimientos del suelo representativos de diversos entornos tectónicos. Las funciones resultantes se validan a través de pruebas que incluyen el cálculo de las probabilidades anuales promedio de colapso y la tasa anual promedio de pérdidas para diferentes ubicaciones, además de comparar los resultados de simulaciones de eventos históricos con los daños y pérdidas observados (GEM 2024c).



Imagen: Flickr - Ciudades Sostenibles BID / Santa Marta, Colombia

REFERENCIAS

Abid, S. K., N. Sulaiman, S. W. Chan, U. Nazir, M. Abid, H. Han, A. Ariza-Montes, and A. Vega-Muñoz, 2021: Toward an Integrated Disaster Management Approach: How Artificial Intelligence Can Boost Disaster Management. Sustainability 2021, Vol. 13, Page 12560, 13, 12560, https://doi.org/10.3390/SU132212560.

Akosah, S., I. Gratchev, D. H. Kim, and S. Y. Ohn, 2024: Application of Artificial Intelligence and Remote Sensing for Landslide Detection and Prediction: Systematic Review. Remote Sensing 2024, Vol. 16, Page 2947, 16, 2947, https://doi.org/10.3390/RS16162947.

Albano, R., I. Craciun, L. Mancusi, A. Sole, and A. Ozunu, 2017a: FLOOD DAMAGE ASSESSMENT AND UNCERTAINTY ANALYSIS: THE CASE STUDY OF 2006 FLOOD IN ILISUA BASIN IN ROMANIA -. Carpathian Journal of Earth And Environmental Sciences, 2.

——, L. Mancusi, and A. Abbate, 2017b: Improving flood risk analysis for effectively supporting the implementation of flood risk management plans: The case study of "Serio" Valley. Environ Sci Policy, 75, 158–172, https://doi.org/10.1016/J.ENVSCI.2017.05.017.

——, ——, A. Sole, and J. Adamowski, 2017c: FloodRisk: a collaborative, free and open-source software for flood risk analysis. Geomatics, Natural Hazards and Risk, 8, 1812–1832, https://doi.org/10.1080/19475705.2017.1388854/ASSET/A0A74E85-2E0F-4603-BD2C-08F8D37B77BD/ASSETS/IMAGES/TGNH_A_1388854_F0011_OC.JPG.

Albano, R., A. Sole, J. Adamowski, A. Perrone, and A. Inam, 2018: Using FloodRisk GIS freeware for uncertainty analysis of direct economic flood damages in Italy. International Journal of Applied Earth Observation and Geoinformation, 73, 220–229, https://doi.org/10.1016/J.JAG.2018.06.019.

Australian Water School, 2024: AI-assisted coding for water modellers - Live Training - Australian Water School. https://awschool.com.au/training/ai-python-for-modellers/?utm_medium=email&utm_campaign=509%20-%20New%20courses%20%20PyQGIS%20%20AI&utm_content=509%20-%20New%20courses%20%20PyQGIS%20%20AI+CID_c44a2139f0006be37d7c56ad00aefc09&utm_source=Email%20marketing%20software&utm_term=AI-assisted%20Python%20coding%20for%20water%20modelling (Accessed September 3, 2024).

Azizi, A., 2024: A survey of seismic risk assessment using OpenQuake.

Aznar-Siguan, G., and D. N. Bresch, 2019: CLIMADA v1: a global weather and climate risk assessment platform. Geosci. Model Dev, 12, 3085–3097, https://doi.org/10.5194/gmd-12-3085-2019.

Banco Mundial, CEPREDENAC, EIRD, and ERN, 2009: Manual de usuario - CAPRA-GIS.

Bentivoglio, R., E. Isufi, S. N. Jonkman, and R. Taormina, 2022: Deep learning methods for flood mapping: a review of existing applications and future research directions. Hydrol Earth Syst Sci, 26, 4345–4378, https://doi.org/10.5194/HESS-26-4345-2022.

BID, 2019: Metodología de evaluación del riesgo de desastres y cambio climático para proyectos del BID: Documento técnico de referencia para equipos a cargo de proyectos del BID | Publicaciones. https://publications.iadb.org/es/publications/spanish/viewer/Metodologia-de-evaluacion-del-riesgo-de-desastres-y-cambio-clim%C3%A1tico-para-proyectos-del-BID-Documento-tecnico-de-referencia-para-equipos-a-cargo-de-proyectos-del-BID.pdf (Accessed February 20, 2025).

Birkmann, J., 2006: Measuring vulnerability to natural hazards: Towards disaster resilient societies. U.N.U. Press, Ed. bepress,.

Bjånes, A., R. De La Fuente, and P. Mena, 2021: A deep learning ensemble model for wildfire susceptibility mapping. Ecol Inform, 65, 101397, https://doi.org/10.1016/J.ECOINF.2021.101397.

Blass, R., 2021: ETH Library Coupling Oasis LMF with CLIMADA. https://doi.org/10.3929/ethz-b-000480061.

De Bono, A., and M. G. Mora, 2014: A global exposure model for disaster risk assessment. International Journal of Disaster Risk Reduction, 10, 442–451, https://doi.org/10.1016/J.IJDRR.2014.05.008.

De Bono, A., and B. Chatenoux, 2015: A Global Exposure Model for GAR 2015. https://doi.org/10.13140/RG.2.1.3893.9041.

Bretherton, E., N. A. Horspool, Y. I. Syed, V. L. Miller, and R. Paulik, 2023: RiskScape Case Studies: Informing Land-Use Planning Through Natural Hazard and Climate-Change Risk Modelling. https://www.naturalhazards.govt.nz/assets/Publications-Resources/RiskScape-Case-Studies-Informing-Land-Use-Planning-Final-Report.pdf (Accessed January 12, 2025).

Cardona, O. D., M. G. Ordaz, E. Reinoso, L. E. Yamín, and A. H. Barbat, 2012: CAPRA-Comprehensive Approach to Probabilistic Risk Assessment: International Initiative for Risk Management Effectiveness.

Carr, A. B., M. A. Trigg, A. T. Haile, M. V. Bernhofen, A. N. Alemu, T. W. Bekele, and C. L. Walsh, 2024: Using global datasets to estimate flood exposure at the city scale: an evaluation in Addis Ababa. Front Environ Sci, 12, 1330295, https://doi.org/10.3389/FENVS.2024.1330295/BIBTEX.

CEPREDENAC, GFDRR, IDB, Spanish Fund for Latinamerica and the Caribbean, ISDR, and The World Bank, 2015: CAPRA Initiative: Integrating Disaster Risk Information Into Development Policies and Programs in Latin America and the Caribbean Working Towards Safe and Sustainable Urban Environments. https://ecapra.org/sites/default/files/documents/CAPRA%20Initiative%20Integrating%20disaster%20risk%20into%20development%20policies%20in%20LATAM.pdf (Accessed July 29, 2024).

Chantavilasvong, W., and L. Guerrero, 2019: Application of HAZUS-MH Flood Model in Developing Countries: The Case of Piura, Peru. NAKHARA (Journal of Environmental Design and Planning), 16.

Copernicus, 2024: Global Human Settlement - GHSL Homepage - European Commission. https://human-settlement.emergency.copernicus.eu/ (Accessed December 16, 2024).

Courty, L. G., R. L. Wilby, J. K. Hillier, and L. J. Slater, 2019: Intensity-duration-frequency curves at the global scale. Environmental Research Letters, 14, 084045, https://doi.org/10.1088/1748-9326/AB370A.

Datta, A., D. J. Wu, W. Zhu, M. Cai, and W. L. Ellsworth, 2022: DeepShake: Shaking Intensity Prediction Using Deep Spatiotemporal RNNs for Earthquake Early Warning. Seismological Research Letters, 93, 1636–1649, https://doi.org/10.1785/0220210141.

Deltares, 2024a: Delft-FIAT. https://storymaps.arcgis.com/stories/687a256881b94bf6ad20677543bb8cf2 (Accessed January 12, 2025).

——, 2024b: Delft-FIAT: A flood impact assessment tool | Deltares. https://www.deltares.nl/en/software-and-data/products/delft-fiat-flood-impact-assessment-tool (Accessed November 17, 2024).

Dewitte, S., J. P. Cornelis, R. Müller, and A. Munteanu, 2021: Artificial Intelligence Revolutionises Weather Forecast, Climate Monitoring and Decadal Prediction. Remote Sensing 2021, Vol. 13, Page 3209, 13, 3209, https://doi.org/10.3390/RS13163209.

Dis, M. O., E. Anagnostou, and Y. Mei, 2018: Using high-resolution satellite precipitation for flood frequency analysis: case study over the Connecticut River Basin. J Flood Risk Manag, 11, S514–S526, https://doi.org/10.1111/JFR3.12250.

Eberenz, S., D. Stocker, T. Röösli, and D. Bresch, 2019: Exposure data for global physical risk assessment. https://doi.org/10.5194/essd-2019-189.

ETH Zurich, 2017a: CLIMADA overview — CLIMADA 5.0.0 documentation. https://climada-python.readthedocs.io/en/stable/tutorial/1_main_climada.html (Accessed February 5, 2025).

——, 2017b: Hazard: Tropical cyclones — CLIMADA 5.0.0 documentation. https://climada-python.readthedocs.io/en/stable/tutorial/climada_hazard_TropCyclone.html (Accessed February 6, 2025).

——, 2017c: Welcome to CLIMADA! — CLIMADA 5.0.0 documentation. https://climada-python.readthedocs.io/en/stable/index.html (Accessed August 27, 2024).

——, 2025a: ECA Case Studies – Weather and Climate Risks | ETH Zurich. https://wcr.ethz.ch/research/casestudies.html (Accessed February 6, 2025).

——, 2025b: CLIMADA Data Types. https://climada.ethz.ch/climada-api/data-types/ (Accessed February 9, 2025).

expert.ai, 2024: What Is Machine Learning? A Definition. https://www.expert.ai/blog/machine-learning-definition/ (Accessed September 30, 2024).

FEMA, 2020: GitHub - nhrap-hazus/hazpy. https://github.com/nhrap-hazus/hazpy?tab=readme-ov-file (Accessed January 1, 2025).

——, 2022a: Hazus Hurricane Model Technical Manual Hazus 5.1.

——, 2022b: Multi-hazard Loss Estimation Methodology: Flood Model Hazus®-MH 5.1 Technical Manual.

——, 2022c: Hazus Software.

——, 2022d: FEMA Factsheet: Hazus Flood Hazard Import Tool (FHIT)1.

——, 2022e: Hazus Tsunami Model Technical Manual.

——, 2022f: Multi-hazard Loss Estimation Methodology Earthquake Model Hazus ®-MH 5.1 Technical Manual. https://www.fema.gov/sites/default/files/documents/fema_hazus-earthquake-model-technical-manual-5-1.pdf (Accessed July 14, 2024).

——, 2023: What is Hazus? https://www.fema.gov/flood-maps/tools-resources/flood-map-products/hazus/about (Accessed July 7, 2024).

——, 2024a: Centro de servicio de mapas de inundaciones de FEMA | Hazus. https://msc-fema-gov.translate.goog/portal/resources/hazus?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc (Accessed January 1, 2025).

——, 2024b: FEMA Flood Map Service Center: Hazus.

——, 2024c: Hazus User & Technical Manuals. https://www.fema.gov/flood-maps/tools-resources/flood-map-products/hazus/user-technical-manuals (Accessed July 7, 2024).

——, 2024d: Hazus 7.0 User Guide.

——, Hazus ®-MH 2.1 User Manual Hazus-MH User Manual ii.

Field, E. H., T. H. Jordan, and C. A. Cornell (2003). "OpenSHA - A developing Community- Modeling Environment for Seismic Hazard Analysis". In: Seism. Res. Lett. 74, pages 406– 419

FloodRise, 2024: FloodRISE - Tijuana River Valley Flood Hazards. https://ucirvine.maps.arcgis.com/apps/webappviewer/index.html?id=1d3fe4654858432aad4ca324b6e819ea (Accessed January 12, 2025).

FloodRiskGroup, 2021: GitHub - FloodRiskGroup/floodrisk2: FloodRisk2 is a QGIS 3.x plugin and is a new version of the previous FloodRisk for QGIS 2.x, having additional features. https://github.com/FloodRiskGroup/floodrisk2 (Accessed July 9, 2024).

Gegenleithner, S., M. Pirker, C. Dorfmann, R. Kern, and J. Schneider, 2024: Long Short-Term Memory Networks for Real-time Flood Forecast Correction: A Case Study for an Underperforming Hydrologic Model. EGUsphere, 2024, 1–24, https://doi.org/10.5194/egusphere-2024-1030.

GEM, 2024a: OpenQuake Integrated Risk Modelling Toolkit — Integrated Risk Modelling Toolkit 3.20.0 documentation. https://docs.openquake.org/oq-irmt-qgis/v3.20.0/ (Accessed July 29, 2024).

——, 2024b: Global Exposure Model | Global EarthQuake Model Foundation. https://www.globalquakemodel.org/product/global-exposure-model (Accessed December 16, 2024).

——, 2024c: GEM Vulnerability Model Documentation — GEM Vulnerability Functions 2022.1.1-dev documentation. https://docs.openquake.org/vulnerability/ (Accessed December 16, 2024).

——, 2024d: Overview of the OpenQuake engine — OpenQuake Engine 3.20.1 documentation. https://docs.openquake.org/oq-engine/manual/latest/underlying-science/overview.html (Accessed July 29, 2024).

——, 2024e: Release notes v3.23 — OpenQuake Engine 3.23 documentation. https://docs.openquake.org/oq-engine/master/manual/release-notes/whats-new-3.23.html (Accessed March 6th, 2025).

GFDRR, 2018: Machine Learning for Disaster Risk Management. https://www.gfdrr.org/sites/default/files/publication/181222_WorldBank_DisasterRiskManagement_Ebook_D6.pdf (Accessed September 30, 2024).

Google, 2024a: Flood Forecasting: AI for Information & Alerts - Google Research. https://sites.research.google/floodforecasting/ (Accessed October 6, 2024).

——, 2024b: How Google uses AI to improve global flood forecasting. https://blog.google/technology/ai/google-ai-global-flood-forecasting/ (Accessed October 6, 2024).

Google Research, 2024: Open Buildings - Google Research - Open Buildings. https://sites.research.google/gr/open-buildings/ (Accessed December 16, 2024).

He, R., W. Zhang, J. Dou, N. Jiang, H. Xiao, and J. Zhou, 2024: Application of artificial intelligence in three aspects of landslide risk assessment: A comprehensive review. Rock Mechanics Bulletin, 3, 100144, https://doi.org/10.1016/J.ROCKMB.2024.100144.

Hochrainer-Stigler, S., 2014: User Interface of the CatSim Model and Practical Guidelines. https://pure.iiasa.ac.at/id/eprint/11212/1/XO-14-004.pdf (Accessed November 17, 2024).

——, R. Mechler, and G. Pflug, 2013: Modeling Macro Scale Disaster Risk: The CATSIM Model. 119–143, https://doi.org/10.1007/978-94-007-2226-2_8.

——, ——, and J. Mochizuki, 2015: A risk management tool for tackling country-wide contingent disasters: A case study on Madagascar. Environmental Modelling & Software, 72, 44–55, https://doi.org/10.1016/J.ENVSOFT.2015.06.004.

Huffman, G. J., and Coauthors, 2020: NASA Global Precipitation Measurement (GPM) Integrated Multi-satellitE Retrievals for GPM (IMERG).

Huizinga, J., H. de Moel, and W. Szewczyk, 2017: Global flood depth-damage functions. Methodology and the database with guidelines. 1–108 pp.

IIASA, 2024a: CATSIM - Inter-industry Impact Assessment - CATSIM - Inter-industry Impact Assessment - IIASA. https://previous.iiasa.ac.at/web/home/research/researchPrograms/RISK/catsimvariations.html (Accessed November 17, 2024).

——, 2024b: Catastrophe Simulation (CATSIM) | IIASA. https://iiasa.ac.at/models-tools-data/catsim (Accessed November 17, 2024).

——, 2024c: Financial preparation for natural disasters | IIASA. https://iiasa.ac.at/impacts/nov-2014/financial-preparation-for-natural-disasters (Accessed November 17, 2024).

InaSAFE, 2019a: InaSAFE concepts — InaSAFE Documentation Project 3.0.0 documentation. https://manual.inasafe.org/training/socialisation/inasafe_concepts.html (Accessed July 18, 2024).

——, 2019b: Introducing InaSAFE — InaSAFE Documentation Project 3.0.0 documentation. https://manual.inasafe.org/training/socialisation/introduction.html (Accessed July 18, 2024).

——, 2019c: InaSAFE 5.0 is released | InaSAFE. https://inasafe.org/news/inasafe-5-0-is-released/index.html (Accessed July 18, 2024).

——, 2019d: Roles & responsibilities | InaSAFE. https://inasafe.org/about-inasafe/governance/roles-responsibilities/index.html (Accessed July 18, 2024).

——, 2019e: Case Study: InaSAFE during Jakarta's Flood in 2014. https://inasafe.org/about-inasafe/cases/index.html (Accessed July 18, 2024).

——, 2023: Module 5: Calculating Damages and Losses — InaSAFE Documentation Project 3.0.0 documentation. https://manual.inasafe.org/training/old-training/intermediate/qgis-inasafe/405-calculating-damages-and-losses.html (Accessed January 20, 2025).

IN-CORE, 2024: IN-CORE. https://incore.ncsa.illinois.edu/ (Accessed July 31, 2024).

Ivić, M., 2019: ARTIFICIAL INTELLIGENCE AND GEOSPATIAL ANALYSIS IN DISASTER MANAGEMENT. https://doi.org/10.5194/isprs-archives-XLII-3-W8-161-2019.

Jain, H., R. Dhupper, A. Shrivastava, D. Kumar, and M. Kumari, 2023: AI-enabled strategies for climate change adaptation: protecting communities, infrastructure, and businesses from the impacts of climate change. Computational Urban Science, 3, 1–17, https://doi.org/10.1007/S43762-023-00100-2/FIGURES/3.

Jain, P., S. C. P. Coogan, S. G. Subramanian, M. Crowley, S. Taylor, and M. D. Flannigan, 2020: A review of machine learning applications in wildfire science and management. Environmental Reviews, 28, 478–505, https://doi.org/10.1139/ER-2020-0019/ASSET/IMAGES/ER-2020-0019TAB3.GIF.

Jiao, P., and A. H. Alavi, 2020: Artificial intelligence in seismology: Advent, performance and future trends. Geoscience Frontiers, 11, 739–744, https://doi.org/10.1016/J.GSF.2019.10.004.

Jones, A., and Coauthors, 2023: AI for climate impacts: applications in flood risk. npj Climate and Atmospheric Science 2023 6:1, 6, 1–8, https://doi.org/10.1038/s41612-023-00388-1.

Khan, C. B., and Coauthors, 2023: A Biologist's Guide to the Galaxy: Leveraging Artificial Intelligence and Very High-Resolution Satellite Imagery to Monitor Marine Mammals from Space. J Mar Sci Eng, 11, 595, https://doi.org/10.3390/JMSE11030595/S1.

König, N., 2017: Case Study of Hurricane Matthew - Loss Analysis with climada and Oasis LMF using ECMWF Forecast Data. .

Kou, G., D. Ergu, and Y. Shi, 2014: An integrated expert system for fast disaster assessment. Comput Oper Res, 42, 95–107, https://doi.org/10.1016/J.COR.2012.10.003.

Kropf, C. M., A. Ciullo, L. Otth, S. Meiler, A. Rana, E. Schmid, J. W. Mccaughey, and D. N. Bresch, 2022: Uncertainty and sensitivity analysis for probabilistic weather and climate-risk modelling: an implementation in CLIMADA v.3.1.0. Geosci. Model Dev, 15, 7177–7201, https://doi.org/10.5194/gmd-15-7177-2022.

Kulmesch, S., G. Paulus, and M. Leitner, 2010: Evaluation of the HAZUS-MH Loss Estimation Methodology for a Natural Risk Management Case Study in Carinthia, Austria.

Kulp, S. A., and B. H. Strauss, 2018: CoastalDEM: A global coastal digital elevation model improved from SRTM using a neural network. Remote Sens Environ, 206, 231–239, https://doi.org/10.1016/J.RSE.2017.12.026.

Lehigh University, and Florida Atlantic University, 2020: PRAISys. http://www.praisys.org/ (Accessed January 1, 2025).

van de Lindt, J. W., and Coauthors, 2023: The interdependent networked community resilience modeling environment (IN-CORE). Resilient Cities and Structures, 2, 57–66, https://doi.org/10.1016/J.RCNS.2023.07.004.

Llauca, H., W. Lavado-casimiro, K. León, J. Jimenez, K. Traverso, and P. Rau, 2021: Assessing Near Real-Time Satellite Precipitation Products for Flood Simulations at Sub-Daily Scales in a Sparsely Gauged Watershed in Peruvian Andes. Remote Sensing 2021, Vol. 13, Page 826, 13, 826, https://doi.org/10.3390/RS13040826.

Marulanda, M. C., M. L. Carreño, O. D. Cardona, M. G. Ordaz, and A. H. Barbat, 2013: Probabilistic earthquake risk assessment using CAPRA: Application to the city of Barcelona, Spain. Natural Hazards, 69, 59–84, https://doi.org/10.1007/S11069-013-0685-Z/METRICS.

Masood, M., M. Naveed, M. Iqbal, G. Nabi, H. M. Kashif, M. Jawad, and A. Mujtaba, 2023: Evaluation of Satellite Precipitation Products for Estimation of Floods in Data-Scarce Environment. Advances in Meteorology, 2023, 1685720, https://doi.org/10.1155/2023/1685720.

Mccarthy, J., 2007: WHAT IS ARTIFICIAL INTELLIGENCE?

McClean, F., R. Dawson, and C. Kilsby, 2023: Intercomparison of global reanalysis precipitation for flood risk modelling. Hydrol Earth Syst Sci, 27, 331–347, https://doi.org/10.5194/HESS-27-331-2023.

McSpadden, D., S. Goldenberg, B. Roy, M. Schram, J. Goodall, and H. Lipford, 2023: A comparison of machine learning surrogate models of street-scale flooding in Norfolk, Virginia. Machine Learning with Applications, https://doi.org/10.48550/ARXIV.2307.14185.

META, 2025: Mapas de densidad de población de alta resolución de Data For Good at Meta. https://dataforgood.facebook.com/dfg/tools/high-resolution-population-density-maps#methodology (Accessed February 16, 2025).

Microsoft, 2024: GitHub - microsoft/GlobalMLBuildingFootprints: Worldwide building footprints derived from satellite imagery. https://github.com/microsoft/GlobalMLBuildingFootprints?tab=readme-ov-file#will-there-be-more-data-coming-for-other-geographies (Accessed December 16, 2024).

Mistry, H. K., and D. Lombardi, 2023: A stochastic exposure model for seismic risk assessment and pricing of catastrophe bonds. Natural Hazards, 117, 803–829, https://doi.org/10.1007/S11069-023-05884-4/TABLES/4.

Mohammadi, S. A., M. Nazariha, and N. Mehrdadi, 2014: Flood Damage Estimate (Quantity), Using HEC-FDA Model. Case Study: The Neka River. Procedia Eng, 70, 1173–1182, https://doi.org/10.1016/J.PROENG.2014.02.130.

Munich Climate Insurance Initiative, 2020: CLIMADA | ECA. https://eca-network.org/climada/ (Accessed July 21, 2024).

NASA, 2020: The IMERG multi-satellite precipitation estimates reformatted as 2-byte GeoTIFF files for display in a Geographic Information System (GIS).

——, 2024: Together, we can build a clearer picture of landslides.

National Institute of Water and Atmospheric Research Ltd, and Institute of Geological and Nuclear Sciences Ltd, 2024a: Overview — RiskScape 1.6.0 documentation. https://riskscape.org.nz/docs/intro/overview.html#overview (Accessed August 14, 2024).

——, and ——, 2024b: Release Changelog — RiskScape 1.6.0 documentation. https://riskscape.org.nz/docs/general/CHANGELOG.html#v1-6-0 (Accessed August 14, 2024).

National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd, 2024c: Probabilistic modelling — RiskScape 1.7.0 documentation. https://riskscape.org.nz/docs/advanced/probabilistic.html (Accessed September 25, 2024).

——, 2024d: Models — RiskScape 1.7.0 documentation. https://riskscape.org.nz/docs/reference/models.html#models (Accessed September 24, 2024).

——, 2024e: Creating a RiskScape project — RiskScape 1.7.0 documentation. https://riskscape.org.nz/docs/intro/project-tutorial.html (Accessed September 24, 2024).

Nearing, G., and Coauthors, 2024: Global prediction of extreme floods in ungauged watersheds. Nature 2024 627:8004, 627, 559–563, https://doi.org/10.1038/s41586-024-07145-1.

Nevo, S., and Coauthors, 2022: Flood forecasting with machine learning models in an operational framework. Hydrol Earth Syst Sci, 26, 4013–4032, https://doi.org/10.5194/HESS-26-4013-2022.

Nirandjan, S., E. E. Koks, M. Ye, R. Pant, K. C. H. Van Ginkel, J. C. J. H. Aerts, and P. J. Ward, 2024: Physical vulnerability database for critical infrastructure hazard risk assessments-a systematic review and data collection. Hazards Earth Syst. Sci, 24, 4341–4368, https://doi.org/10.5194/nhess-24-4341-2024.

Nkwunonwo, U., M. Whitworth, and B. Baily, 2015: Relevance of Social Vulnerability Assessment to Flood Risk Reduction in the Lagos Metropolis of Nigeria. Br J Appl Sci Technol, 8, 366–382, https://doi.org/10.9734/BJAST/2015/17518.

Oasis LMF, 2024a: Oasis LMF Documentation. https://oasislmf.github.io/home/introduction.html (Accessed November 11, 2024).

——, 2024b: FAQs :: Oasis Loss Modelling Framework. https://oasislmf.org/faqs (Accessed August 1, 2024).

——, 2024: Modelling methodology - Oasis LMF Documentation. https://oasislmf.github.io/sections/modelling-methodology.html#simulation-methodology (Accessed February 4, 2025).

OECD, and JRC, 2008: Handbook on Constructing Composite Indicators. OECD publishing, 1–162 pp.

OpenStreetMap contributors., 2017: Planet dump retrieved from https://planet.osm.org .

Papathoma-Köhle, M., M. Schlögl, L. Dosser, F. Roesch, M. Borga, M. Erlicher, M. Keiler, and S. Fuchs, 2022: Physical vulnerability to dynamic flooding: Vulnerability curves and vulnerability indices. J Hydrol (Amst), 607, 127501, https://doi.org/10.1016/J.JHYDROL.2022.127501.

Pesaresi, M., and P. Politis, 2023: GHS-BUILT-H R2023A - GHS building height, derived from AW3D30, SRTM30, and Sentinel2 composite. European Commission, Joint Research Centre (JRC),.

Plevris, V., 2024: AI-Driven Innovations in Earthquake Risk Mitigation: A Future-Focused Perspective. Geosciences 2024, Vol. 14, Page 244, 14, 244, https://doi.org/10.3390/GEOSCIENCES14090244.

Prakash, N., A. Manconi, and S. Loew, 2021: A new strategy to map landslides with a generalized convolutional neural network. Scientific Reports 2021 11:1, 11, 1–15, https://doi.org/10.1038/s41598-021-89015-8.

Pregnolato, M., C. Galasso, and F. Parisi, 2015: A compendium of existing vulnerability and fragility relationships for flood : preliminary results. https://doi.org/10.14288/1.0076226.

PreventionWeb, 2023: RiskChanges: Open-Source Tool for Multi-Hazard Risk Assessment and Management | UN-SPIDER Knowledge Portal. https://www.preventionweb.net/drr-community-voices/open-source-tool-assist-multi-hazard-risk-assessment (Accessed January 1, 2025).

Rao, A., and Coauthors, 2020: Probabilistic seismic risk assessment of India. https://doi.org/10.1177/8755293020957374, 36, 345–371, https://doi.org/10.1177/8755293020957374.

RiskChanages, 2021: RiskChangesDesktop · PyPI. https://pypi.org/project/RiskChangesDesktop/#files (Accessed January 1, 2025).

RiskChanges, 2021: Tutorials on GUI — RiskChanges 1.0.0 documentation. https://sdss-documentation.readthedocs.io/en/latest/tutorials_gui.html (Accessed January 12, 2025).

Rodríguez, J. T., B. Vitoriano, J. Montero, and V. Kecman, 2011: A disaster-severity assessment DSS comparative analysis. OR Spectrum, 33, 451–479, https://doi.org/10.1007/S00291-011-0252-5/METRICS.

Rozelle, J. R., 2007: INTERNATIONAL ADAPTATION OF THE HAZUS EARTHQUAKE MODEL USING GLOBAL EXPOSURE DATASETS.

Rygel, L., D. O'Sullivan, and B. Yarnal, 2006: A method for constructing a social vulnerability index: An application to hurricane storm surges in a developed country. Mitig Adapt Strateg Glob Chang, 11, 741–764, https://doi.org/10.1007/s11027-006-0265-6.

Sapountzis, M., A. Kastridis, A. P. Kazamias, A. Karagiannidis, P. Nikopoulos, and K. Lagouvardos, 2021: Utilization and uncertainties of satellite precipitation data in flash flood hydrological analysis in ungauged watersheds. Global Nest Journal, 23, 388–399, https://doi.org/10.30955/GNJ.003905.

Scofield, R. A., 1987: The NESDIS Operational Convective Precipitation- Estimation Technique. Mon Weather Rev, 115, 1773–1793, https://doi.org/10.1175/1520-0493(1987)115<1773:tnocpe>2.0.co;2.

——, and R. J. Kuligowski, 2003: Status and outlook of operational satellite precipitation algorithms for extreme-precipitation events. Weather Forecast, 18, 1037–1051, https://doi.org/10.1175/1520-0434(2003)018<1037:SAOOOS>2.0.CO;2.

Scussolini, P., J. C. J. H. Aerts, B. Jongman, L. M. Bouwer, H. C. Winsemius, H. de Moel, and P. J. Ward, 2016: FLOPROS: an evolving global database of flood protection standards. Natural Hazards and Earth System Sciences, 16, 1049–1061, https://doi.org/10.5194/nhess-16-1049-2016.

Shameem Ansar, A., S. Sudha, and S. Francis, 2022: Identification and classification of landslide susceptible zone using geospatial techniques and machine learning models. Geocarto Int, 37, 18328–18355, https://doi.org/10.1080/10106049.2022.2138986.

Sheehan, B., M. Mullins, D. Shannon, and O. McCullagh, 2023: On the benefits of insurance and disaster risk management integration for improved climate-related natural catastrophe resilience. Environ Syst Decis, 43, 639–648, https://doi.org/10.1007/S10669-023-09929-8/FIGURES/2.

Souvignet, M., D. Florian, W. Ieneke, L. Mueller, D. N. Bresch, and K. Development Bank, 2016: Economics of Climate Adaptation (ECA)-Guidebook for Practitioners A Climate Risk Assessment Approach Supporting Climate Adaptation Investments.

Stalhandske, Z., E. Schmid, C. B. Steinmann, C. Kropf, and D. N. Bresch, 2022: Many-hazard Risk Assessment with the CLIMADA Data API. EGU22, https://doi.org/10.5194/EGUSPHERE-EGU22-8673.

——, C. B. Steinmann, S. Meiler, I. J. Sauer, T. Vogt, D. N. Bresch, and C. M. Kropf, 2024: Global multi-hazard risk assessment in a changing climate. Scientific Reports 2024 14:1, 14, 1–14, https://doi.org/10.1038/s41598-024-55775-2.

Sterlacchini, S., S. O. Akbas, J. Blahut, O.-C. Mavrouli, C. Garcia, B. Q. Luna, and J. Corominas, 2014: Methods for the characterization of the vulnerability of elements at risk. Mountain Risks: From Prediction to Management and Governance, T. Van Asch, J. Corominas, S. Greiving, J.-P. Malet, and S. Sterlacchini, Eds., Vol. 34 of, Springer Netherlands, 233–273.

Strauch, W., 2009: Estimación de la precipitación usando imágenes de satélite - aporte a la alerta temprana de deslizamientos. https://webserver2.ineter.gob.ni/desliza/nesdis/lluvia/gif/tecnico.html (Accessed January 21, 2020).

Subramaniam, S., and Coauthors, 2022: Artificial Intelligence Technologies for Forecasting Air Pollution and Human Health: A Narrative Review. Sustainability 2022, Vol. 14, Page 9951, 14, 9951, https://doi.org/10.3390/SU14169951.

Sufi, F. K., 2022: AI-SocialDisaster: An AI-based software for identifying and analyzing natural disasters from social media. Software Impacts, 13, 100319, https://doi.org/10.1016/j.simpa.2022.100319.

——, and I. Khalil, 2024: Automated Disaster Monitoring from Social Media Posts Using AI-Based Location Intelligence and Sentiment Analysis. IEEE Trans Comput Soc Syst, 11, 4614–4624, https://doi.org/10.1109/TCSS.2022.3157142.

Sun, W., P. Bocchini, and B. D. Davison, 2020: Applications of artificial intelligence for disaster management. Natural Hazards 2020 103:3, 103, 2631–2689, https://doi.org/10.1007/S11069-020-04124-3.

Sven Willner, Inga Sauer, Lisa Novak, and Christian Otto, 2024: Global simulations of fluvial floods based on the ISIMIP2 ensemble of global hydrological models (v1.0). ISIMIP Repository. https://doi.org/10.48364/ISIMIP.303619 (Accessed February 9, 2025).

Tan, L., J. Guo, S. Mohanarajah, and K. Zhou, 2020: Can we detect trends in natural disaster management with artificial intelligence? A review of modeling practices. Natural Hazards 2020 107:3, 107, 2389–2417, https://doi.org/10.1007/S11069-020-04429-3.

Tedla, M. G., M. Rasmy, T. Koike, and L. Zhou, 2024: Evaluation of satellite precipitation products for real-time extreme river flow modeling in data scarce regions. Proceedings of the International Association of Hydrological Sciences, 386, 223–228, https://doi.org/10.5194/PIAHS-386-223-2024.

The World Bank, 2019: Fragility and Vulnerability Assessment Guide GPSS Global Program for Safer Schools GLOSI THE GLOBAL LIBRARY OF SCHOOL INFRASTRUCTURE GPSS.

Trinh, M. X., and F. Molkenthin, 2021: Flood hazard mapping for data-scarce and ungauged coastal river basins using advanced hydrodynamic models, high temporal-spatial resolution remote sensing precipitation data, and satellite imageries. Natural Hazards, 109, 441–469, https://doi.org/10.1007/S11069-021-04843-1/FIGURES/10.

United Nations General Assembly, 2015: Resolution adopted by the General Assembly on 3 June 2015. Sendai Framework for Disaster Risk Reduction 2015–2030. 1–24, https://doi.org/10.1093/oxfordhb/9780199560103.003.0005.

Universidad de Los Andes, 2024a: CAPRA-GIS | CAPRA | Probabilistic Risk Assessment Platform. https://ecapra.org/topics/capra-gis (Accessed July 29, 2024).

——, 2024b: About Us | CAPRA | Probabilistic Risk Assessment Platform. https://ecapra.org/about-us (Accessed July 29, 2024).

University of Southampton, 2018: WorldPop (www.worldpop.org) 100m Population. Version 2.0 estimates for numbers of people per pixel (ppp) and people per hectare (pph) for 2020, with national totals adjusted to match UN population division estimates (http://esa.un.org/wpp/).

USACE, 2024a: Risk Assessment Methodology. https://www.hec.usace.army.mil/confluence/fdadocs/techref/risk-assessment-methodology-167248960.html (Accessed August 22, 2024).

——, 2024b: Risk Measurement. https://www.hec.usace.army.mil/confluence/fdadocs/techref/risk-measurement-139729880.html (Accessed August 22, 2024).

——, 2024c: Monte Carlo Simulation. https://www.hec.usace.army.mil/confluence/fdadocs/techref/monte-carlo-simulation-159155747.html (Accessed August 22, 2024).

——, 2024d: Expected Annual Damage. https://www.hec.usace.army.mil/confluence/fdadocs/techref/expected-annual-damage-167248971.html (Accessed August 22, 2024).

——, 2024e: Average Annual Equivalent Damage with Uncertainty. https://www.hec.usace.army.mil/confluence/fdadocs/techref/average-annual-equivalent-damage-with-uncertainty-167249007.html (Accessed August 22, 2024).

——, 2024f: Damage Reduced With Uncertainty. https://www.hec.usace.army.mil/confluence/fdadocs/techref/damage-reduced-with-uncertainty-167249022.html (Accessed August 22, 2024).

——, 2024g: Deterministic System Performance Metrics. https://www.hec.usace.army.mil/confluence/fdadocs/techref/deterministic-system-performance-metrics-167248986.html (Accessed August 22, 2024).

Vickery, P. J., D. Wadhera, M. D. Powell, and Y. Chen, 2009: A Hurricane Boundary Layer and Wind Field Model for Use in Engineering Applications. J Appl Meteorol Climatol, 48, 381–405, https://doi.org/10.1175/2008JAMC1841.1.

Wanzala, M. A., A. Ficchi, H. L. Cloke, E. M. Stephens, H. M. Badjana, and D. A. Lavers, 2022a: Assessment of global reanalysis precipitation for hydrological modelling in data-scarce regions: A case study of Kenya. J Hydrol Reg Stud, 41, 101105, https://doi.org/10.1016/J.EJRH.2022.101105.

Wanzala, M. A., A. Ficchi, H. L. Cloke, E. M. Stephens, H. M. Badjana, and D. A. Lavers, 2022b: Assessment of global reanalysis precipitation for hydrological modelling in data-scarce regions: A case study of Kenya. J Hydrol Reg Stud, 41, 101105, https://doi.org/https://doi.org/10.1016/j.ejrh.2022.101105.

Wasko, C., S. Westra, R. Nathan, H. G. Orr, G. Villarini, R. V. Herrera, and H. J. Fowler, 2021: Incorporating climate change in flood estimation guidance. Philosophical Transactions of the Royal Society A, https://doi.org/10.1098/RSTA.2019.0548.

Van Westen, C., and W. Bakker, 2015: Software Development Report.

Xu, C., and Z. Xue, 2024: Applications and challenges of artificial intelligence in the field of disaster prevention, reduction, and relief. Natural Hazards Research, 4, 169–172, https://doi.org/10.1016/J.NHRES.2023.11.011.

Yang, L., J. Driscol, S. Sarigai, Q. Wu, H. Chen, and C. D. Lippitt, 2022: Google Earth Engine and Artificial Intelligence (AI): A Comprehensive Review. Remote Sensing 2022, Vol. 14, Page 3253, 14, 3253, https://doi.org/10.3390/RS14143253.

Yepes-Estrada, C., and Coauthors, 2023: Global building exposure model for earthquake risk assessment. https://doi.org/10.1177/87552930231194048, 39, 2212–2235, https://doi.org/10.1177/87552930231194048.

Yigitcanlar, T., K. C. Desouza, L. Butler, and F. Roozkhosh, 2020: Contributions and Risks of Artificial Intelligence (AI) in Building Smarter Cities: Insights from a Systematic Review of the Literature. Energies 2020, Vol. 13, Page 1473, 13, 1473, https://doi.org/10.3390/EN13061473.

Zhang, X., J. Zhang, C. Yuan, S. Liu, Z. Chen, and W. Li, 2020: Locating induced earthquakes with a network of seismic stations in Oklahoma via a deep learning method. Scientific Reports 2020 10:1, 10, 1–12, https://doi.org/10.1038/s41598-020-58908-5.

Zhu, Q., D. Zhou, Y. Luo, Y. P. Xu, G. Wang, and X. Gao, 2021: Suitability of high-temporal satellite-based precipitation products in flood simulation over a humid region of China. Hydrological Sciences Journal, 66, 104–117, https://doi.org/10.1080/02626667.2020.1844206.

Zhu, W., T. Tao, H. Yan, J. Yan, J. Wang, S. Li, and K. Xin, 2023: An optimized long short-term memory (LSTM)-based approach applied to early warning and forecasting of ponding in the urban drainage system. Hydrol Earth Syst Sci, 27, 2035–2050, https://doi.org/10.5194/HESS-27-2035-2023.



Imagen: Adobe Stock

ANEXOS

ANEXO A. CARACTERÍSTICAS DE LAS HERRAMIENTAS EXISTENTES PARA EL CÁLCULO DE RIESGO

A.1. CAPRA (PROBABILISTIC RISK ASSESSMENT PLATFORM)

A.1.1. Descripción general

CAPRA es una plataforma diseñada para la evaluación del riesgo de desastres utilizando un enfoque probabilístico. Esta plataforma permite a los usuarios cuantificar y analizar el riesgo asociado a diversas amenazas, facilitando la toma de decisiones informadas en la gestión del riesgo de desastres.

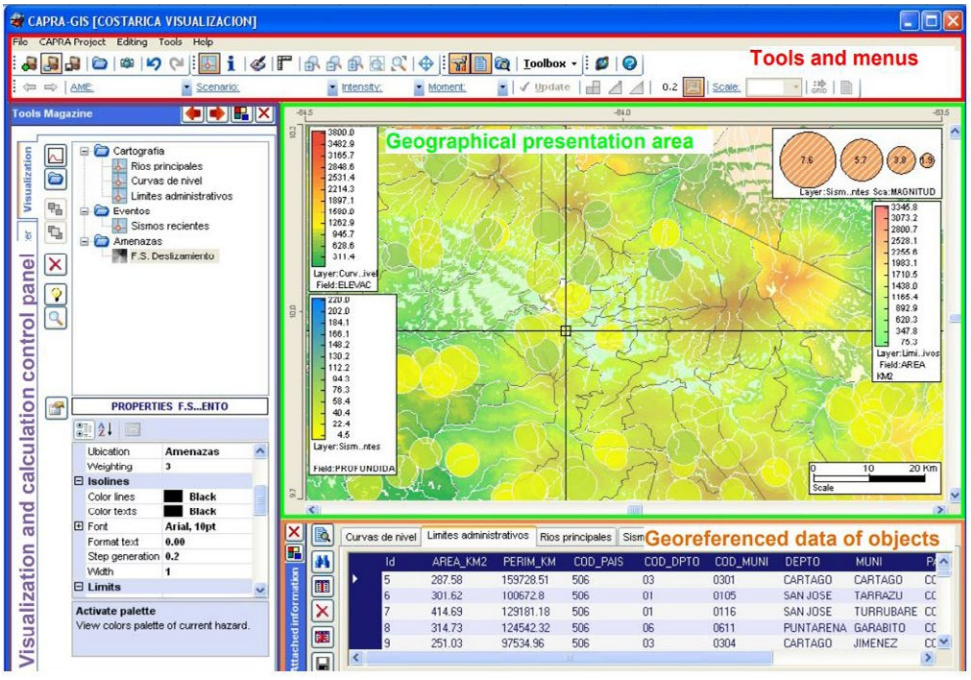
La plataforma CAPRA ofrece módulos específicos para el cálculo de amenaza por inundación, movimientos en masa, huracanes y sismos (Universidad de Los Andes 2024a). El módulo de evaluación de riesgos se denomina CAPRA-GIS y permite realizar los cálculos probabilísticos de riesgos basados en datos de amenaza, exposición y vulnerabilidad física.

A.1.2. Métodos aplicados

CAPRA aplica modelos probabilísticos para evaluar la exposición y vulnerabilidad a diferentes tipos de amenazas. Utiliza un enfoque modular que incluye la evaluación de amenaza, la exposición, la vulnerabilidad y el cálculo de daños. Los métodos incluyen simulaciones estocásticas y análisis de escenarios para proporcionar estimaciones de riesgo.

CAPRA-GIS puede procesar los resultados de amenaza obtenido de los módulos de CAPRA o de otras fuentes siempre y cuando los archivos de amenaza se encuentren en el formato propio del software (archivos de extensión .AME). La pantalla principal de la herramienta tiene las siguientes áreas: un área de menú y herramientas, un área de visualización geográfica, un área para desplegar información de datos georrefenciados, un área de barra de estatus y un área de mensajes de procesamiento, como se muestra en la Figura 30 (Banco Mundial et al. 2009).

Figura 30. Pantalla principal de CAPRA-GIS



Fuente: Banco Mundial et al. (2009).

La herramienta requiere los siguientes tipos de información (Banco Mundial et al. 2009):

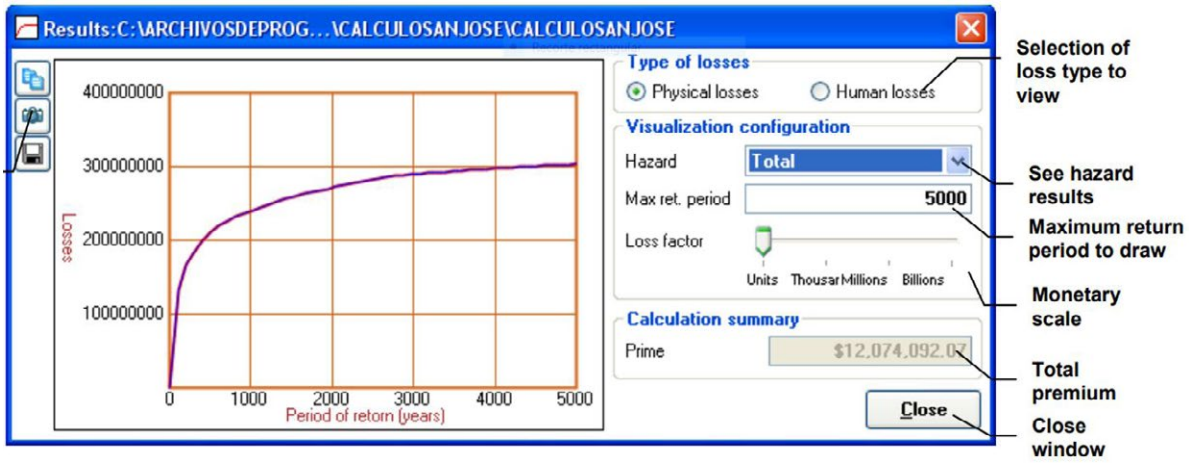
- **Archivos de amenaza (*.ame):** Los archivos de amenaza pueden almacenar cualquier número de combinaciones de configuraciones, intensidades y tiempos, para una frecuencia de ocurrencia determinada.

- **ShapeFiles (*.shp):** Son capas vectoriales que contienen información geográfica espacial. Los archivos shp contienen los elementos expuestos y sus atributos deben contener la tipología de los elementos expuestos a través de la cual se vinculan con una determinada curva de vulnerabilidad.

- **Archivo de vulnerabilidad ERN (*.dat):** archivos de texto externos con referencia y parámetros adicionales almacenados junto con el Proyecto, utilizados para configurar el cálculo de las pérdidas.

Una vez los 3 componentes están organizados en un proyecto, es posible iniciar los cálculos y obtener las métricas de riesgo, entre ellas la curva de riesgo y la distribución espacial de los daños. Los cálculos pueden ejecutarse por escenario o de manera probabilística.

Figura 31. Ventana de visualización de los cálculos de riesgo



Fuente: Banco Mundial et al. (2009).

A.1.3. Enfoque matemático

El enfoque matemático utilizado por CAPRA está desarrollado en Cardona et al. (2012) para el caso de sismos, pero el mismo enfoque se utiliza para todas las amenazas, a continuación, se presenta un resumen.

El riesgo se calcula utilizando la tasa de excedencia de los valores de pérdida, $v(p)$. Esta cantidad representa el número esperado de eventos por unidad de tiempo que generarán pérdidas iguales o mayores que p. Su cálculo se basa en el teorema de la probabilidad total:

Ecuación 4

$$v(p) = \sum_{i=1}^{Eventos} \Pr\left(P > p \,\middle|\, \text{Evento } i\right) \cdot F_A\left(\text{Evento } i\right)$$

donde "Pr" $(P>p \mid \text{Evento } i)$ es la probabilidad de excedencia de pérdida dado que ocurre el evento i, y F_A (Evento i) es la frecuencia anual de ocurrencia del evento i. Las funciones de vulnerabilidad se emplean para estimar $\Pr(P > p \mid \text{Evento } i)$. Para calcular $\Pr(P>p \mid \textit{Evento } i)$, se asume que, dado un evento

con magnitud y ubicación conocidas, la intensidad en el sitio donde se encuentra la estructura sigue una distribución lognormal con una mediana y desviación estándar logarítmica. Bajo esta suposición, la probabilidad requerida se obtiene encadenando dos distribuciones condicionales (Marulanda et al. 2013):

Ecuación 5

$$\Pr(P > p \mid \text{Evento}) = \int_0^{\infty} (P > p \mid Sa) \cdot p_{SA}(Sa \mid M,R) dSa$$

donde $p_{SA}(Sa \mid M,R)$ es la función de densidad de probabilidad de la intensidad Sa, dado que un sismo ocurre con magnitud M a una distancia R. Generalmente, $Sa \mid M,R$ se modela mediante una distribución lognormal cuya mediana y desviación estándar logarítmica dependen de M y R , y se determinan a partir del modelo de predicción del movimiento del terreno seleccionado por el analista. El primer término de la integral se obtiene a partir de la relación de vulnerabilidad de la estructura en análisis.

La estimación de pérdidas económicas se realiza multiplicando la proporción de daño obtenida en el módulo de vulnerabilidad por el valor en riesgo de cada clase de activo y ubicación. Posteriormente, las pérdidas se agregan según se requiera en el análisis.

Las principales métricas de estimación del riesgo incluyen la Pérdida Anual Promedio (PAP), la Curva de Excedencia de Pérdidas (CEP) y la Pérdida Máxima Probable (PMP). La PAP es la pérdida anual esperada y se define como la esperanza matemática de la pérdida anual:

Ecuación 6

$$\text{PAP} = \sum_{i=1}^{Eventos} \text{E}(P \mid \text{Evento } i)\, F_A(\text{Evento } i)$$

donde $\text{E}(P \mid \text{Evento } i)$ es la pérdida esperada del evento i, y $F_A(\text{Evento } i)$ es su frecuencia anual de ocurrencia. La CEP representa la frecuencia anual con la cual una pérdida monetaria específica será superada, y es la métrica más relevante en la gestión del riesgo catastrófico. Finalmente, la PMP indica la pérdida asociada a una determinada frecuencia de excedencia o período de retorno. La curva de PMP se define generalmente en términos de valor económico o porcentaje relativo al período de retorno, y se utiliza para determinar el tamaño de las reservas que las aseguradoras deben mantener para evitar pérdidas que excedan su capacidad financiera.

A.1.4. Avances recientes en CAPRA

La versión 2.4 de CAPRA-GIS introduce una versión de 64 bits que mejora la gestión de grandes cantidades de memoria RAM, optimizando el rendimiento en sistemas operativos de 64 bits. Además, esta actualización incluye características de seguridad mejoradas, como la protección contra

desbordamientos de búfer, protección de ejecución de datos (DEP) y Patch Guard, ofreciendo un entorno más seguro para el cálculo probabilístico de riesgos. Estas mejoras hacen que CAPRA-GIS sea más eficiente para el análisis de riesgos. Desafortunadamente, la versión 2.4 es del año 2018 y en la página oficial no existe información sobre actualizaciones ni del software ni de sus manuales. En el caso de los manuales estos fueron desarrollados en el año 2009 (Banco Mundial et al. 2009).

A.1.5. Comunidad de desarrollo

En julio de 2016, el Banco Mundial lanzó una convocatoria abierta para administrar y ser propietario del sitio web de CAPRA. Uniandes (Universidad de Los Andes – Colombia) fue seleccionada luego de que un panel evaluara la propuesta teniendo en cuenta criterios como la calidad técnica de la propuesta, el apoyo internacional de la propuesta y el conocimiento y experiencia con CAPRA, logrando el puntaje de evaluación más alto. Desde enero de 2017, Uniandes administra y es propietaria de la plataforma CAPRA (Universidad de Los Andes 2024b).

A.1.6. Limitaciones

Una de las principales limitaciones de CAPRA es la falta de documentación de los métodos utilizados para realizar los cálculos. Esta falta de documentación también se refleja en la creación del archivo .ame de entrada lo que hace complicado para los usuarios generar la información necesaria para ejecutar los cálculos de riesgo utilizando solo la documentación. De otro lado el código del software no se encuentra disponible en ningún repositorio, a pesar de que la iniciativa inicialmente abogaba por un código abierto, en la actualidad no es posible acceder al código de manera pública.

A.1.7. Casos de uso

CAPRA ha sido utilizada en varios países para evaluar el riesgo de desastres y desarrollar estrategias de mitigación. Por ejemplo, en Colombia, se ha aplicado para la evaluación del riesgo sísmico y de inundaciones, informando la planificación urbana y las políticas de gestión del riesgo. También se ha utilizado en proyectos de infraestructura para asegurar que las construcciones sean resilientes, como el caso de infraestructura de salud, gobierno y educativa descrito en la **Caja 2**.

Caja 2. Ejemplo de aplicación de CAPRA

Estudio de Caso de CAPRA en el Área Metropolitana de San Salvador (AMSS)

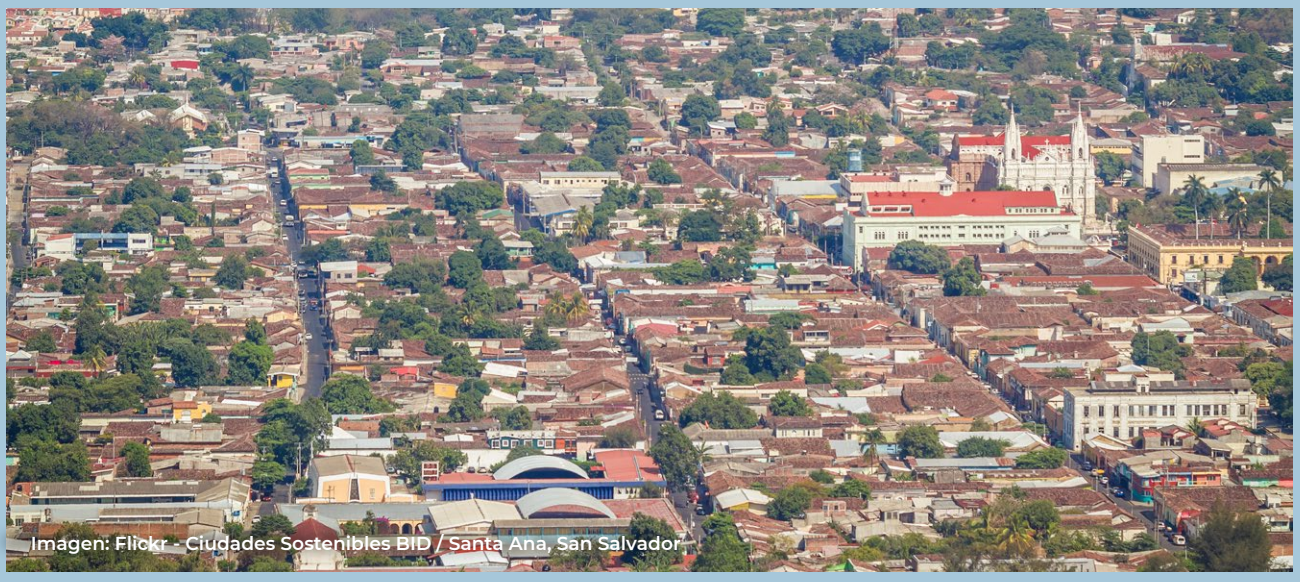


Imagen: Flickr - Ciudades Sostenibles BID / Santa Ana, San Salvador

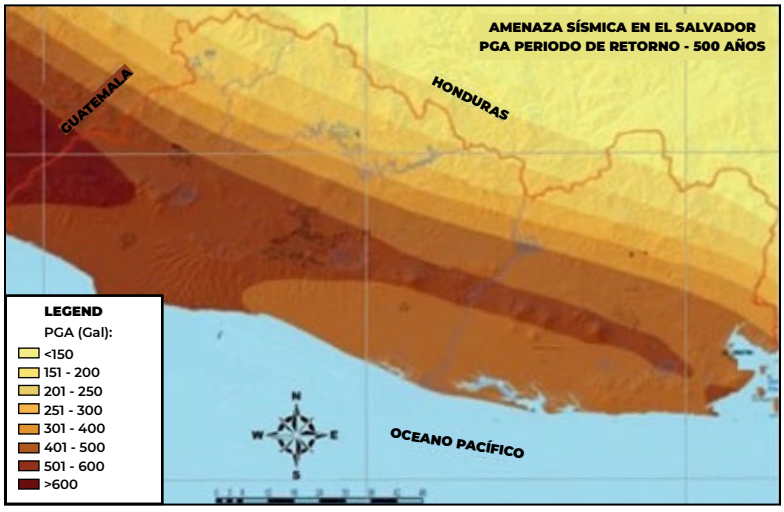
La amenaza sísmica en el Área Metropolitana de San Salvador (AMSS) se refiere a la probabilidad de que ocurra un movimiento sísmico de cierta intensidad en un lugar y tiempo específicos. Esta amenaza está determinada por factores inmodificables como la sismicidad, que incluye la frecuencia y magnitud de los sismos, y la geología de la región. Un aspecto clave en el análisis de la amenaza sísmica es la comprensión de la atenuación sísmica regional, que es la pérdida de energía que experimenta una onda sísmica al atravesar el suelo.

Para evaluar la respuesta sísmica en el AMSS, se recopilaron y validaron datos sobre la geología del área, análisis estratigráficos, registros de pozos de agua y parámetros dinámicos, además de registros acelerográficos. Esta información, administrada por la oficina de monitoreo del Ministerio de Medio Ambiente y Recursos Naturales (MARN), es esencial para entender cómo el suelo y otras características del sitio influyen en la magnitud y tipo de movimiento sísmico. Esto incluye los efectos del tipo de suelo y la coincidencia entre los periodos de vibración de las estructuras y el terreno.

Los mapas de amenaza y riesgo sísmico en el AMSS se desarrollaron con CAPRA e incluyen múltiples escenarios sísmicos probables, con un total de 24,996 posibles eventos sísmicos. Estos mapas proporcionan estimaciones de la aceleración máxima del suelo y los movimientos estructurales asociados para diferentes alturas de edificaciones en cada escenario. Los mapas son herramientas cruciales para identificar zonas con distintos niveles de respuesta sísmica, ayudando a prever el impacto de futuros terremotos y facilitando la planificación y mitigación de riesgos.

La evaluación de la vulnerabilidad en el AMSS incluyó el desarrollo de curvas de vulnerabilidad basadas en datos de daños de terremotos anteriores y registros de aceleración espectral de cada estructura. Se realizó un análisis específico de los edificios pertenecientes a los Ministerios de Salud y Gobierno, así como una muestra del 20% de los edificios del Ministerio de Educación. Este análisis consideró factores como el año de construcción, materiales, daños previos y características estructurales, ayudando a identificar los edificios más vulnerables ante futuros eventos sísmicos.

Amenaza sísmica para el periodo de retorno de 500 años



En respuesta a los hallazgos del análisis de vulnerabilidad sísmica, el gobierno de El Salvador diseñó un programa de reducción de vulnerabilidad con un enfoque inicial en el sector educativo. Este programa busca no solo abordar las necesidades urgentes de los edificios en condiciones críticas, sino también establecer una estrategia a largo plazo para mejorar las características estructurales y funcionales de las edificaciones existentes y nuevas. Este esfuerzo complementa otras políticas de reducción de riesgos implementadas en los últimos años.

Este análisis inicial realizado con CAPRA proporciona una estimación del daño probable basado en la información disponible, destacando la importancia de evaluar la vulnerabilidad sísmica para la toma de decisiones. Aunque los resultados están abiertos a revisión, el análisis es crucial para identificar los niveles de riesgo existentes y desarrollar estrategias para reducir estos riesgos a niveles aceptables. En áreas urbanas como el AMSS, donde los sismos son frecuentes, la infraestructura existente y el conocimiento de los peligros potenciales son determinantes para la planificación de mitigación de riesgos.

Fuente: CEPREDENAC et al. (2015).

A.2. HAZUS

A.2.1. Descripción general

Hazus proporciona una metodología estandarizada a nivel nacional desarrollada por la Agencia Federal para el Manejo de Emergencias (FEMA) de los Estados Unidos. Se distribuye como software de escritorio basado en SIG y gratuito, con una colección de bases de datos de inventario para cada estado y territorio de EE. UU. Hazus se utiliza para evaluar amenaza, vulnerabilidad y riesgo y estimar los impactos físicos, económicos y sociales de sismos, huracanes, inundaciones y tsunamis (FEMA 2023).

Hazus es un software diseñado para ejecutarse en ArcGIS. Los requerimientos mínimos de software de soporte son: Esri ArGIS 10.8.2, Microsoft Windows 10 o 11 64-bit (Pro & Enterprise), Esri's Spatial Analyst extension necesario para la evaluación de inundaciones y tsunami, y Windows NETFramework 4.8 (FEMA 2024b).

El programa Hazus proporciona datos, herramientas analíticas independientes y software que se ejecuta dentro de la plataforma ArcGIS Desktop de Esri. Las herramientas separadas incluyen el Sistema Integral de Gestión de Datos (CDMS) y varios módulos de código abierto que simplifican el análisis de riesgos, las exportaciones de datos y la generación de informes. Los datos de Hazus incluyen inventarios de referencia para edificios, instalaciones esenciales e infraestructura en Estados Unidos (FEMA 2022c).

Hazus cuenta con otras herramientas complementarias como:

- **Herramienta de importación de amenaza por inundación (Flood Hazard Import Tool - FHIT):** es una herramienta de código abierto que permite a los usuarios de Hazus buscar, descargar y preparar datos de amenaza por inundación disponibles al público para importarlos en una región de estudio de inundación de Hazus. Actualmente soporta modelos de profundidad de tormenta de ADCIRC (ADvanced CIRCulation Model) (FEMA 2022d) .

- **Herramienta de Exportación Hazus:** Una herramienta de código abierto que facilita la extracción y análisis de resultados de evaluación de riesgos de Hazus, sin necesidad de experiencia previa en mapeo o codificación. La Herramienta de Exportación permite procesar múltiples regiones de estudio de Hazus de manera eficiente y rápida (FEMA 2022d).

A.2.2. Métodos aplicados

Hazus emplea modelos de estimación de pérdidas que utilizan herramientas geográficas para calcular daños físicos, pérdidas económicas y sociales.

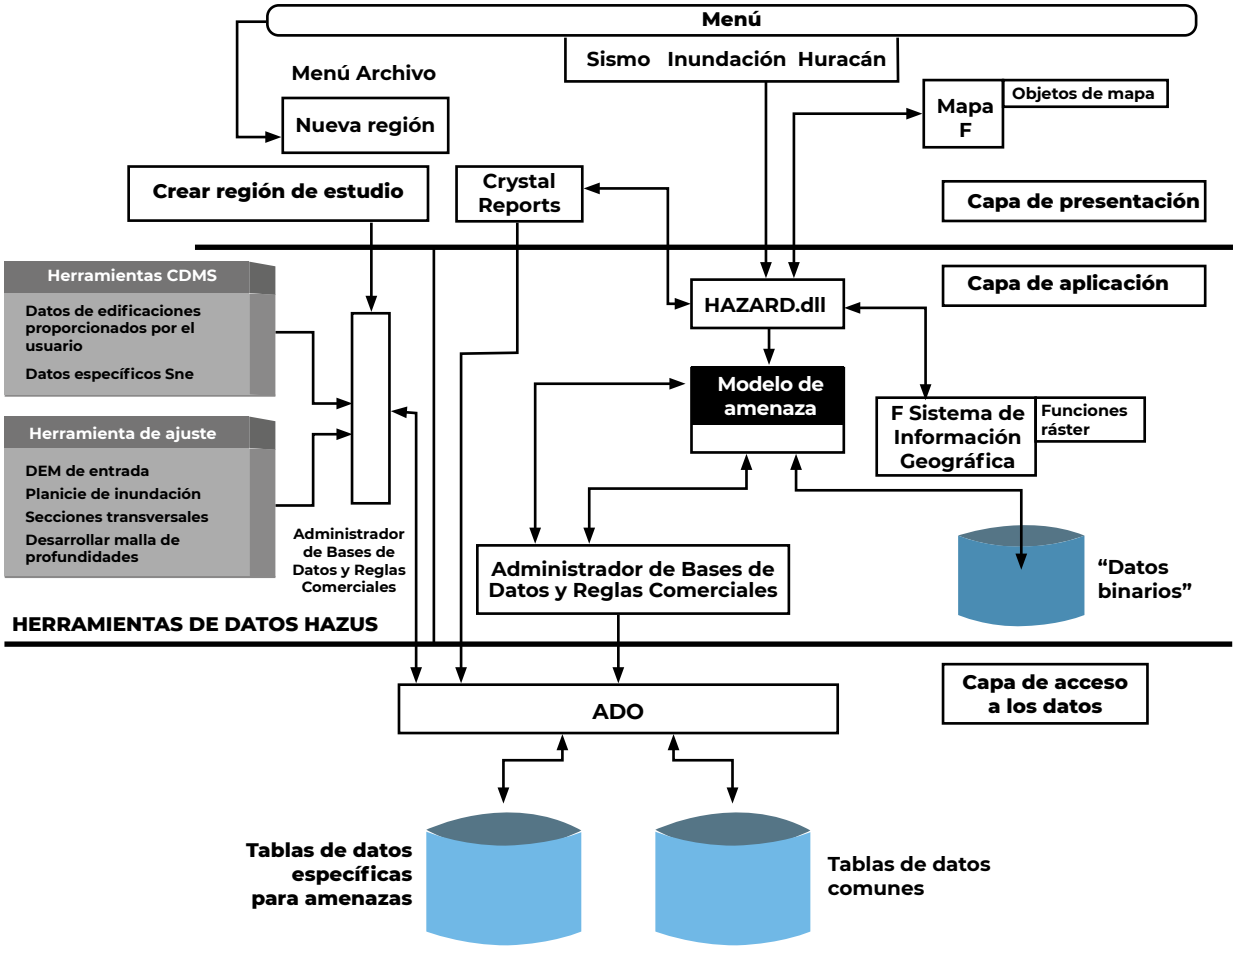
El modelo de inundación comparte una arquitectura de software modular general común con los modelos de sismo y vientos. Las pantallas de la interfaz de usuario varían hasta cierto punto para cada

tipo de amenaza, pero tienen un aspecto común. En la **Figura 32** se proporciona una descripción general de la arquitectura de Hazus y los diversos componentes de amenaza.

Los modelos de amenaza específicos de Hazus se describen a continuación (FEMA 2023):

Sismos: estima daños a estructuras, contenido, inventarios y pérdidas económicas. Evalúa la probabilidad de daño a edificaciones e infraestructura basándose en datos de USGS ShakeMap. El modelo calcula los daños y pérdidas en edificios, instalaciones esenciales, transporte, líneas vitales de servicios públicos y población en función de sismos en tiempo real, escenarios o análisis probabilísticos. Además, aborda los cálculos requeridos para manejo de escombros, seguimiento de incendios, víctimas y albergue. Las pérdidas directas se estiman en función de los daños físicos a las estructuras, los contenidos, el inventario y los interiores de los edificios. El modelo de sismo incluye el Módulo de Construcción de Ingeniería Avanzada para el análisis de construcción individual y grupal (FEMA 2024c).

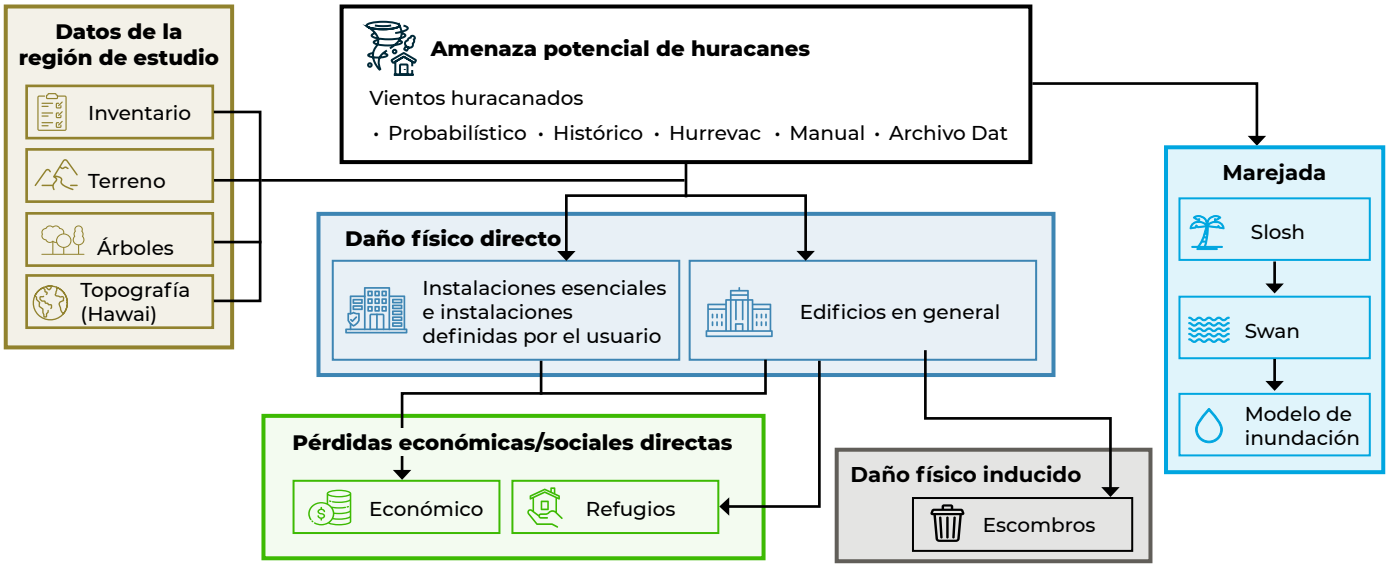
Figura 32. Arquitectura de software Hazus con herramientas de datos Hazus



Huracanes: evalúa daños por vientos huracanados, generación de escombros y pérdidas económicas. Calcula el daño físico y económico a edificaciones debido al viento y los escombros transportados por el viento. Los datos de amenaza de viento se generan a nivel de unidad censal. El modelo considera ráfagas máximas, rugosidad del terreno y datos de cobertura arbórea para tormentas históricas o eventos probabilísticos. Los resultados pueden combinarse con un modelo interno de marejada ciclónica o datos de marejada suministrados por el usuario para estimar el daño a edificaciones causado por inundaciones costeras. Los manuales técnicos y de usuario de Hazus Hurricane Wind proporcionan información sobre los resultados del modelo, las incertidumbres, la ejecución de análisis básicos y avanzados, las funciones de daño, la generación de escombros, los requisitos de refugio, las mareas de tormenta y los impactos. El Manual Técnico también incluye estudios de validación de huracanes históricos (FEMA 2024c).

La metodología Hazus para huracanes, mostrada en la **Figura 33**, permite estimar las consecuencias para una ciudad o región a partir de un escenario de huracanes o de un conjunto de eventos probabilísticos de 100.000 años. La información que puede ser generada incluye: estimaciones cuantitativas de las pérdidas en términos de costos directos de reparación y reemplazo de edificios dañados, pérdida de ingresos comerciales, costos de reubicación, desplazamientos de hogares, requisitos de albergue, cantidad de escombros e impactos económicos regionales, además pérdidas de funcionalidad en términos de pérdida de función y tiempos de restauración para hospitales, comisarías de policía, estaciones de bomberos y centros de operaciones de emergencia (FEMA 2022a).

Figura 33. Metodología del modelo de huracanes Hazus



Fuente: FEMA (2022a).

El modelo probabilístico utiliza un enfoque de simulación del ciclo de vida en el que se modela la trayectoria completa de un huracán o tormenta tropical, comenzando con su inicio sobre el océano y terminando con su disipación final. Usando este enfoque, la presión central se modela en función de la temperatura de la superficie del mar, el rumbo de la tormenta, la velocidad, etcétera, y se actualiza en intervalos de seis horas en el historial de la tormenta. Se utiliza la interpolación lineal entre los puntos de seis horas. El enfoque se valida comparando las estadísticas de los parámetros clave de los huracanes simulados con las estadísticas derivadas de los datos históricos. Este modelo incluye un modelo numérico de campo de viento (Vickery et al. 2009), que incorpora una solución no lineal completa a las ecuaciones de movimiento (FEMA 2022a).

Inundaciones: estima daños a edificios, contenido y pérdidas económicas. Calcula daños físicos y pérdidas económicas debido a inundaciones costeras o fluviales, usando funciones que relacionan la profundidad y tipo de inundación con el grado de daño. Los productos específicos incluyen daños a los contenidos de edificios, líneas vitales y pérdidas económicas. La metodología de estimación de pérdidas por inundaciones consta de dos módulos que llevan a cabo procesos analíticos básicos: 1) el análisis de amenaza de inundación y 2) el análisis de estimación de pérdidas por inundaciones. Los resultados del modelo se pueden visualizar a través de una serie de informes y mapas (FEMA 2024c).

1. El módulo de amenaza de inundación utiliza el caudal y la elevación del terreno entre otros, para estimar la profundidad de la inundación y la velocidad del flujo. Los usuarios también tienen la capacidad de importar directamente mallas de amenaza de inundación definidas por el usuario en múltiples formas.
2. El módulo de estimación de pérdidas por inundaciones calcula el daño físico y la pérdida económica a partir de los resultados del análisis de amenaza mediante el uso de curvas de vulnerabilidad.

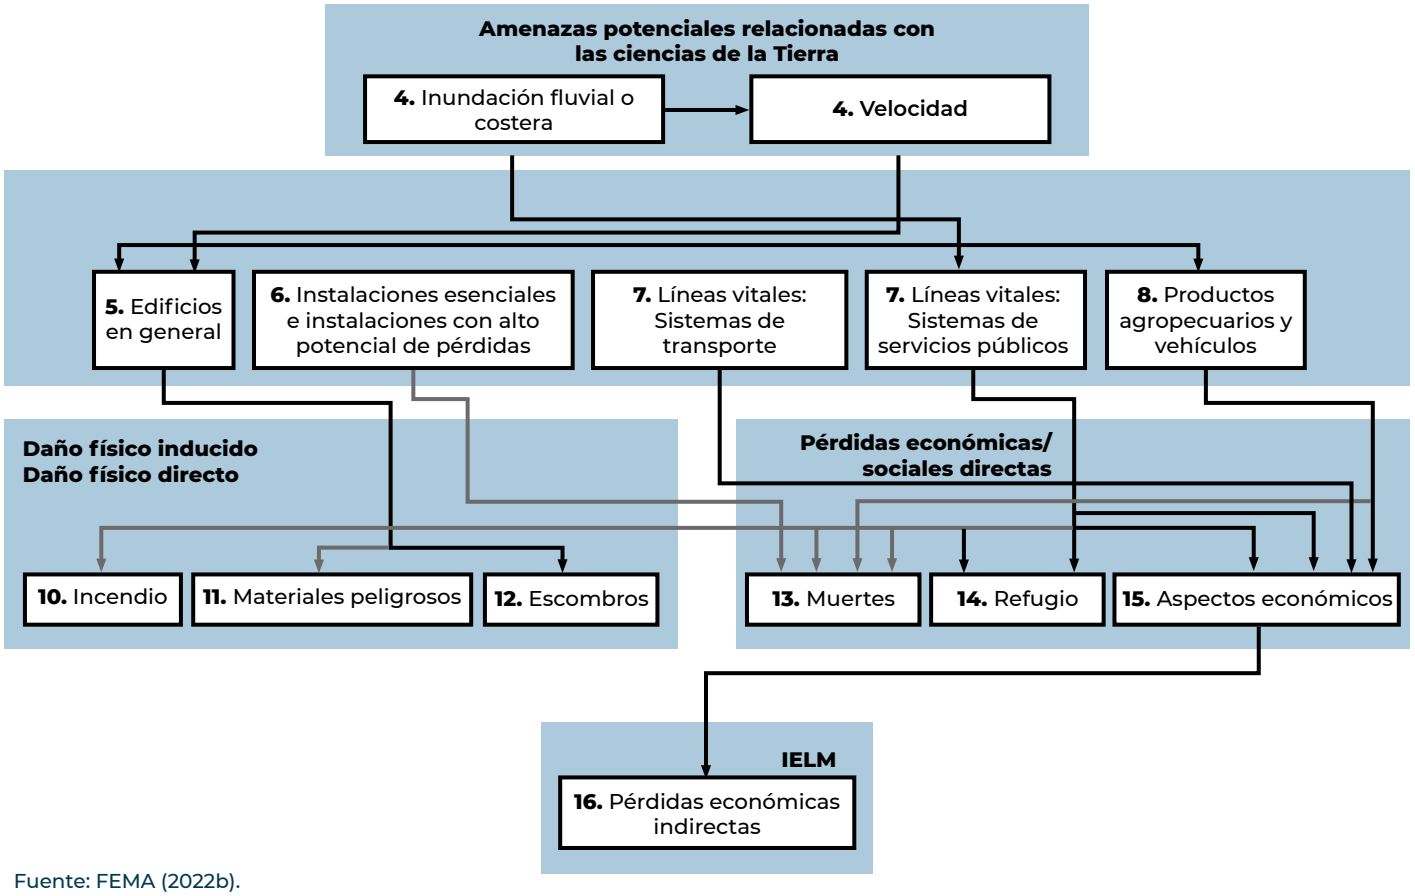
La **Figura 34** muestra el esquema del modelo de inundaciones, en este momento, algunas características del Modelo de Inundación no están disponibles, pero están en desarrollo. En esos casos, los modelos se muestran en cajas grises y las conexiones que conducen a esos componentes también están en gris.

La metodología incorpora la información más reciente disponible en la metodología de estimación de pérdidas por inundación. Por ejemplo, los usuarios pueden desarrollar sus mallas de profundidad en función de sus modelos hidrológicos e hidráulicos y utilizar las funciones de daño más actualizadas. Los módulos incluyen estimadores de pérdidas por daños que no se encontraban anteriormente en la mayoría de los estudios, como las pérdidas económicas indirectas.

Dependiendo de la experiencia del usuario, el modelo de inundación está diseñado para operar con una interfaz de usuario y datos mínimos, o el usuario puede preprocesar datos de mayor calidad y realizar análisis más rigurosos. Por ejemplo, la metodología permite estimaciones simplificadas de daños y pérdidas, utilizando principalmente datos predeterminados suministrados con el software. Estas estimaciones de daños/pérdidas no requieren una amplia recopilación de inventario y se pueden realizar con un presupuesto modesto. Las estimaciones más precisas de daños/pérdidas (análisis de datos suministrados por el usuario) requieren información de inventario más extensa a un costo adicional para el usuario.

En todos los casos los usuarios deberán proporcionar un Modelo Digital de Elevación (DEM). El Modelo de Inundación ha sido diseñado para permitir al usuario definir fácilmente el DEM requerido para su región de estudio y obtener el Conjunto de Datos de Elevación Nacional (NED) del sitio web del USGS. El usuario también puede proporcionar su propio DEM que satisfaga las necesidades del modelo. Una vez que se suministra un DEM, el usuario puede comenzar a desarrollar estimaciones de daños y pérdidas. Un usuario que pueda tener mejores datos del terreno y datos mejorados que definan su amenaza de inundación puede importarlos (FEMA 2022b).

Figura 33. Metodología del modelo de huracanes Hazus



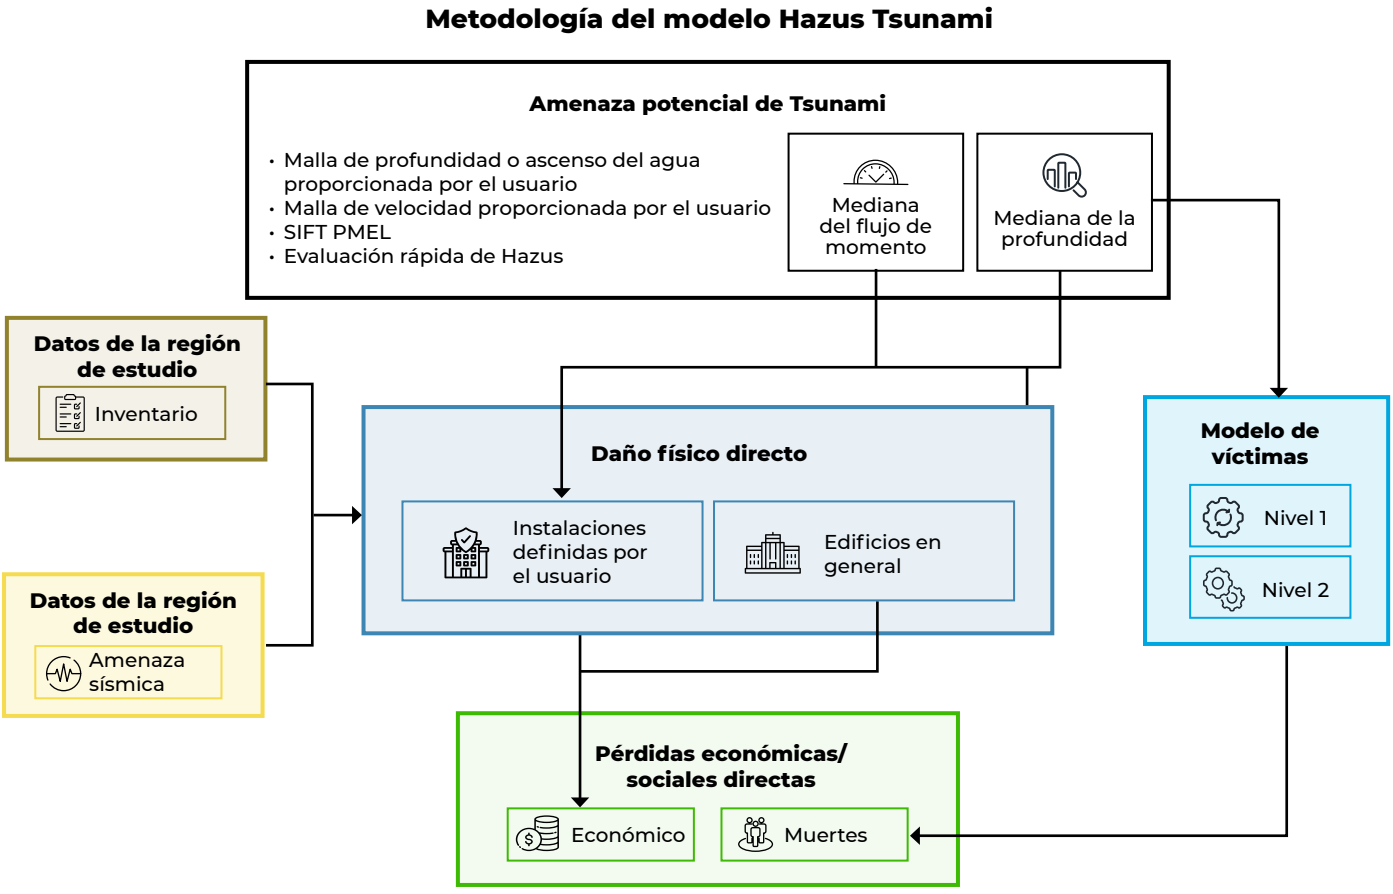
Fuente: FEMA (2022b).

El modelo de inundación incluye un conjunto de funciones de daño con la mayoría de las curvas disponibles de la Administración Federal de Seguros (ahora conocida como la Administración Federal de Seguros y Mitigación dentro del Departamento de Seguridad Nacional) y el Cuerpo de Ingenieros del Ejército de EE. UU. El Inventario General de Edificios (GBS, por sus siglas en inglés) incluye edificios residenciales, comerciales, industriales, agrícolas, religiosos, gubernamentales y educativos. Los daños se estiman en porcentaje y se ponderan por el área de inundación a una profundidad determinada para un bloque censal determinado. Se supone que toda la composición del parque inmobiliario general dentro de una manzana censal determinada se distribuye uniformemente por toda la manzana. La información de inventario necesaria para determinar un porcentaje de daños para el área inundada viene dada por las relaciones entre las clasificaciones de ocupación específicas y los tipos de edificios. Los tres modelos (sismo, viento e inundación) utilizan datos comunes para garantizar que los usuarios no tengan discrepancias en el inventario al cambiar de una amenaza a otra. Por lo general, el modelo de inundación muestra los datos de GBS en el bloque censal, mientras que el modelo de huracanes y terremotos muestra los datos de GBS en el nivel de distrito censal (FEMA 2022b).



Tsunamis: evalúa daños a la infraestructura y pérdidas económicas. Estima la pérdida económica y el daño físico a edificaciones debido a la profundidad y fuerza de las olas de tsunami en cinco estados de alto riesgo (California, Washington, Oregón, Hawái y Alaska), así como en territorios de EE. UU. en el Pacífico y el Caribe. Las estimaciones pueden combinarse con las de pérdidas por sismo para cuantificar impactos adicionales de eventos de tsunami cercanos a la fuente. Las metodologías Hazus generan una estimación de las consecuencias de un escenario de tsunami en una ciudad, condado o región costera. La estimación de pérdidas resultante describirá la magnitud de los daños y perturbaciones que pueden resultar del tsunami modelado. Se puede obtener la siguiente información (ver la **Figura 35**): estimaciones cuantitativas de las pérdidas en términos de costos directos de reparación y reemplazo de edificios dañados, costos directos asociados con la pérdida de función (por ejemplo, pérdida de ingresos comerciales, costos de reubicación) y accidentes, y pérdidas de funcionalidad en términos de pérdida de función y tiempos de restauración de las instalaciones definidas por el usuario proporcionadas por el usuario. La versión actual del modelo Hazus Tsunami no estima lo siguiente: estimaciones de daños, pérdidas y funcionalidad para instalaciones esenciales e infraestructura crítica; requisitos de vivienda; escombros; y pérdidas económicas indirectas (FEMA 2022e).

Figura 35. Esquema de la metodología del modelo de tsunami Hazus



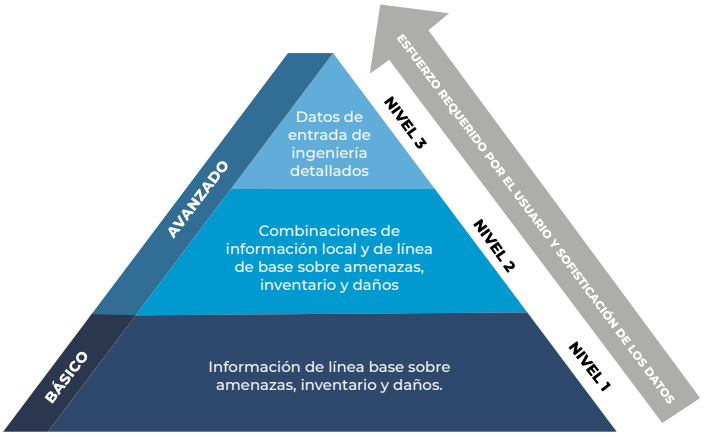
Fuente: FEMA (2022e).

Estos modelos están respaldados por manuales de usuario y técnicos que proporcionan información detallada sobre cómo funcionan los modelos y cómo generar estimaciones de pérdidas.

El desarrollo de cada módulo involucró la participación de un grupo de expertos interdisciplinario. Por ejemplo, el desarrollo de la metodología y la implementación del software de inundaciones ha sido desarrollado por un equipo de expertos en pérdidas por inundaciones compuesto por ingenieros, modeladores hidráulicos e hidrológicos, planificadores de emergencias, economistas, científicos sociales, analistas de sistemas de información geográfica y desarrolladores de software. El Comité de Supervisión de Inundaciones proporcionó dirección técnica y revisión del trabajo.

Los análisis de riesgo de Hazus se dividen en Básicos o Avanzados (ver **Figura 36**), dependiendo del nivel de detalle y esfuerzo requerido. Los análisis avanzados utilizan datos locales más detallados para estimaciones más precisas.

Figura 36. Niveles de análisis de HAZUS



Fuente: FEMA (2023).

Por ejemplo, en el caso de las inundaciones, el modelo de Inundación permite los siguientes tres niveles de análisis:

Nivel 1

Este es el tipo de análisis más simple que requiere un esfuerzo mínimo por parte del usuario, ya que se basa principalmente en la información proporcionada con la metodología (por ejemplo, información del censo, patrones regionales amplios de adopción del código de llanuras aluviales, etc.). No se espera que el usuario tenga amplios conocimientos técnicos. Si bien los métodos requieren alguna entrada proporcionada por el usuario para ejecutarse, el tipo de entrada requerida podría recopilarse poniéndose en contacto con agencias gubernamentales o consultando información publicada. A este nivel, las **estimaciones serán gruesas, y probablemente serán apropiadas sólo como estimaciones iniciales de pérdidas para determinar dónde se justifican análisis más detallados**. Algunos componentes de la metodología no se pueden realizar en un análisis de datos predeterminado, ya que requieren un inventario más detallado que el proporcionado con la metodología. Lo siguiente no se incluye en el análisis de datos predeterminados: daños/pérdidas debido a fallas en el suelo o erosión (ribereñas), daños/pérdidas debido a inundaciones provocadas por sismos como tsunamis, daños/pérdidas debido a fallas en presas. En este nivel, el usuario tiene la opción (no es obligatorio) de introducir información sobre instalaciones específicas del sitio, como sitios de materiales peligrosos o instalaciones esenciales, entre otros. Se necesitaría de una semana a un mes para recopilar información relevante según el tamaño de la región y el nivel de detalle que desee el usuario.

Nivel 2

El análisis de Nivel 2 tiene por objeto mejorar los resultados del Nivel 1 teniendo en cuenta datos adicionales que están fácilmente disponibles o que pueden convertirse o calcularse fácilmente para cumplir con los requisitos metodológicos. En el nivel 2, es posible que el usuario tenga que determinar los parámetros de los informes o mapas publicados como entrada para el modelo. Requiere datos de inventario más extensos y más esfuerzo por parte del usuario que el análisis de datos predeterminado. El propósito de este tipo de análisis es proporcionar al usuario las mejores estimaciones de daños/pérdidas por inundación que se pueden obtener utilizando los métodos estandarizados incluidos en la metodología. Los usuarios del Modelo de Inundación deberán preprocesar sus datos de amenaza de inundación para su uso en el Modelo de Inundación. Es probable que el usuario necesite contratar consultores para ayudar en la implementación de ciertos métodos. Por ejemplo, es probable que se requieran usuarios conocedores de los modelos de hidrología e hidráulica para definir las profundidades de las inundaciones. Todos los componentes de la metodología pueden realizarse a este nivel y las estimaciones de pérdidas se basan en inventarios desarrollados localmente (por el usuario). En este nivel, existen métodos estandarizados de análisis incluidos en el software, pero no existe un estudio estandarizado de análisis de datos suministrados por el usuario. A medida que el usuario proporciona datos más completos, la calidad del análisis y los resultados mejoran. Dependiendo del tamaño de la región y del nivel de detalle deseado por el usuario, se necesitarían de uno a seis meses para obtener la información requerida para este tipo de análisis.

Nivel 3

El análisis de nivel 3 requerirá grandes esfuerzos por parte del usuario para desarrollar información sobre amenaza de inundación y la exposición. Este tipo de análisis incorpora resultados de estudios de ingeniería y económicos realizados utilizando métodos y software no incluidos dentro de la metodología. En este nivel, se necesitarían uno o más expertos técnicos para adquirir datos, realizar análisis detallados, evaluar los daños y pérdidas y ayudar al usuario a reunir un inventario más extenso. En este nivel habrá una amplia participación de las empresas de servicios públicos locales y de los propietarios de instalaciones especiales. La calidad y el detalle de los resultados dependen del nivel de esfuerzo. Se necesitarían de seis meses a dos años para completar un Análisis Avanzado.

Cada nivel subsiguiente se basa en los datos y procedimientos de análisis disponibles en los niveles anteriores y se suma a ellos (FEMA 2022b). La **Tabla 22** muestra el nivel de información y análisis requeridos para cada componente del análisis en el caso de las inundaciones.

Tabla 22. Niveles de análisis ejemplificados para el caso de inundaciones

	Nivel 1	Nivel 2	Nivel 3
Amenaza	Los usuarios suministran el Modelo Digital del Terreno (DEM), normalmente el DEM de 30 metros del USGS. El Modelo de Inundación utiliza los datos de amenaza predeterminados, incluidos los códigos de unidades hidráulicas y la metodología de acumulación para desarrollar líneas centrales aproximadas de las corrientes. Se utilizan ecuaciones de regresión del USGS y registros de medición para determinar las curvas de frecuencia de caudal.	Datos de amenaza suministrados por el usuario preprocesados. El usuario proporcionará resultados mejorados de DEM, hidráulica e hidrología de inundación, incluidas las secciones transversales de las corrientes. Los usuarios del análisis costero suministran polígonos con las elevaciones y los límites del área de análisis.	Similar al Nivel 2, aunque es probable que el usuario trabaje con modelos hidráulicos fuera del Modelo de Inundación y el FIT.
Inventario	Presente en la metodología de datos predeterminada de Hazus, mejorada para las necesidades de inundación. Asignación de datos de bloques censales a través de análisis estadísticos y supuestos generales para la elevación del primer piso. Uso general de la tierra, Líneas vitales, Agricultura, Inventario de vehículos, Instalaciones esenciales.	El usuario proporciona datos de inventario procesados a través de CDMS. Los usuarios mejoran la información de elevación del primer piso y otros atributos necesarios para la estimación de pérdidas por inundación.	Datos de alta calidad sobre el valor de los edificios, las vulnerabilidades a las inundaciones, los contenidos, las ocupaciones, etc., extendidos a las instalaciones industriales y otras instalaciones de alto valor.
Curvas de daño	Curvas regionales consistentes con el nivel de detalle del inventario, basadas en las curvas de daños por profundidad disponibles de la FIA o el USACE. Biblioteca de curvas disponibles para la selección del usuario. El usuario puede crear sus propias curvas de daño utilizando guías internas.	El usuario proporciona sus propias funciones o modifica específicamente la biblioteca de curvas existente para las prácticas locales.	Curvas de entrada del usuario basadas en estudios detallados del edificio, condiciones específicas del cultivo, etc.
Estimación de daño	Estimaciones de daños basadas en la profundidad de la inundación dentro de un bloque censal determinado. Pérdidas desarrolladas para el material de construcción general, vehículos, productos agrícolas, transporte selecto y características de servicios públicos.	De acuerdo con el Nivel 1, la estimación se mejora a través de datos de amenaza de mayor resolución y precisión y el detalle de los datos de inventario y la modificación de las curvas de daño	De acuerdo con el Nivel 1, la estimación se mejora a través de datos de amenaza de mayor resolución y precisión y el detalle de los datos de inventario y la modificación de las curvas de daño.
Pérdidas/ Impactos Directos	Costo de reparación / reemplazo, víctimas humanas y necesidades de refugio, vivienda temporal, vehículos, pérdidas de cultivos y ganado.	De acuerdo con el Nivel 1, la estimación se mejora a través de datos de amenaza y el detalle de los datos de inventario y la modificación de las curvas de daño.	De acuerdo con el Nivel 1, la estimación se mejora a través de datos de amenaza y el detalle de los datos de inventario y la modificación de las curvas de daño.
Pérdidas/ Impactos Indirectos	Impactos económicos sectoriales.	Impactos económicos sectoriales.	Impactos económicos sectoriales.
Aplicaciones típicas	Mitigación de inundaciones / formulación de políticas regulatorias, a nivel regional, estatal y federal · Estudios de prefactibilidad · Respuesta de emergencia en tiempo real sin previo aviso	Planificación y zonificación · Selección de alternativas de mitigación · Estudios de prefactibilidad de ingeniería · Planificación de emergencias y respuesta en tiempo real · Análisis de impacto ambiental · Educación	· Análisis de instalaciones esenciales, culturales y de alto potencial de pérdida · Planificación de emergencias y respuesta en tiempo real · Investigación en mitigación e ingeniería · Investigación científica

Fuente: FEMA (2022b).

A.2.3. Enfoque matemático

El modelo de inundación de Hazus hasta la versión 6.1 requería de los daños por inundación del conjunto de períodos de retorno: 10 años, 25 años, 50 años, 100 años y 500 años para el cálculo del daño anual esperado (EAD por sus siglas en inglés). El modelo de inundación de Hazus 6.1 calcula los daños por bloque censal (y por ocupación) para el conjunto de períodos de retorno. El EAD en esta versión del software se aproxima mediante la **Ecuación 7** (FEMA 2022b).

Ecuación 7

$$AAL = (f_{10} - f_{25})\frac{(L_{10} - L_{25})}{2} + (f_{25} - f_{50})\frac{(L_{25} - L_{50})}{2} + (f_{50} - f_{100})\frac{(L_{50} - L_{100})}{2} + (f_{100} - f_{500})\frac{(L_{100} - L_{500})}{2} + (f_{500} - f_{500})$$

Donde L_{xxx} corresponde al daño o a la pérdida para el periodo de retorno xxx y f_{xxx} a la probabilidad de excedencia para el periodo de retorno xxx. Esta ecuación puede ser simplificada como se muestra en la Ecuación 8 (FEMA 2022b).

Ecuación 8

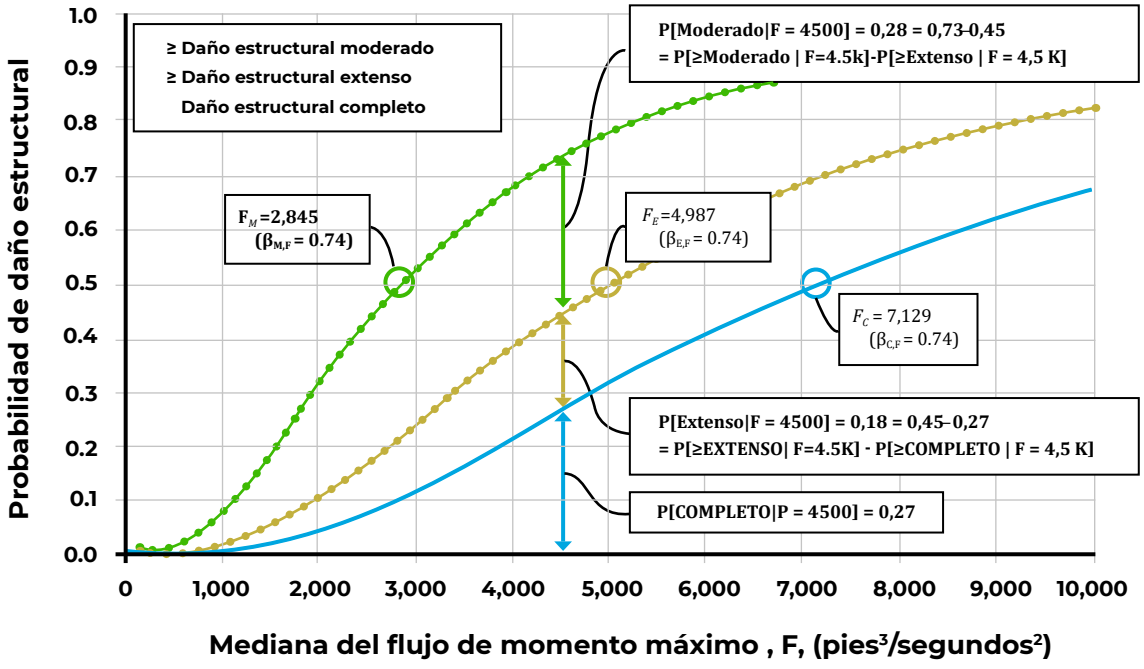
$$AAL = 0.030L_{10} + 0.04L_{25} + 0.015L_{50} + 0.009L_{100} + 0.006L_{500}$$

Para la versión de Hazus 7.0 cualquiera de 3 o más periodos de retorno pueden ser utilizados para los cálculos (FEMA 2024d).

En Hazus tsunami y sismo, los datos de salida desarrollados por el módulo de daños en edificios son estimaciones de la probabilidad acumulada de estar en, o superar, cada estado de daño para el parámetro de amenaza (o parámetros, si se combinan) de interés. Las probabilidades de estado de daño discreto se crean a partir de las probabilidades de daño acumuladas. Estas salidas se utilizan directamente como entradas para los módulos de pérdidas económicas y sociales directas (FEMA 2022e).

Las funciones de daño por tsunami de los edificios se presentan en forma de curvas de fragilidad lognormal que relacionan la probabilidad de estar en, o superar, un estado discreto de daño dada la estimación mediana del parámetro de amenaza de interés (es decir, la altura máxima de inundación mediana o el flujo de momento máximo medio). La **Figura 37** ilustra las curvas de fragilidad que describen el daño estructural Moderado, Extenso y Completo debido al flujo del tsunami (es decir, el flujo medio del momento máximo, F) (FEMA 2022e).

Figura 37. Ejemplo de curva de fragilidad para tsunami



Fuente: FEMA (2022b).

Conceptualmente, la forma de las funciones de daño causados por el tsunami a los edificios es la misma que la de la curva lognormal de fragilidad utilizado por el modelo de sismos. Cada curva de estado de daño está definida por el valor mediano y la variabilidad asociada del parámetro de fragilidad de interés. La variabilidad de estas curvas de fragilidad tiene dos componentes fundamentales: la variabilidad de la mediana de la estimación del parámetro de amenaza (es decir, la incertidumbre en la demanda) y la variabilidad del valor mediano del estado de daño (es decir, la incertidumbre en la capacidad) para la amenaza de interés (FEMA 2022e).

El daño se clasifica en tres estados principales: moderado, extenso y completo. Tanto en el modelo de tsunami como en el de sismo, estos términos se utilizan para describir el alcance y la gravedad de los daños. En el caso de los sismos, también se considera un estado adicional de daño leve, mientras que para los tsunamis no se incluye esta categoría, ya que resulta difícil diferenciarlo de la ausencia de daño. Aunque la causa y manifestación del daño varían entre tsunamis y sismos, se asume que los estados de daño son equivalentes cuando representan un nivel similar de afectación y gravedad (FEMA 2022d).

Los daños estructurales, se calculan mediante la **Ecuación 9** y **Ecuación 10**.

Ecuación 9

$$CS_{ds,i} = BRC_i \sum_{i=1}^{33} PSBTSTR_{ds,i} \times RCS_{ds,i}$$

Ecuación 10

$$CS_i = \sum_{ds=2}^{5} CS_{ds,i}$$

Donde:

$CS_{ds,i}$ es el costo de daño estructural (costos de reparación y reemplazo) para el estado de daño ds y la ocupación i. Los datos sobre el costo de reemplazo de edificios para cada una de las 33 clases de ocupación se pueden encontrar en el Manual Técnico de Inventario de Hazus.

BRC_i es el costo de reemplazo del edificio para la ocupación i.

$PSBTSTR_{ds,i}$ es la probabilidad de que la ocupación se encuentre en el estado de daño estructural ds.

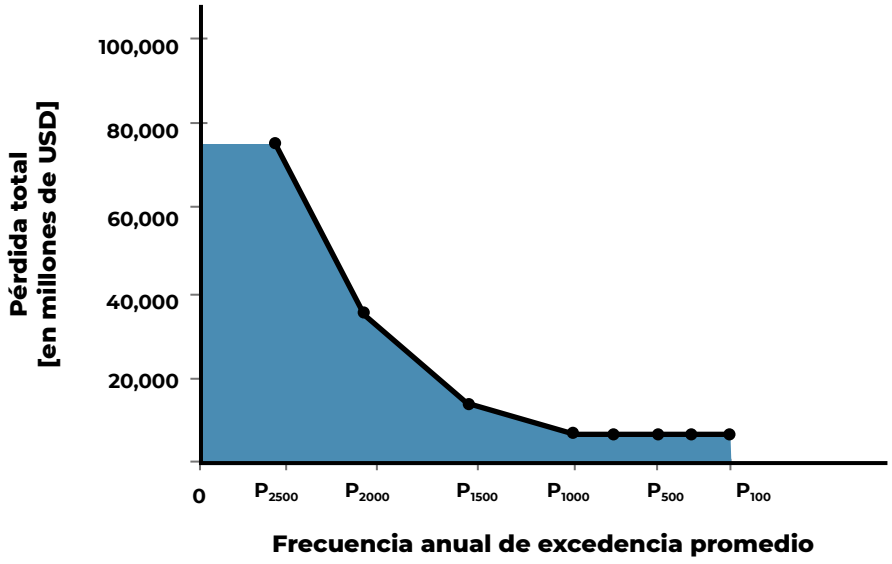
$RCS_{ds,i}$ es la proporción de reparación y reemplazo estructural para la ocupación i en el estado de daño ds.

Hazus Tsunami también calcula daños en contenidos, los tiempos de restauración y la funcionalidad de los edificios para las instalaciones individuales definidas por el usuario, gastos de relocalización, y pérdida de ingresos y renta. Las funciones de restauración, su metodología asociada y la funcionalidad derivada están disponibles en el Manual Técnico del Modelo de Sismo de Hazus (FEMA 2022), según el tipo de instalación. En el modelo de tsunami, se implementó una tabla de búsqueda en la base de datos de parámetros de análisis para que los usuarios no tengan que localizar y utilizar las funciones de restauración como si debe hacerse en el modelo de sismo (FEMA 2022e).

En el caso de sismos la metodología Hazus considera intensidades para ocho niveles de amenaza con una probabilidad asociada: que van desde el sismo con una probabilidad del 39% de ser superado en 50 años (período de retorno de 100 años) hasta sismo con una probabilidad del 2% de ser superado en 50 años (período de retorno de 2500 años). Una vez procesados los datos de amenaza, se utiliza un módulo de análisis interno en Hazus para transformar las pérdidas de los ocho escenarios en una pérdida sísmica anualizada (AEL). La **Figura 38** ilustra un ejemplo de una curva de riesgo utilizando el método de Hazus con ocho valores de daño asociadas a probabilidades de excedencia. Hazus calcula la AEL estimando el área sombreada bajo la curva de probabilidad de pérdida que se muestra en la **Figura 38**. Esta área representa una aproximación al EAD y equivale a tomar la suma de las pérdidas multiplicada

por su probabilidad anual de ocurrencia. El criterio utilizado por Hazus para seleccionar el número de puntos de la curva de riesgo fue la eficiencia computacional frente a la precisión marginal mejorada. Para determinar el número adecuado de períodos de retorno, se realizó un estudio de sensibilidad que comparó la estabilidad de los resultados del AEL con el número de períodos de retorno para 10 regiones de Estados Unidos utilizando 5, 8, 12, 15 y 20 períodos de retorno. La diferencia en los resultados de la AEL utilizando 8, 12, 15 y 20 períodos de retorno fue insignificante (FEMA 2022f).

Figura 38. Curva de daño y área bajo la curva como ha sido conceptualizada por Hazus para el cálculo de riesgo sísmico

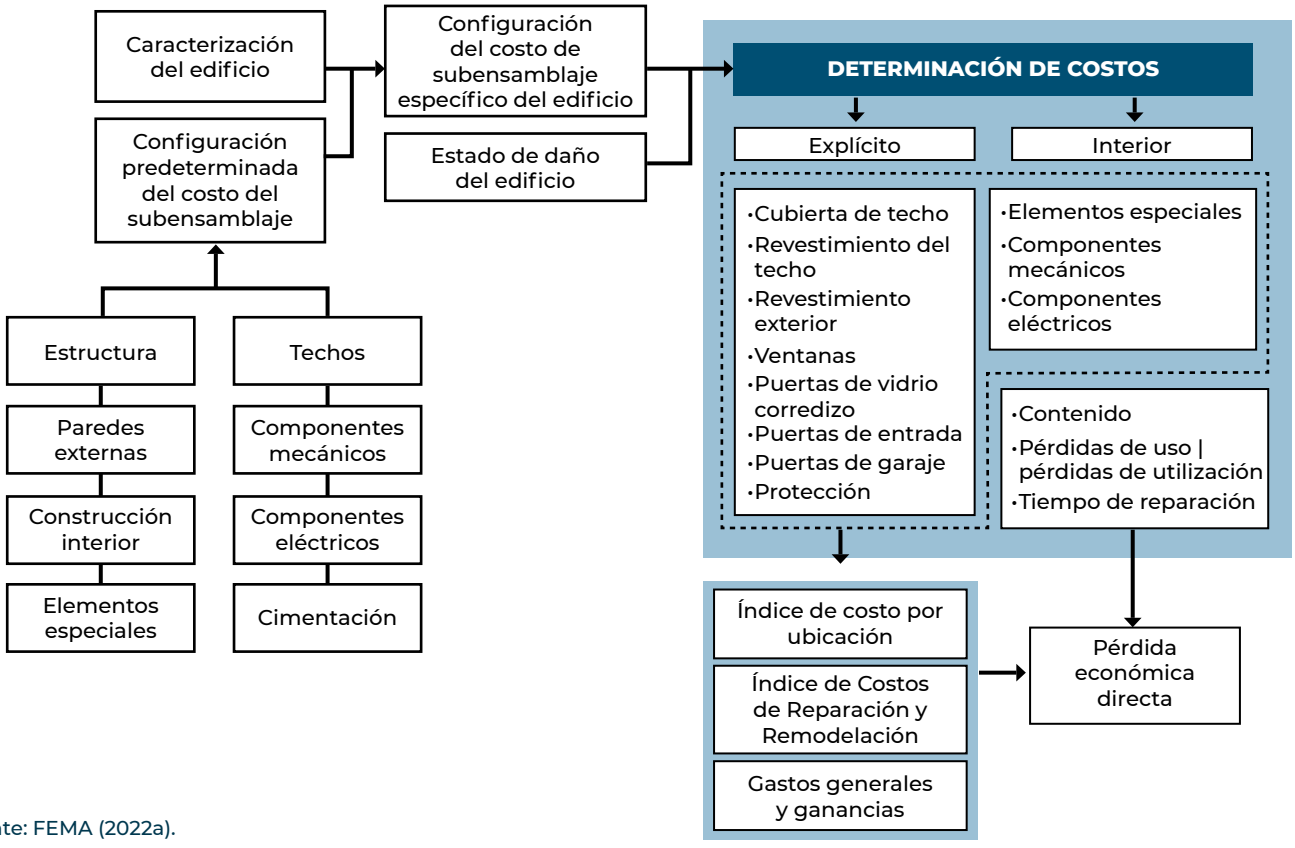


Fuente: FEMA (2022e).

El modelo de huracanes de Hazus utiliza un enfoque completamente probabilista para obtener los resultados de riesgo. La metodología Hazus estima las consecuencias de un huracán en una ciudad o región mediante un conjunto probabilístico de eventos, cuya extensión varía según la geografía. El modelo de simulación de la trayectoria de la tormenta se inicia muestreando aleatoriamente una posición inicial, fecha, hora, dirección y velocidad de traslación de una de las tormentas tropicales dadas en la base de datos HURDAT. El número de tormentas que se simularán en cualquier año se obtiene muestreando de una distribución binomial negativa con un valor medio de 8.4 tormentas por año y una desviación estándar de 3.56 tormentas por año. El enfoque de modelado permite que las tormentas se curven, cambien de velocidad y se intensifiquen a medida que se desplazan, reproduciendo las estadísticas continuamente variables asociadas con la presión central, la dirección, etc., a lo largo de la costa de los EE. UU (FEMA 2022a).

El modelo de pérdidas es un modelo físico que calcula las pérdidas económicas directas utilizando una combinación de técnicas de costos explícitas e implícitas (ver **Figura 39**). El modelo de pérdidas subdivide los edificios en subconjuntos de costos. Este enfoque proporciona una flexibilidad significativa en los costos y la capacidad de procesar una amplia gama de tipos de edificios. El modelo de pérdidas está diseñado para procesar estados de daño detallados de la envolvente del edificio y proporciona la capacidad adicional de estimar las pérdidas económicas en el interior del edificio y el contenido, considerando directamente el volumen de agua que penetra a través de las fenestraciones falladas (ventanas, puertas, puertas de garaje, etc.). El enfoque de modelado también es adecuado para estimar la pérdida de uso y el tiempo de reparación (FEMA 2022a).

Figura 39. Representación esquemática del modelo de pérdidas



Fuente: FEMA (2022a).

El modelo de viento sigue un enfoque probabilista basado en la metodología de amenaza-carga-resistencia-daño-pérdida, desarrollada desde un marco de riesgo individual. El desempeño de los edificios frente a vientos extremos se formula probabilísticamente mediante conceptos de fiabilidad estructural. Se estima la probabilidad de falla de elementos individuales (como ventanas o puertas) comparando la carga del viento con la resistencia del elemento. A través de simulaciones en distintos tipos de edificios, se calculan las probabilidades de daño y se establecen relaciones entre la intensidad del viento y el daño físico (FEMA).

La pérdida anual promedio por huracanes considera todas las pérdidas futuras causadas por la amenaza de huracán que resulten de posibles eventos de amenaza con diferentes magnitudes y períodos de retorno promediados por año. Se puede utilizar para ayudar a examinar los beneficios de la mitigación y comparar los riesgos económicos de diferentes amenazas en un mismo lugar. Hazus se puede utilizar para generar la pérdida anual promedio sumando todas las pérdidas producidas durante la simulación de huracanes de 20,000 años y dividiendo por 20,000 años (FEMA 2022a).

A.2.4. Avances recientes e innovaciones

HAZUS ha incorporado mejoras continuas para integrar los últimos enfoques científicos y tecnológicos. Las actualizaciones recientes incluyen la versión **Hazus 7.0,** que introduce importantes innovaciones al integrar capacidades avanzadas de ArcGIS Pro, mejorando la interfaz y herramientas de análisis SIG. Sus principales avances incluyen flujos de trabajo simplificados para inundaciones y huracanes, metodologías mejoradas para zonas de inundación costeras, y un cálculo más flexible de pérdida anual promedio (AAL) que permite usar múltiples mallas de profundidad para análisis de inundaciones. Además, Hazus 7.0 simplifica el acceso a datos al eliminar la configuración manual de bases de datos, consolidando la información en un archivo accesible para todos los territorios de EE. UU.

A.2.5. Comunidad de desarrollo

El programa Hazus es administrado por el Programa de Evaluación de Riesgos de Amenazas Naturales de FEMA y colabora con otras agencias federales, instituciones de investigación y autoridades de planificación regional. Esta colaboración asegura que los recursos de Hazus incorporen los últimos avances científicos y tecnológicos y satisfagan las necesidades de la comunidad de gestión de riesgos (FEMA 2023).

A.2.6. Limitaciones

Aunque es una herramienta poderosa, su base de datos y modelos están principalmente adaptados para el contexto estadounidense, aunque puede utilizarse en otras áreas geográficas con las adaptaciones necesarias.

A.2.7. Casos de uso

Aunque Hazus es usado primordialmente en EEUU, existen adaptaciones y casos de uso en otros países. Kulmesch et al. (2010) utilizaron Hazus para analizar el riesgo por inundación en una región de Austria, Rozelle (2007) utilizó y compararó los resultados del modelo de sismo de Hazus en Nepal. También existen casos de aplicación en Latinoamérica como el desarrollado por Chantavilasvong y Guerrero (2019) que se presenta en la **Caja 3**.

Caja 3. Ejemplo de aplicación de Hazus

Estudio de Caso de Hazus en Piura (Perú)



Imagen: Adobe Stock

En el norte de Perú, en la región de Piura, la temporada de lluvias se extiende de diciembre a marzo, y en años de El Niño puede prolongarse hasta abril. En 2017, un año marcado por un fuerte fenómeno de El Niño, las precipitaciones fueron diez veces mayores a lo normal, generando pérdidas económicas estimadas en $3.1 mil millones de dólares a nivel nacional. En Piura, la región más afectada, se registraron cuatro muertes, cientos de familias desplazadas y la pérdida de unas 15,000 hectáreas de cultivos bajo el agua.

El estudio utiliza una adaptación del modelo HAZUS-MH de la Agencia Federal para el Manejo de Emergencias de EE. UU. (FEMA). La metodología propuesta aborda las limitaciones de datos y capacidad técnica en Piura mediante un enfoque accesible y replicable que incluye: (i) un análisis sencillo y accesible que utiliza QGIS para el análisis espacial; (ii) mapas de distribución espacial que identifican áreas con riesgos de inundación; (iii) valorización monetaria de los costos potenciales de daños en edificios; (iv) análisis espacial de riesgo de inundación; (v) delimitación de Áreas de Inundación.

El modelo adaptado utiliza herramientas de código abierto como QGIS para realizar un análisis espacial de riesgo de inundación. Los datos base incluyen el Modelo Digital de Elevación (DEM) SRTM3 de la NASA y curvas globales de daños por profundidad de inundación (Huizinga et al. 2017). Los pasos metodológicos principales incluyen:

- **Delimitación de áreas de inundación:** Identificación de zonas propensas a inundaciones a partir de altitudes relativas a los niveles estimados del río.
- **Evaluación de exposición:** Superposición de mapas de inundación con datos de edificaciones, clasificadas según materiales de construcción (madera y concreto).

Cálculo de daños estructurales: Estimación de edificios colapsados y dañados utilizando curvas de daño por profundidad de inundación.

Valorización monetaria: Cuantificación de costos de reconstrucción y reparación, proporcionando estimaciones económicas de los impactos potenciales.

Los mapas producidos muestran que muchas áreas inundables han sido desarrolladas como zonas residenciales o comerciales, exponiendo a sus habitantes a inundaciones fluviales. En el escenario de mayor riesgo, se estima que aproximadamente 6,274,439 m² de edificios serán afectados, con un costo potencial de $4.2 mil millones de dólares para toda la región de Piura. Este monto incluye 5,821,163 m² de edificios dañados y 453,276 m² de edificios colapsados, afectando principalmente a viviendas de población de bajos ingresos construidas con materiales como quincha o madera.

El modelo HAZUS-MH adaptado a la región de Piura demuestra ser una herramienta útil para estimar riesgos de inundación y cuantificar impactos económicos. Sin embargo, el éxito de su implementación depende de: (i) mejorar la disponibilidad y calidad de datos locales; (ii) capacitar a las autoridades locales en análisis de riesgos y planificación de mitigación; (iii) promover un enfoque participativo que empodere a los actores locales para gestionar sus propios riesgos climáticos. La metodología adaptada del modelo HAZUS-MH representa un primer paso importante para estimar riesgos de inundación de manera accesible y efectiva en Piura. Aunque existen brechas de datos y limitaciones, la simplicidad y replicabilidad del enfoque lo convierten en una herramienta valiosa para empoderar a las autoridades locales y fomentar planes de mitigación de riesgos más robustos.

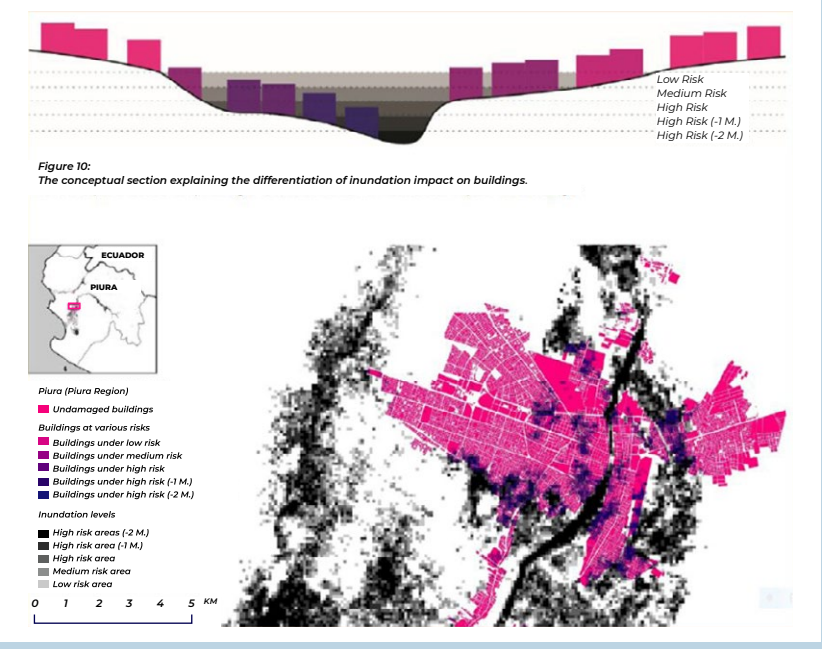


Figure 10:
The conceptual section explaining the differentiation of inundation impact on buildings.

Fuente: Chantavilasvong & Guerrero (2019).

A.3. RISKSCAPE: HERRAMIENTA DE EVALUACIÓN DE RIESGO

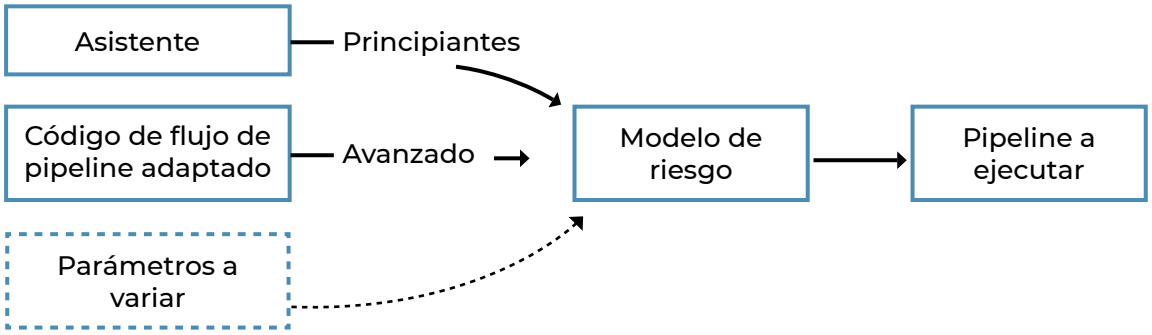
A.3.1. Descripción general

RiskScape es una aplicación de procesamiento de datos espaciales de código abierto diseñada para el análisis de riesgos multiamenaza, desarrollada conjuntamente por GNS Science y el Instituto Nacional de Agua e Investigación Atmosférica (NIWA) de Nueva Zelanda. Altamente personalizable, RiskScape permite a los modeladores adaptar el análisis de riesgos a las necesidades específicas del dominio y los datos de entrada que se están modelando. La herramienta puede integrar datos de diversas fuentes y formatos, aplicando una variedad de operaciones geoespaciales, estadísticas y de manipulación de datos. Esto facilita la modelización de una amplia gama de flujos de trabajo de manera coherente, simplificando las complejidades inherentes al manejo de datos geoespaciales. Además, RiskScape permite la ejecución de modelos deterministas simples en una laptop hasta la ejecución de modelos probabilísticos intensivos en computación en una instancia de computación en la nube de alto rendimiento (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024a).

A.3.2. Métodos aplicados

RiskScape ofrece un asistente que guía a los usuarios en la creación inicial de un modelo de riesgo simple mediante una serie de preguntas relacionadas con sus datos de entrada y el tipo de modelado que desean realizar. RiskScape utiliza su propio lenguaje de scripting para describir el flujo de procesamiento del modelo, conocido como “pipeline”. Este pipeline define una serie de pasos de procesamiento de datos, escritos como expresiones simples similares a fórmulas de hojas de cálculo o declaraciones básicas de Python. RiskScape toma las respuestas del asistente y las convierte en código de pipeline que puede ejecutar (ver **Figura 40**).

Figura 40. Generación del pipeline



Fuente: National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd (2024d).

A medida que los modeladores se vuelven usuarios más avanzados de RiskScape, pueden personalizar completamente su flujo de trabajo de modelado definiéndolo directamente en el código del pipeline, utilizando como punto de partida el código generado por el asistente. Actualmente, RiskScape es una herramienta de línea de comandos (CLI), por lo que los usuarios ejecutan sus modelos desde la línea de comandos. Ejecutar un modelo significa que RiskScape procesa los datos de entrada según las instrucciones del pipeline y guarda los resultados en un archivo.

Un modelo puede ejecutarse variando los archivos de datos de entrada u otras suposiciones. Los detalles de los modelos y pipelines se almacenan en archivos de texto (por ejemplo, archivos INI) que indican a RiskScape exactamente qué hacer. Esta colección de archivos se denomina proyecto. Un proyecto define los flujos de trabajo del modelo de principio a fin, incluyendo qué archivos de datos de entrada y funciones de vulnerabilidad se deben utilizar. Los proyectos organizan los modelos de RiskScape de manera que los modelos relacionados, que involucran amenazas similares o afectan a las mismas características de interés, se agrupan de manera coherente.

Un proyecto contiene el conjunto completo de instrucciones necesarias para ejecutar uno o más modelos de RiskScape, incluyendo:

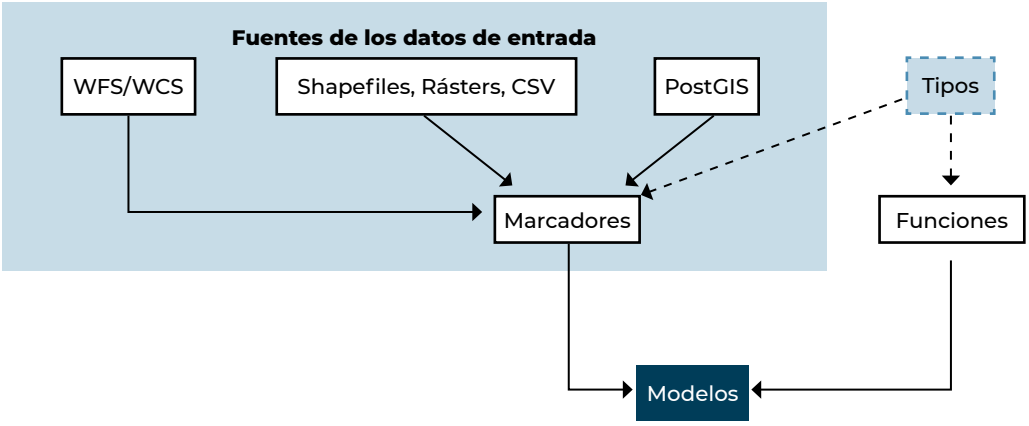
- **Fuentes de datos de entrada:** Datos de varias fuentes en formato de GIS, que se pueden usar sin necesidad de importación o preprocesamiento. Las ubicaciones de los diversos archivos de entrada y cualquier instrucción adicional sobre cómo cargar los datos se especifican en un marcador de RiskScape.

- **Funciones:** Los usuarios pueden escribir sus propias funciones en Python para evaluar el impacto de una amenaza en un elemento en riesgo, como estimar daños, calcular costos o muestrear una curva probabilística. Los usuarios avanzados también pueden usar funciones para manipular o transformar los datos en cualquier punto del pipeline.

- **Tipos:** RiskScape utiliza un sistema de tipos para representar la estructura de los datos a medida que fluyen a través del modelo. Los tipos definen cómo se pueden manipular los datos de entrada, y las funciones que se pueden usar. Los tipos compuestos pueden representar un conjunto de atributos, como un activo de construcción o la consecuencia (pérdidas, daños, etc.) de la amenaza.

- **Modelos**: El modelo es la combinación de datos de entrada, funciones y otros parámetros que se aplican a un pipeline de procesamiento de datos para producir resultados (ver **Figura 41**). Los modelos pueden definirse a partir de respuestas guardadas del asistente o directamente en el código del pipeline.

Figura 41. Componentes de los proyectos

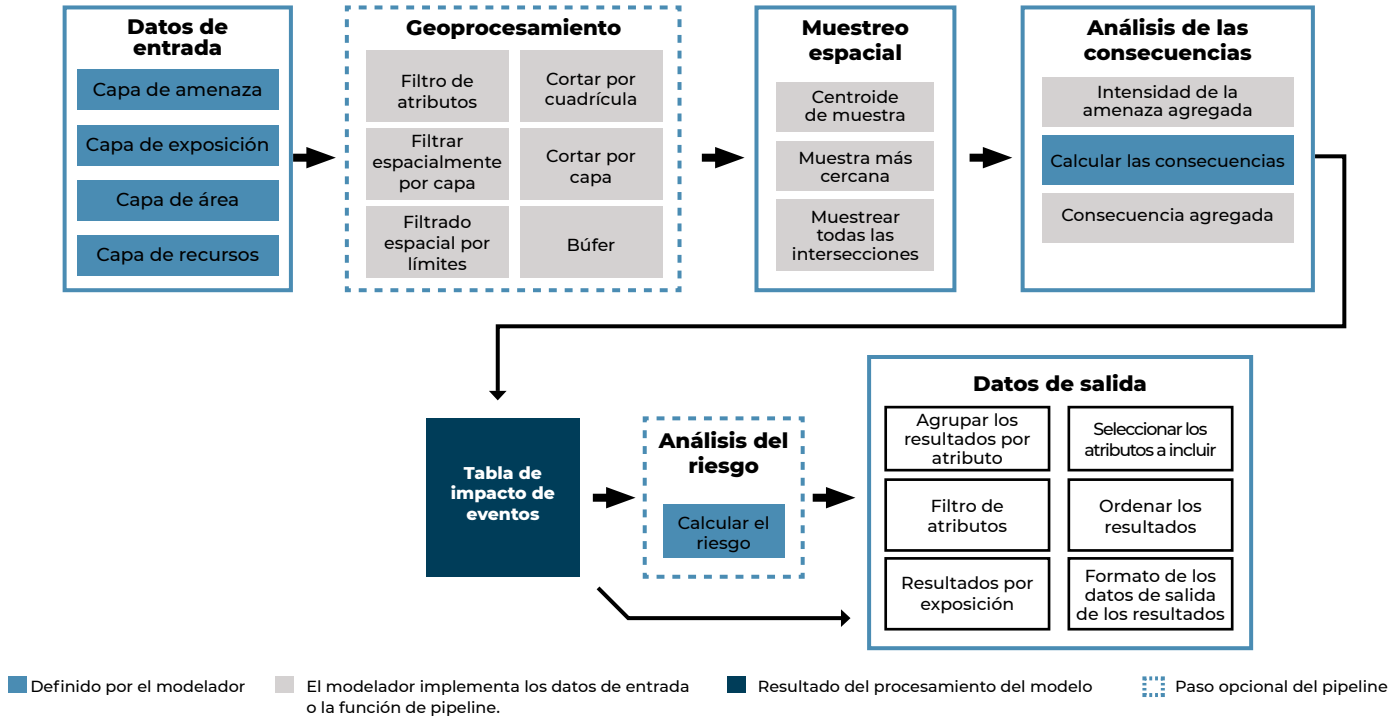


Fuente: National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd(2024d).

Los modelos de RiskScape son flujos de trabajo personalizados y predefinidos (ver **Figura 42**) que procesan datos geoespaciales para realizar análisis de riesgo. Al ejecutar un modelo, se analiza el riesgo de los datos proporcionados. El flujo de trabajo de un modelo incluye varias fases clave: la carga de datos de entrada, geoprocesamiento, muestreo espacial, análisis de consecuencias, análisis de riesgos y la generación de informes. Los datos de entrada incluyen capas de exposición, que contienen los elementos en riesgo, y capas de amenaza. Opcionalmente, se pueden agregar capas adicionales para mejorar los resultados del modelo (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024d).

El geoprocesamiento transforma los datos geométricos antes de cualquier análisis de riesgo. Posteriormente, el muestreo espacial combina geoespacialmente los datos de entrada para determinar la intensidad de la amenaza para cada elemento en riesgo. El análisis de consecuencias calcula el impacto de la amenaza en cada elemento en riesgo, produciendo una tabla de impacto del evento que resume los resultados. Los usuarios avanzados pueden realizar cálculos de riesgo adicionales, como la probabilidad anual esperada, en la fase de análisis de riesgos. Finalmente, los resultados se filtran y agregan para generar informes personalizados, lo que permite que un solo modelo produzca múltiples archivos de salida (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024d).

Figura 42. Flujo de trabajo



Fuente: National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd (2024d).

Las funciones de daño en RiskScape permiten analizar el impacto de una amenaza, más allá de simplemente determinar si un edificio está expuesto o no. El usuario puede definir su propia función en Python para realizar cualquier tipo de análisis de riesgo que desee. RiskScape utiliza una Función de Distribución Acumulada (CDF) log-normal para calcular la probabilidad condicional (entre 0 y 1) de que un edificio se encuentre en un determinado estado de daño como resultado de estar expuesto a una amenaza, por ejemplo, inundación. Los cinco estados de daño utilizados en el modelo son los siguientes (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024e):

- **Leve:** Daño no estructural.
- **Menor:** Daño no estructural significativo y daño estructural menor.
- **Moderado:** Daño estructural y no estructural significativo.
- **Grave:** Daño estructural irreparable que requiere demolición.
- **Colapso:** Colapso estructural completo.

La fragilidad del edificio (es decir, la forma de la curva CDF log-normal) varía según el material de construcción del edificio. El modelo de daño asigna un estado de daño general a cada edificio basándose en las probabilidades calculadas, utilizando una elección aleatoria ponderada para determinar el nivel de daño final (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024e).

RiskScape ofrece una gran variedad de formatos de entrada y salida como se muestra en la **Tabla 23** (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024d).

Tabla 23. Formatos de datos aceptados por RiskScape

Formato	Extensión de archivo	Soporte
arcgrid	asc	datos de entrada
csv	csv	datos de entrada y salida
geojson	geojson, json	datos de entrada y salida
geopackage	gpkg	datos de entrada y salida
geotiff	tif, tiff	datos de entrada
kml	kml	datos de entrada y salida
postgis		datos de entrada
shapefile	shp	datos de entrada y salida
wfs		datos de entrada
NetCDF		datos de entrada
hdf5		datos de entrada

Fuente: National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd (2024d)

A.3.3. Enfoque matemático

En el marco conceptual de RiskScape, se utilizan los términos modelo probabilístico y modelo de escenario para describir dos tipos diferentes de modelización probabilística[24] (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024c):

- **Modelo probabilístico:** Es un modelo en el que se calcula la pérdida para muchos eventos independientes con el fin de obtener resultados probabilísticos, como las pérdidas anualizadas o las curvas de excedencia.

- **Modelo de escenario:** Este tipo de modelo calcula la pérdida para un único evento teórico, en el que existe incertidumbre sobre cómo se desarrollará el evento. Por ejemplo, cómo se propagará el movimiento del suelo desde el epicentro de un sismo, o cómo las condiciones del terreno el día del evento afectarán la propagación de una inundación tras la ruptura de un dique.

[24] RiskScape define modelización probabilística como aquella que se refiere a un modelo de pérdidas que aborda ciertas incertidumbres presentes en el análisis.

Para construir un modelo probabilístico en RiskScape, hay dos partes clave: la generación de una tabla de pérdidas por evento y el cálculo de resultados probabilísticos (por ejemplo, la Probabilidad Anual de Excedencia AEP). La estructura del modelo dependerá en gran medida del conjunto de datos del evento de amenaza. La tabla de pérdidas por evento calcula la pérdida total para cada evento, y su construcción varía según los datos de entrada (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024c).

RiskScape considera los siguientes enfoques para los análisis probabilísticos:

- **Basado en eventos:** cada evento en el conjunto de datos de entrada se trata como si tuviera la misma probabilidad dentro del propio modelo (simulación de Monte Carlo). El modelo depende de tener suficientes eventos en el conjunto de datos para modelar la incertidumbre y generar una curva de pérdidas. Un aspecto clave de los modelos probabilísticos basados en eventos es el número de conjuntos de eventos hipotéticos a los que pertenecen los eventos. Típicamente, esto corresponde al número de períodos de tiempo, como por ejemplo los años, que se modelan, y es necesario para calcular las pérdidas anualizadas. A este conjunto se le denomina el Conjunto de Eventos Estocásticos (SES, por sus siglas en inglés).

  Una vez se obtiene la pérdida total para cada evento, cada evento se asigna a un Conjunto de Eventos Estocásticos (SES). Esto asigna cada evento al año calendario en el que ocurrió.
  El SES es importante para calcular la Pérdida Promedio Anualizada, ya que algunos años calendario pueden tener múltiples eventos, mientras que otros años pueden no tener eventos. Es importante destacar que, si no ocurrieron eventos en un SES (año) determinado, se asigna una pérdida de cero.
  Para producir la curva de riesgo, las pérdidas se clasifican de mayor a menor y se asigna una probabilidad dividiendo el rango entre el número de conjuntos de eventos.

  Para ilustrar el método y otros presentados en esta sección, se utilizarán los ejemplos proporcionados por la documentación en línea de RiskScape[25].

  La **Tabla 24** muestra un conjunto de datos de 5 eventos para los que se ha calculado la pérdida.

Tabla 24. Ejemplo de 5 eventos para los cuales se ha calculado la pérdida

Evento	Conjunto de eventos	Pérdida
1	1	$1100
2	3	$500
3	4	$600
4	4	$200

[25] https://riskscape.org.nz/docs/advanced/probabilistic.html

Se cuentan las pérdidas que exceden un nivel de pérdidas determinado como se muestra en la **Tabla 25**.

Tabla 25. Conteo de eventos de pérdida que exceden un nivel de pérdidas determinado

Nivel de pérdida	Conteo
100	4
250	3
500	2
750	1
1000	1

Se calcula la tasa de excedencia (λ) para un periodo de tiempo unitario (1).

Tabla 26. Tasa de excedencia

Nivel de pérdida	Conteo	Cálculo	λ
100	4	4 / (5 *1)	0.8
250	3	3 / (5 *1)	0.6
500	2	2 / (5 *1)	0.4
750	1	1 / (5 *1)	0.2
1000	1	1 / (5 *1)	0.2

Asumiendo que los eventos son independientes, es posible utilizar una distribución de Poisson para calcular la probabilidad anual de excedencia y (AEP) mediante la sustitución de la tasa (λ) y el periodo de tiempo (T) en la fórmula 1- exp(-λ * T).

Tabla 27. Cálculo de AEP

Nivel de pérdida	Conteo	λ	Cálculo	AEP
100	4	0.8	1 - exp(-0.8 * 1)	0.55
250	3	0.6	1 - exp(-0.6 * 1)	0.45
500	2	0.4	1 - exp(-0.4 * 1)	0.33
750	1	0.2	1 - exp(-0.2 * 1)	0.18
1000	1	0.2	1 - exp(-0.2 * 1)	0.18

El periodo de retorno o intervalo de recurrencia promedio (ARI) puede calcularse de la tasa como se muestra en la **Tabla 28**.

Tabla 28. Cálculo del periodo de retorno

Nivel de pérdida	Conteo	λ	Cálculo	ARI
100	4	0.8	1 / 0.8	1.25
250	3	0.6	1 / 0.6	1.66
500	2	0.4	1 / 0.4	2.5
750	1	0.2	1 / 0.2	5
1000	1	0.2	1 / 0.2	5

Basado en eventos ponderados: cada evento en el conjunto de datos de entrada ya tiene una probabilidad o tasa de ocurrencia asociada. Esta es la tasa a la que ocurre este evento durante el período de tiempo definido (generalmente anualmente). Por ejemplo, una tasa de 0.1 para un período de un año significaría que, en promedio, un evento es probable que ocurra cada diez años. Un modelo basado en eventos ponderados ofrece una buena cobertura del rango de eventos posibles, sin requerir la gran cantidad de eventos de una simulación de Monte Carlo.

Por ejemplo, la **Tabla 29** muestra las pérdidas para 5 eventos.

Tabla 29. Tabla de pérdidas para 5 eventos

Evento	Tasa de ocurrencia	Pérdida
1	0.01	$1100
2	0.035	$500
3	0.04	$600
4	0.1	$200
5	0.05	$800

Para calcular la pérdida anual esperada AAL se realiza la suma de los valores de tasa de ocurrencia multiplicada por la pérdida, que resulta en una AAL de $112.50.

Tabla 30. Cálculo de la pérdida anual esperada

Evento	Tasa de ocurrencia	Pérdida	Tasa de ocurrencia x pérdida
1	0.01	$1100	$11.0
2	0.035	$500	$17.5
3	0.04	$600	$24.0
4	0.1	$200	$20.0
5	0.05	$800	$40.0
Total	**0.235**	**$3200**	**$112.50**

Para calcular la desviación estándar se aplica la fórmula tasa de ocurrencia x pérdida^2. Agregando los valores se obtiene $71250. La raiz cuadarada de este valor proporciona una desviación estándar de $266.93.

Tabla 31. Cálculo de la desviación estándar

Evento	Tasa de ocurrencia	Pérdida	Tasa de ocurrencia x pérdida
1	0.01	$1100	12100
2	0.035	$500	8750
3	0.04	$600	14400
4	0.1	$200	4000
5	0.05	$800	32000
Total			**71250**

Para calcular la probabilidad anual de excedencia, se agrega la tasa de ocurrencia de cada evento que excede un nivel de pérdida lo que proporciona la tasa total de excedencia.

Tabla 32. Tasa total de excedencia

Nivel de pérdida	Tasa de excedencia
100	0.235
250	0.135
500	0.1
750	0.06
1000	0.01

Con la tasa de excedencia se puede calcular de probabilidad anual de excedencia (AEP) aplicando $1 - \exp(-\lambda * T)$.

Tabla 33. Cálculo de la probabilidad anual de excedencia (AEP)

Nivel de pérdida	Tasa de excedencia	Cálculo	AEP
100	0.235	1 - exp(-0.235 * 1)	0.209
250	0.135	1 - exp(-0.135 * 1)	0.126
500	0.1	1 - exp(-0.1 * 1)	0.095
750	0.06	1 - exp(-0.06 * 1)	0.058
1000	0.01	1 - exp(-0.1 * 1)	0.01

El periodo de retorno, o intervalo de recurrencia promedio (ARI), puede calcularse de la tasa como se muestra en la **Tabla 34**.

Tabla 34. Cálculo del intervalo de recurrencia promedio (ARI)

Nivel de pérdida	Tasa de excedencia	Cálculo	ARI
100	0.235	1 / 0.235	4.26
250	0.135	1 / 0.135	7.41
500	0.1	1 / 0.1	10.0
750	0.06	1 / 0.06	16.67
1000	0.01	1 / 0.01	100.0

Basado en amenaza: el conjunto de datos de entrada contiene un número reducido de eventos, cada evento tiene una tasa de ocurrencia (o período de retorno). Por ejemplo, los archivos de entrada de amenaza podrían representar una inundación con periodos de retorno de 10 años, 50 años, 100 años, etc. Esto difiere de otros modelos probabilísticos, como los modelos basados en eventos, donde se deriva la probabilidad de excedencia a partir de la ejecución del propio modelo.

El principal beneficio del enfoque basado en amenazas es que solo se necesita un pequeño número de eventos para crear un resultado probabilístico. Esto es útil cuando no es factible producir los miles de capas de amenaza requeridas para un modelo basado en eventos.

Un modelo probabilístico basado en amenazas requiere que cada evento en el modelo tenga un intervalo de recurrencia conocido (o período de retorno), que esté presente en los datos de las capas de amenaza (o en los metadatos). Además, la función de pérdidas del modelo debe producir pérdidas que aumenten de forma monótona con respecto a la disminución de la frecuencia de la amenaza. En otras palabras, los eventos menos frecuentes deben producir una pérdida más severa para cada elemento en riesgo que esté expuesto a la amenaza.

La probabilidad de excedencia se da como un número decimal entre 0 y 1. Esto se interpreta como la probabilidad de que ocurra un evento de esta intensidad o mayor en un período dado (generalmente años). Una probabilidad de excedencia se puede relacionar con un período de retorno utilizando una función de masa de probabilidad. En los ejemplos proporcionados por RiskScape se asume que la función de la distribución de Poisson es adecuada. Al usar Poisson, se utiliza el período de retorno como tasa, también conocida como lambda λ. Un período de retorno puede convertirse en una probabilidad de excedencia (EP) con la **Ecuación 11**.

Ecuación 11

$$EP = 1 - e^{\lambda x T}$$

A menudo, las probabilidades de excedencia se calculan a partir de un período de retorno (RP) con una aproximación simple, mostrada en la **Ecuación 12**.

Ecuación 12

$$\frac{1}{RP}$$

Pero esta es una aproximación más pobre que usar el cálculo basado en Poisson. La **Tabla 35** muestra cómo el método de aproximación se vuelve menos preciso a medida que aumenta la probabilidad.

Tabla 35. Comparación de la probabilidad de excedencia calculada con Poisson y con el recíproco

Probabilidad	ARI recíproco	Poisson ARI
0.001%	1000000	99999.49
0.1%	1000	999
25%	4	3.48
50%	2	1.44

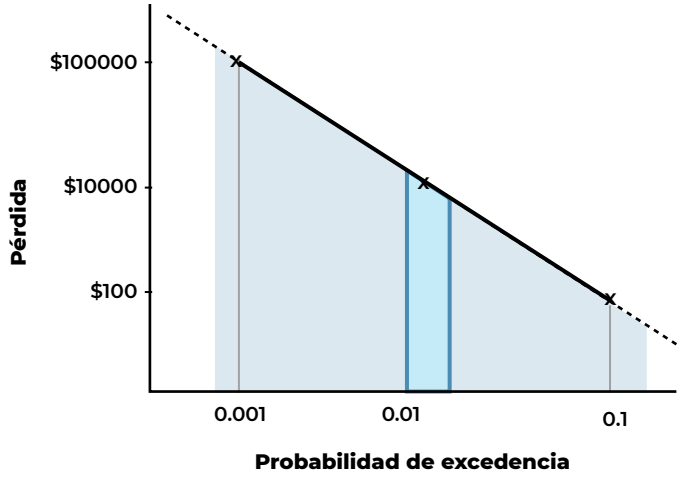
Con un modelo probabilístico basado en amenaza, no hay suficientes puntos de datos para usar el mismo método numérico para calcular una AAL como en el caso de modelos basados en eventos o en eventos ponderados. En cambio, este método se basa en la regla del trapecio para estimar el área bajo la "curva" de la probabilidad de excedencia de cada evento y la pérdida calculada para ese evento.

Tabla 36. Ejemplo de probabilidad de excedencia y pérdidas asociadas

Evento	Probabilidad de excedencia	Poisson ARI
1	0.1	$1000
2	0.01	$10000
3	0.001	$100000

A partir de los datos de la **Tabla 36** , es posible trazar la curva, y usando el método del trapecio puede estimarse el área bajo la curva, que representa la AAL.

Figura 43. Curva de probabilidad de excedencia y pérdidas



La **Figura 43** muestra el área sombreada (en escala log-log) debajo de la curva trazada a partir de los puntos de datos de la **Tabla 36**. Tomar una "rebanada" entre dos puntos de la curva da como resultado una forma trapezoidal (ver zona azul en la **Figura 43**).

El método trapezoidal simplemente toma múltiples porciones entre el mínimo EP (es decir, 0,001) y el EP máximo (es decir, 0,1) y los suma. Esto da como resultado el área bajo la curva entre los puntos de datos del primer y último evento. Sin embargo, todavía faltan dos partes de la curva: el lado izquierdo entre EP 0.0 y 0.001, y el lado derecho entre EP 0.1 y 1.0 (o cuando la pérdida se convierta en $0). No es posible hacer nada con respecto al lado derecho de la curva que falta, esto depende de disponer de datos de amenaza que se acerquen lo más posible a un evento de cero pérdidas. Para el lado izquierdo que falta, sabemos que las pérdidas están aumentando monótonamente, por lo tanto, las pérdidas entre 0.0 y 0.001 deben ser mayores o iguales a la pérdida máxima conocida ($100,000). Así que, esencialmente, podemos añadir un punto de datos extra (EP=0.0, pérdida=$100,000) a la curva.

El método trapezoidal consiste simplemente en tomar la diferencia de valor (probabilidad de excedencia) entre dos puntos de datos y multiplicarlo por el valor medio (pérdida). En la Tabla 37 se muestra la integración trapezoidal aplicada a los tres eventos de ejemplo, más el punto de datos adicional EP=0.0.

Tabla 37. Cálculo del área bajo la curva

Diferencia de EP	Promedio de pérdidas	Rebanada trapezoidal
0.1 - 0.01	($10,000 + $1,000) / 2	0,09 * 5500 = 495,0
0.01 - 0.001	($100,000 + $10,000) / 2	0,009 * 55000 = 495,0
0.001 - 0.0	($100,000 + $100,000) / 2	0,001 * 100000 = 100,0

La suma de las rebanadas trapezoidales es $495 + $495 + $100 = $1090.

Debido a que el corte 'trapezoidal' EP = 0.0 es en realidad un rectángulo, se puede simplificar a solo la pérdida máxima multiplicada por el EP mínimo. Con este término adicional EP=0.0, el cálculo del AAL del área de la curva de pérdidas se muestra en la **Ecuación 13**, donde f_a corresponde a EP mínimo, La a la pérdida máxima, L_{RP} corresponde a la pérdida asociada a determinada probabilidad de excedencia o periodo de retorno y n es el indicador de los puntos de la curva con N igual al número total de puntos de la curva y Δf es la diferencia de probabilidad de excedencia entre dos puntos consecutivos.

Ecuación 13

$$AAL = f_a L_a + \sum_{RP_n=a}^{N} \Delta f \ \frac{L_{RP_n} + L_{RP_{n+1}}}{2}$$

A.3.4. Avances recientes e innovaciones

Las últimas mejoras en el software RiskScape incluyen cambios significativos y mejoras que impactan tanto a usuarios expertos como a la experiencia general del software. Un cambio notable es la actualización de la biblioteca GeoTools, utilizada para el procesamiento de geometría, lo que mejora la estabilidad y el rendimiento. Se han implementado nuevas funcionalidades facilitando la personalización avanzada por parte de los usuarios. Además, se ha añadido una función para trabajar con funciones bidimensionales, y se han mejorado las funciones de manejo de errores (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024b).

A.3.5. Comunidad de desarrollo

RiskScape es mantenido y desarrollado por GNS Science y NIWA, con el apoyo financiero de la Comisión de sismos de Nueva Zelanda (EQC). La comunidad de usuarios incluye científicos, planificadores urbanos, aseguradoras y entidades gubernamentales que utilizan la plataforma para modelar pérdidas y riesgos asociados con desastres.

A.3.6. Limitaciones

La principal limitación de RiskScape es la necesidad de una configuración y modelado avanzados que pueden requerir conocimientos especializados, particularmente conocimientos en programación en Python.

A.3.7. Casos de uso

RiskScape se ha utilizado en toda Nueva Zelanda y el Pacífico Sur para ayudar a planificadores, entidades gubernamentales y compañías de seguros a modelar pérdidas y riesgos por desastres. Esto es crucial para la toma de decisiones en la planificación del uso del suelo, seguros y respuesta a emergencias. Por ejemplo, ha sido utilizado para analizar la exposición de edificios residenciales a sismos y para la planificación urbana frente a inundaciones y movimientos en masa. La **Caja 4** muestra un ejemplo del uso de RiskScape en planificación del uso del suelo.



Imagen: Adobe Stock

Caja 4. Ejemplo de aplicación de RiskScape

Caso de Estudio: Gestión de Riesgos por Inundación en Te Auaunga / Oakley Creek, Auckland



Te Auaunga (Oakley Creek) es un río que fluye desde Mt Roskill a través de varios suburbios del oeste de Auckland, descargando en el puerto interior de Waitemata cerca de Point Chevalier. La zona ha sido designada para una redensificación urbana a través del Plan de Uso del Suelo de Auckland (AUP). Actualmente, las zonas que se encuentran inmediatamente adyacentes al cuerpo de agua son una mezcla de zonas residenciales: casas y edificios de apartamentos, mezcla de viviendas urbanas y mezcla de viviendas suburbanas. Existe el potencial de una mayor densidad urbana mediante el cambio del plan de uso del suelo que podría permitir un mínimo de tres viviendas de tres pisos.

El departamento de operaciones de aguas pluviales del Consejo de Auckland, desarrolló el programa “Making Space for Water”, que fue presentado al Consejo en junio de 2023 e incluye nueve iniciativas clave:

- **Redes azul-verde en áreas críticas de riesgo de inundación:** Soluciones de aguas pluviales, mejora de parques o espacios abiertos, adquisición de propiedades.
- **Propiedades en alto riesgo:** Trabajo con los propietarios de propiedades en soluciones de ingeniería, reasentamiento y adquisición de propiedades.

- **Mejoras en alcantarillas y puentes:** Evaluación, reemplazo y mejora de activos vulnerables.
- **Manejo de trayectorias de flujo superficial:** Reparación, mantenimiento y trayectorias de flujo superficial, así como educación para los propietarios de viviendas en sus áreas de influencia.
- **Asentamientos rurales:** Respuesta a las necesidades de agua en comunidades afectadas por inundaciones, incluidos Marae y Papakāinga, y apoyo a la planificación de resiliencia comunitaria.
- **Inteligencia sobre inundaciones:** Inversión en herramientas de planificación y modelado para mejorar la toma de decisiones del consejo.
- **Rehabilitación de cuerpos de agua:** Manejo de vegetación, estabilización de taludes, modificación de cuerpos de agua, asesoramiento para propietarios de viviendas.
- **Resiliencia ante inundaciones liderada por la comunidad:** Asesoramiento para propietarios de propiedades en áreas de alto riesgo, asesoría específica para industrias, eventos públicos y campañas de sensibilización.
- **Aumento del mantenimiento:** Maximización de la eficiencia de la red de aguas pluviales, que incluye barrido de calles, limpieza de pozos y eliminación de maleza en los cuerpos de agua.

Este caso de estudio utiliza elementos de esas iniciativas para considerar cuatro enfoques de gestión de riesgos a través de la planificación del uso del suelo: Proteger, Aceptar, Reducir, Evitar (PARA por sus siglas en inglés):

- **Proteger:** Estructuras de protección duras. Este enfoque no se incluye en el caso de estudio, ya que requiere el modelamiento de la amenaza con obras, lo cual está fuera del alcance.
- **Aceptar (Acomodar):** Elevar la altura de los pisos. Los requisitos actuales son de 500 mm sobre un evento de inundación con probabilidad de 1% AEP (probabilidad anual de excedencia).
- **Reducir:** Redes azul-verde que incluyen soluciones de aguas pluviales, mejora de espacios verdes o abiertos, y reasentamiento.
- **Evitar:** No permitir más desarrollos o intensificación.

El objetivo es utilizar RiskScape™ para cuantificar el beneficio de diversas opciones de intervención del modelo PARA para el riesgo futuro en la llanura de inundación. El proceso seguido para crear la pipeline de RiskScape™ fue el siguiente:

- Modelar el riesgo futuro base (sin cambios en la política de uso del suelo existente), luego modelar con las opciones de intervención políticas para mostrar la diferencia en el riesgo futuro. La diferencia en el riesgo futuro se utiliza para mostrar la posible reducción del riesgo al implementar las políticas y contribuir al análisis de costo-beneficio.

- Modelar una serie de escenarios con diferentes AEPs (probabilidad anual de excedencia) para entender el riesgo de inundación a través de un espectro de posibles escenarios. Se utilizaron escenarios con AEPs que van desde 5%, 2%, 1%, 0.5%, 0.2%, 0.1% hasta 0.01% para considerar una gama amplia de posibles inundaciones.

- Elegir un horizonte temporal de planificación. En este caso, se eligió el año 2120 como fecha de riesgo futuro, lo que implica modificar los datos de exposición desde el presente hasta una exposición potencial en 97 años.

- Examinar los niveles de intensificación futura. Las zonas del plan de uso del suelo tienen niveles variables de redensificación residencial que pueden ocurrir como una actividad permitida, pero deben cumplir con los estándares.

- Definir la máxima intensificación posible dentro del horizonte de planificación.

- Generar conjuntos de datos de exposición futura. Una vez establecido el ritmo de desarrollo, RiskScape™ genera conjuntos de datos de exposición futura para cada año entre el año actual (2023) y el horizonte de planificación futuro (2120).

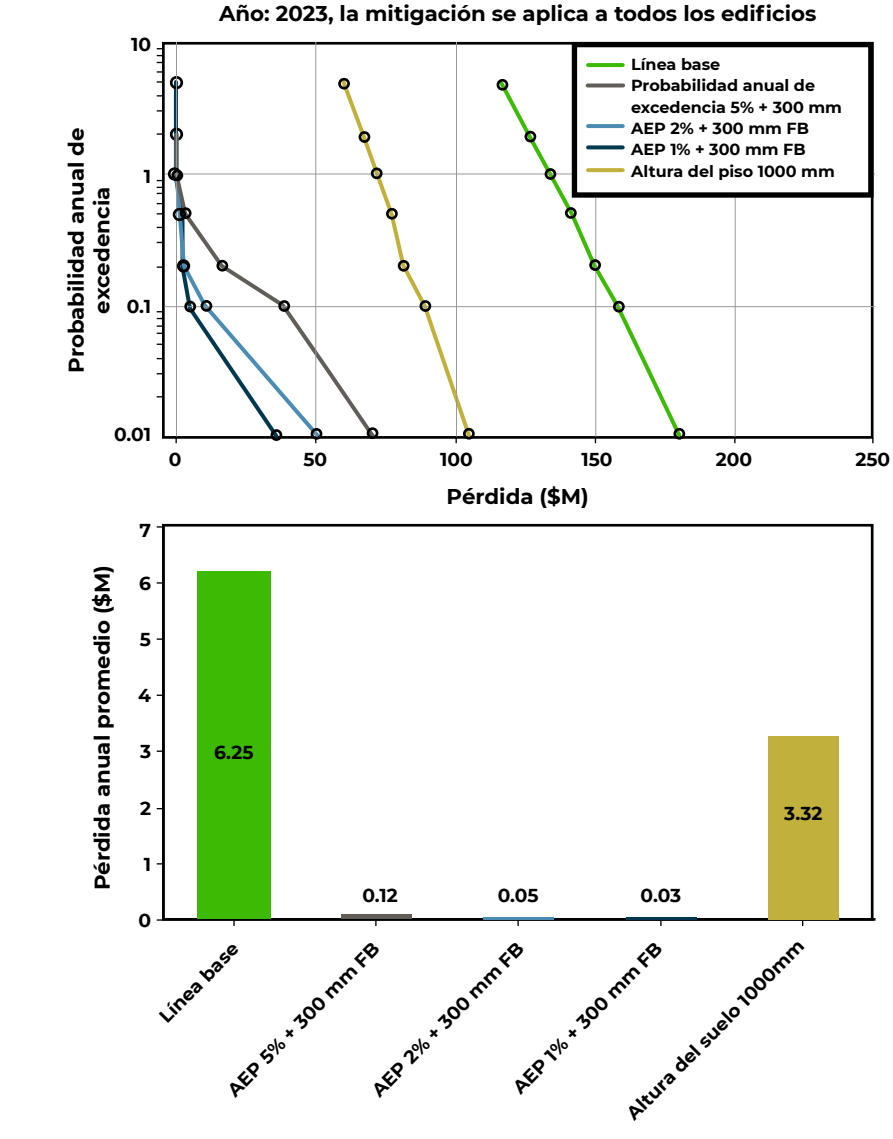
- Calcular el riesgo a lo largo del tiempo. RiskScape™ calcula el riesgo para cada año utilizando las capas de amenaza. Si existiera un cambio climático o algún otro factor temporal en los datos de amenaza, también podría incorporarse.

Los resultados obtenidos con RiskScape™ se definen mediante dos métricas (ver la siguiente figura): curvas de riesgo y la AAL (pérdida anual promedio). Las curvas de riesgo muestran la probabilidad de exceder un nivel determinado de pérdida en función del AEP, con diferentes opciones de mitigación.

La opción de elevar las alturas de los pisos a un valor fijo de 1000 mm reduce la pérdida, pero no es tan beneficiosa como vincularla con un modelo de AEP más un margen de seguridad (freeboard). También se observa una reducción en las pérdidas al aplicar modelos de AEP del 5%, 2% o 1% más margen de seguridad. La métrica de AAL muestra la reducción de pérdidas

a lo largo del tiempo, lo que es útil para el análisis de costo-beneficio. Con la aplicación de diversas opciones de mitigación, como el aumento de las alturas de los pisos o la inclusión de margen de seguridad, se logra una reducción significativa de las pérdidas anuales.

Este caso de estudio demuestra cómo RiskScape™ puede ser utilizado para cuantificar los beneficios de diversas intervenciones políticas en la gestión de riesgos de inundación. Al modelar diferentes escenarios de riesgo y aplicar diversas opciones de mitigación, se puede optimizar la toma de decisiones en cuanto a la planificación del uso del suelo y la resiliencia frente a inundaciones, promoviendo una gestión más informada y eficiente de los riesgos para la comunidad.



Fuente: Bretherton et al. (2023)

A.4. INASAFE

A.4.1. Descripción general

InaSAFE (Indonesia Scenario Assessment for Emergencies) es una herramienta de software libre desarrollada para la evaluación del impacto de desastres como sismos, tsunamis e inundaciones. Fue desarrollada en colaboración entre la Agencia Nacional de Gestión de Desastres de Indonesia, el Gobierno Australiano y el Banco Mundial GFDRR.

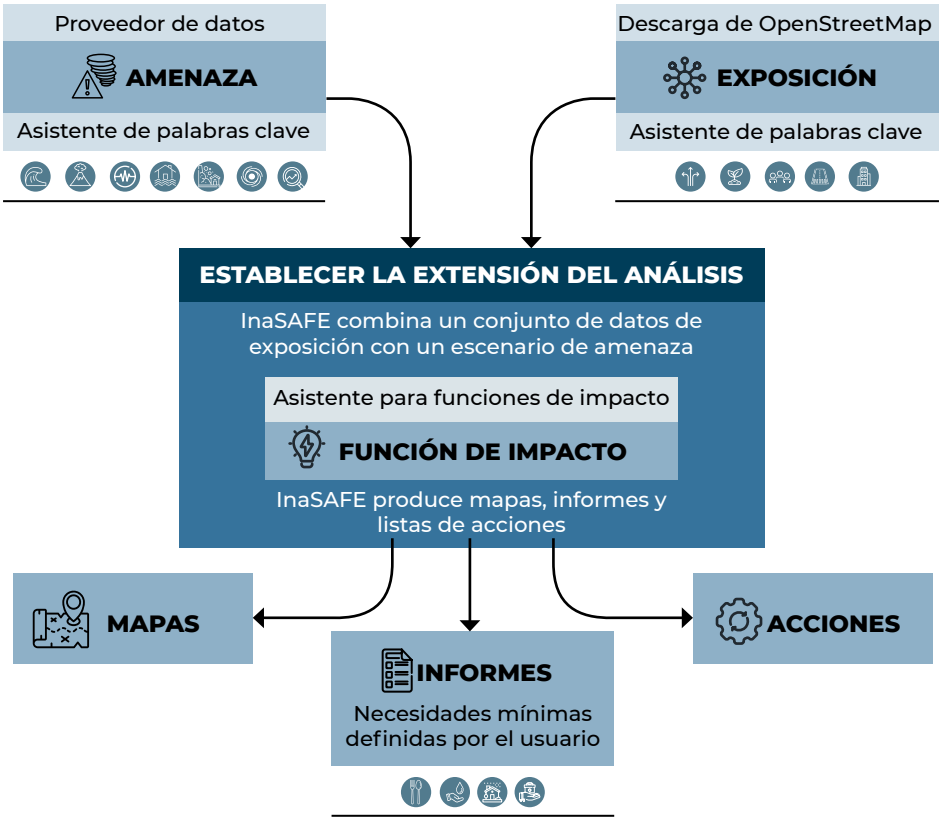
InaSAFE es un software libre que produce escenarios de impacto de amenazas naturales para mejorar las actividades de planificación, preparación y respuesta. Proporciona una forma simple pero rigurosa de combinar información técnica, de gobiernos locales y comunidades para proporcionar información sobre los impactos probables de futuros desastres.

El proyecto InaSAFE se inició con el fin de proporcionar una herramienta para los gestores de desastres que desean comprender cuáles serán los impactos potenciales de un desastre. Inicialmente, la actividad se centró en Indonesia, un país muy vulnerable a diferentes desastres, como inundaciones, tsunamis, volcanes, sismos, así como a otros desastres localizados como movimientos en masa, incendios forestales, etc. Desde entonces, InaSAFE ha sido adoptado para su uso en muchos otros países, no es específico de Indonesia (InaSAFE 2019b).

A.4.2. Métodos aplicados

InaSAFE combina una capa de datos de exposición (por ejemplo, la ubicación de los edificios) con un escenario de amenaza (por ejemplo, la huella de una inundación) y devuelve una capa de impacto espacial junto con un resumen estadístico y preguntas de acción. La estructura de la herramienta se muestra en la **Figura 44,** indicando como a los datos de entrada, que corresponden a las capas de amenaza y exposición, se les aplica una función de impacto para producir mapas, reportes y listas de acciones. InaSAFE se enmarca en responder a preguntas como: “En caso de una inundación similar a la de Yakarta de 2013, ¿cuántas personas podrían necesitar ser evacuadas?” (InaSAFE 2019a).

Figura 44. Estructura de InaSAFE



Fuente: InaSAFE (2019a).

InaSAFE también puede dividir los resultados del impacto por límites administrativos y proporcionar un desglose de la información sobre el género y la edad de las personas afectadas dependiendo de la información de entrada utilizada (InaSAFE 2019a).

Los datos de amenaza utilizados en InaSAFE pueden representar un solo evento o varios eventos. La información de un solo evento es útil cuando se desea estimar por ejemplo “cuántas personas se verían afectadas si ocurriera otra inundación como la de 2013”. Los datos de eventos múltiples son útiles cuando se desea planificar para desastres que afectan repetidamente a la misma área.

El tipo de información de amenaza que utiliza InaSafe es vectorial o ráster. En el caso de información vectorial se requiere un campo que representa si el polígono es propenso a inundaciones o no. En el caso de información ráster se requiere una malla simple con valores de celda que representan la profundidad del agua (InaSAFE 2019a).

Actualmente, InaSAFE admite cuatro tipos de datos de exposición: carreteras, edificios, población y cobertura del suelo. Con las funciones de impacto de inundación en carreteras de InaSAFE es posible calcular qué carreteras y de qué tipo podrían verse afectadas por una inundación. Los datos de OpenStreetMap de vías pueden ser descargados directamente utilizando la herramienta de descarga de OSM proporcionada por InaSAFE. En el caso del inventario de edificaciones, InaSAFE require una capa vectorial de polígonos con un campo que incluya el tipo de edificación. Actualmente, InaSAFE solo admite datos censales basados en ráster, pero está planificado para versiones posteriores la asignación de estimaciones de población a edificios utilizando datos censales. La información de cobertura de suelo debe proporcionarse en formato vectorial de polígonos con un campo que contenga el tipo de cobertura. Los datos de lugares generalmente se pueden obtener de las agencias nacionales de mapeo o a través de varias fuentes de datos en línea. Los datos de lugares son útiles si desea evaluar el impacto de un evento en un lugar en particular. Para la evaluación de lugares se utiliza una capa vectorial de puntos que debe tener un campo con el nombre del lugar (InaSAFE 2019a).

Una Función de Impacto es un código de software en InaSAFE que implementa un algoritmo particular para determinar el impacto de una amenaza en la exposición seleccionada. La ejecución de una función de impacto se realiza cuando se han preparado todos los datos de entrada, se ha definido la extensión del análisis y se desea ver las salidas de impacto. Cada Función de Impacto generará resultados que pueden incluir: una capa de mapa de impacto, un resumen de impacto, necesidades mínimas, y listas de verificación de acciones (InaSAFE 2019a).

Una capa de impacto es un nuevo dataset SIG que se produce como resultado de la ejecución de una Función de Impacto. Por lo general, representará la capa de exposición. Por ejemplo, si realiza un análisis de inundación en edificios, la capa de impacto producida será una capa de edificios, pero cada edificio se clasificará en función de si está seco o inundado (el resultado que produce InaSAFE es binario indicando si el edificio ha sido afectado o no). InaSAFE aplicará su propia simbología a la capa de impacto de salida para dejar claro cuáles son los edificios afectados. También hay que tener en cuenta que la capa de impacto solo incluirá entidades/celdas que se produzcan dentro de la extensión del análisis (InaSAFE 2019a).

Una capa de impacto es un nuevo dataset SIG que se produce como resultado de la ejecución de una Función de Impacto. Por lo general, representará la capa de exposición. Por ejemplo, si realiza un análisis de inundación en edificios, la capa de impacto producida será una capa de edificios, pero cada edificio se clasificará en función de si está seco o inundado (el resultado que produce InaSAFE es binario indicando si el edificio ha sido afectado o no). InaSAFE aplicará su propia simbología a la capa de impacto de salida para dejar claro cuáles son los edificios afectados. También hay que tener en cuenta que la capa de impacto solo incluirá entidades/celdas que se produzcan dentro de la extensión del análisis (InaSAFE 2019a).

Mientras que la capa de impacto representa datos espaciales, el resumen de impacto son datos tabulares y textuales. El resumen de impacto proporciona una tabla (o serie de tablas) y otra información textual con el número de edificios, carreteras o personas afectadas, e incluye otra información útil, como

desgloses de necesidades mínimas, listas de verificación de acciones y resúmenes. El resumen de impacto presenta los resultados de la función de impacto en una forma fácil de utilizar (InaSAFE, 2019c). Los resultados están limitados a mostrar exposición es decir al conteo de elementos que se encuentran en una determinada categoría de amenaza, aunque cuenta con funciones de impacto que pueden generar información de población desplazada y muertes (InaSAFE 2019a).

A.4.3. Avances recientes e innovaciones

InaSAFE ha lanzado varias versiones, con mejoras significativas en la interfaz de usuario y la compatibilidad con QGIS. La última versión publicada corresponde a la versión 5.0.0 publicada en noviembre de 2018. Esta versión incluye soporte para QGIS 3.x. Esta versión es una adaptación directa del código base 4.4.0 con algunas características adicionales agregadas, como por ejemplo un puerto QGIS3 con Python 3 y Qt 5 (InaSAFE 2019c).

A.4.4. Comunidad de desarrollo

InaSAFE fue desarrollado inicialmente por la Agencia Nacional de Gestión de Desastres de Indonesia (BNPB), el Gobierno Australiano y el Banco Mundial a través de la Global Facility for Disaster Reduction and Recovery (GFDRR). El Gobierno Australiano, en coordinación con BNPB, impulsa el desarrollo de InaSAFE mediante su uso en seis provincias indonesias. Tras su lanzamiento en octubre de 2012, la Australia-Indonesia Facility for Disaster Reduction (AIFDR) organizó capacitación para la planificación de contingencias en estas provincias con el apoyo de la Humanitarian OpenStreetMap Team (HOT) y la Universidad de Gadjah Mada (UGM) (InaSAFE 2019d).

El uso de InaSAFE ha generado muchas solicitudes de nuevas funciones, priorizadas por BNPB y el Gobierno Australiano y desarrolladas por Kartoza. El Banco Mundial, a través de GFDRR, desarrolló una versión en línea de InaSAFE para facilitar el análisis sin necesidad de descargar el software, y también ha ayudado a otros países a implementar InaSAFE. El Grupo de Trabajo Técnico de InaSAFE, compuesto por representantes de BNPB, el Gobierno Australiano y el GFDRR, son los responsables del desarrollo y mantenimiento del software (InaSAFE 2019d).

A.4.5. Limitaciones

Una de las limitaciones más importantes es que InaSAFE no realiza un análisis cuantitativo económico de riesgo, el software está limitado a la evaluación de la exposición.

A.4.6. Casos de uso

InaSAFE se ha utilizado en varios proyectos de evaluación de riesgos en Indonesia y otros países. Ha sido empleado para la planificación de emergencias, la preparación comunitaria y la respuesta ante desastres, ayudando a las autoridades locales a comprender y mitigar los riesgos de desastres.

Caja 5. Ejemplo de aplicación de InaSAFE

Caso de Estudio: Uso de InaSAFE durante la Inundación en Yakarta de 2014

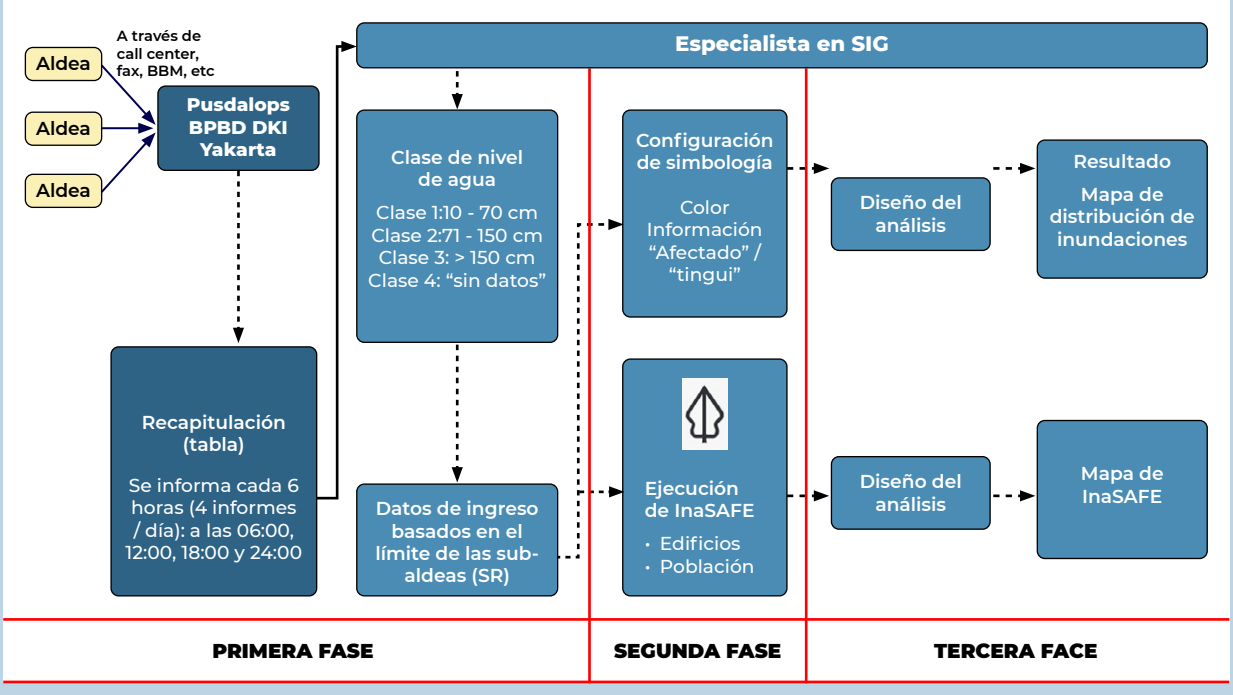
Antecedentes

Yakarta sufre inundaciones estacionales casi todos los años entre diciembre y febrero debido a las altas precipitaciones. Geográficamente, es una llanura baja donde confluyen varios ríos de Java Occidental. Las malas condiciones de drenaje de la ciudad, junto con su ubicación, contribuyen a las inundaciones durante la temporada de lluvias. En estas circunstancias, tanto el público como los funcionarios gubernamentales necesitan información accesible y comprensible sobre las áreas afectadas por las inundaciones.

Reconociendo el papel crítico de los mapas de amenaza en la gestión de desastres, la Australia-Indonesia Facility for Disaster Reduction (AIFDR) financió al Humanitarian OpenStreetMap Team (HOT) para asistir a la Agencia de Gestión de Desastres de Yakarta (BPBD DKI Jakarta) en la cartografía de las inundaciones en 2014. Dos especialistas en GIS de HOT trabajaron diariamente durante dos meses en Pusdalops BPBD DKI Jakarta, produciendo mapas de inundación basados en los informes de las aldeas afectadas.

Implementación

Los mapas se desarrollaron utilizando software libre incluyendo InaSAFE y de código abierto como QGIS 2.0. El flujo de trabajo involucró varias fases que se muestran en la siguiente figura:



- **Recopilación de Datos:** Representantes de las aldeas afectadas reportaron a Pusdalops BPBD DKI Jakarta a través de un centro de llamadas, fax o BlackBerry Messenger, proporcionando información sobre la altura y extensión de la inundación. Estos informes se resumían en una tabla que se enviaba al jefe de Pusdalops y al Gobernador de Yakarta cada seis horas.

- **Desarrollo de Mapas:** Los especialistas en GIS procesaron estas tablas en mapas. La información sobre el nivel de inundación se clasificaba en cuatro clases y se introducía en QGIS 2.0, superponiéndose a los datos de límites de aldeas de OpenStreetMap (OSM).

- **Distribución y Análisis:** Los mapas resultantes incluían símbolos para mostrar la distribución de la inundación y el nivel de inundación. Además, se generaron mapas de InaSAFE, que integraban datos de riesgos y exposición para calcular estimaciones de impacto.

Resultados

La colaboración entre HOT y BPBD DKI Jakarta resultó en la generación de mapas de inundación para el evento ocurrido entre el 12 de enero al 10 de febrero de 2014. Estos mapas mostraban el nivel de inundación en las áreas afectadas y proporcionaban una visualización adicional del número de edificios afectados y la cantidad estimada de desplazados internos obtenida con InaSAFE. Los mapas se publicaban diariamente y resultaron ser útiles para la toma de decisiones oficiales y la distribución de ayuda. Los mapas también fueron accesibles al público, beneficiando a voluntarios y periodistas, y ayudando a la población de Yakarta a hacer frente a las inundaciones.


Imagen: Adobe Stock

Lecciones Aprendidas

Para que InaSAFE funcione de manera óptima, se identificaron dos áreas de mejora:

- **Datos de Infraestructura:** Mejorar la completitud de los datos de infraestructuras, especialmente los edificios públicos, ya que los datos actuales de OSM son limitados.

- **Detalle Geográfico:** Aumentar el detalle de la cobertura geográfica del análisis, pasando del nivel de sub-aldea (RW) a niveles más detallados (RT), para proporcionar información más precisa sobre las áreas afectadas.

Fuente: InaSAFE (2019a).

A.5. OASIS LOSS MODELLING FRAMEWORK (OASIS LMF)

A.5.1. Descripción general

El proyecto H2020_Insurance de la Comisión europea creó el *Oasis Loss Modelling Framework (LMF)* para la modelación de riesgos asociados a catástrofes y extremos climáticos. El principal resultado fue el desarrollo de una plataforma de código abierto, colaborativa y de evaluación de riesgos climáticos múltiples, diseñada para mejorar la información disponible en el sector de (rea)seguros y reducir la brecha entre las pérdidas relacionadas con el clima que están aseguradas y las que no (Sheehan et al. 2023).

Oasis LMF es un sistema de modelado de catástrofes que incluye un conjunto de estándares de datos, una API y herramientas y componentes para construir y ejecutar modelos (Oasis, 2024a). Aunque Oasis es de código abierto y cualquiera puede instalarlo y ejecutarlo de forma gratuita, existen varias empresas que ofrecen servicios y soporte alrededor de Oasis de carácter comercial. Algunas de estas empresas ofrecen una plataforma alojada para ejecutar modelos de Oasis, otras han integrado Oasis en sus propias plataformas y algunas brindan opciones de soporte tradicional para implementaciones internas de Oasis (Oasis, 2024b).

Los principales usuarios de Oasis son (Oasis 2024a):

1. **Desarrolladores de modelos**, que crean, prueban y publican los modelos de riesgo. Generalmente, son científicos o desarrolladores de software que trabajan en empresas de modelación de riesgos o en instituciones académicas.

2. **Analistas de riesgo**, que operan los modelos para apoyar la toma de decisiones. El grupo principal de usuarios son analistas en organizaciones de seguros o reaseguros, quienes ejecutan los modelos para respaldar la fijación de precios y la gestión de carteras. Esto también incluye a usuarios de entidades gubernamentales.

3. **Sistemas empresariales de riesgo** en organizaciones de seguros o reaseguros, donde los modelos de riesgo de Oasis se integran mediante APIs en los flujos de trabajo de fijación de precios y gestión de carteras.

Los componentes del software se describen a continuación y se muestran en la **Figura 45** (Oasis 2024b).

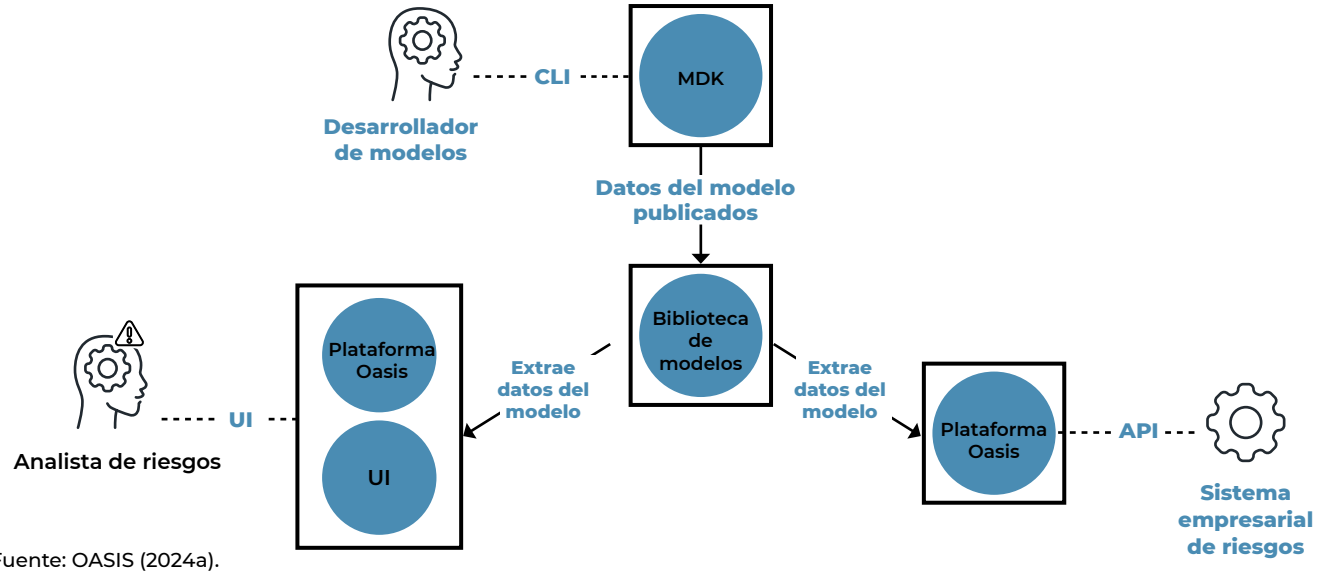
1. Plataforma Oasis: es un sistema de modelación de catástrofes que incluye un conjunto de estándares de datos, una API y herramientas y componentes para construir y ejecutar modelos. Es la base principal de Oasis, en la que se implementa la mayoría del código específico del dominio y se optimiza el rendimiento.

2. Interfaz de Usuario de Oasis (UI): es una aplicación web para cargar datos de exposición, ejecutar modelos implementados en Oasis y recuperar datos de resultados. Está orientada a la operación de modelos en empresas de (rea)seguros en conjunto con herramientas existentes de gestión de exposición y de informes; también es útil para la evaluación de modelos y su uso en contextos gubernamentales. La UI fue diseñada principalmente para la evaluación y pruebas de modelos.

3. Kit de Desarrollo de Modelos de Oasis (MDK): es un conjunto de herramientas para construir, calibrar y crear un modelo listo para ser implementado en la Plataforma Oasis. Está diseñado para desarrolladores de modelos o usuarios académicos, quienes suelen estar familiarizados con el trabajo directo con los datos desde la línea de comandos o de forma programática.

4. Biblioteca de Modelos de Oasis: es un catálogo de modelos de Oasis alojado en AWS. Permite la regresión de los modelos tras las actualizaciones del código de la Plataforma Oasis, así como la validación de la operación y escalabilidad de los modelos.

Figura 45. Ecosistema de Oasis



Fuente: OASIS (2024a).

La plataforma Oasis se puede acceder de diversas maneras, según las necesidades del usuario. Los modelos pueden ejecutarse utilizando la interfaz de usuario de Oasis (UI) o la interfaz de programación de aplicaciones (API). La UI es una aplicación basada en navegador, mientras que la API permite ejecutar los modelos directamente desde otros sistemas. La plataforma Oasis puede implementarse en un servidor utilizando contenedores Docker, o en servidores en la nube, como AWS y Azure (Oasis 2024b).

Aunque hay numerosos modelos disponibles en la plataforma Oasis, el acceso a ellos depende de los acuerdos establecidos entre el usuario y el proveedor del modelo. Se pueden añadir más modelos a la cuenta del usuario una vez que se hayan establecido los acuerdos con los proveedores. Sin embargo, la mayoría de los modelos están disponibles por un tiempo limitado para fines de evaluación a través de un entorno alojado (Oasis 2024a).

El costo de usar Oasis varía según los modelos, los datos utilizados, el tamaño de la organización y la cantidad de usuarios. A continuación, se muestra una guía aproximada de los costos de licencia de los modelos más relevantes (sismos y huracanes en EE. UU., sismos y tifones en Japón, tormentas de viento en Europa e inundaciones en el Reino Unido) para un acuerdo de 3 años, según lo publicado en (Oasis 2024a). Los precios indicados están en USD, no incluyen los costos de alojamiento ni impuestos, y solo deben tomarse como una referencia aproximada, ya que pueden variar.

Empresa pequeña: alrededor de **$479,000**

Empresa mediana: alrededor de **$663,000**

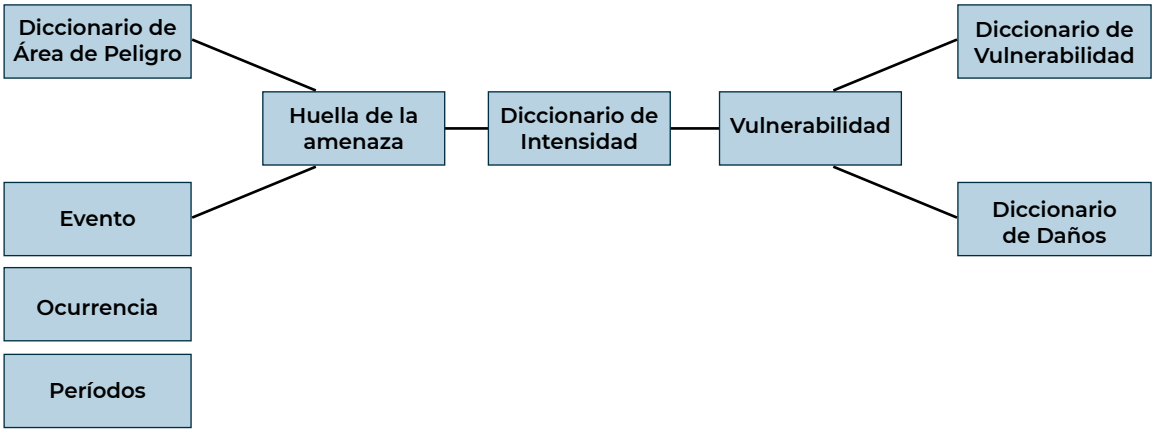
Empresa grande: alrededor de **$930,000**

Los modelos pueden ser utilizados gratuitamente como Modelos de Acceso Abierto cuando se alojan internamente en el servidor AWS de Oasis. La oferta de modelos disponibles está en constante expansión según la demanda y los requisitos. Los modelos iniciales disponibles incluyen los modelos de riesgo sísmico a nivel país para Colombia, Sudafrica y China desarrollados por la Fundación GEM (Global Earthquake Model) y el CHAZ (Modelo de Riesgo Climático) de la Universidad de Columbia.

A.5.2. Métodos aplicados

Un modelo en Oasis está compuesto por los módulos de amenaza y de vulnerabilidad. Estos módulos se relacionan mediante una métrica común de intensidad y se conectan con los datos de exposición a través de un conjunto de identificadores abstractos: areaperil_id y vulnerability_id. La **Figura 46** muestra la forma en la que los módulos de amenaza y vulnerabilidad se conectan en un modelo en Oasis (Oasis 2024b).

Figura 46. Conexión de los módulos de amenaza y vulnerabilidad



Fuente: OASIS (2024a).

El Módulo de Amenaza en Oasis se basa en el archivo *Footprint*, que describe la interacción entre eventos y áreas de amenaza, proporcionando una distribución de probabilidad de intensidad para cada combinación.

El área de amenaza representa de forma abstracta una zona específica para una amenaza determinada. Puede ser cualquier tipo de área (celdas de una cuadrícula, polígonos, regiones administrativas, etc.). El areaperil_id es el identificador del área y debe ser un valor entero, aunque lo que representa no afecta al cálculo en Oasis.

El evento es una representación abstracta de un evento real o sintético que afecta múltiples áreas de amenaza. Puede ser una inundación, tormenta, terremoto, etc. El event_id es el identificador de evento y es un valor entero.

La intensidad representa un conjunto discretizado y abstracto de medidas de intensidad específicas para la amenaza representada.

El Módulo de Vulnerabilidad en Oasis se centra en el archivo *Vulnerability*, que describe la interacción de las intensidades con tipos de vulnerabilidad, proporcionando una distribución de probabilidad de la Tasa de Daño para cada combinación.

El Diccionario de Vulnerabilidad (Vulnerability Dictionary) representa de forma abstracta varias funciones de vulnerabilidad. El vulnerability_id es el identificador y es simplemente un valor entero que representa esa función de vulnerabilidad.

El Daño (Damage) representa un conjunto discretizado y abstracto de tasas de daño.
La parte final de la definición de datos del modelo en Oasis es el archivo de Ocurrencias. Este archivo

detalla las ocurrencias de eventos a lo largo del tiempo y se usa en resultados basados en el tiempo. Una extensión opcional del archivo de Ocurrencias es el archivo de Periodos, que permite asignar un peso a las ocurrencias.

El módulo de amenaza, el módulo de vulnerabilidad y las definiciones de ocurrencias, se combinan utilizando una definición común de intervalos de intensidad para crear una representación completa de un modelo en Oasis.

La UI de Oasis permite al usuario generar múltiples informes de salida. El núcleo de Oasis utiliza una simulación de Monte Carlo que toma muestras aleatorias de la distribución de pérdidas. La cantidad de muestras es definida por el usuario, y el nivel de convergencia alcanzado dentro de ese conjunto de muestras variará según el modelo, el portafolio y los resultados requeridos.

El cálculo de pérdidas se compone de dos pasos: 1) cálculo de distribuciones de probabilidad y 2) método de muestreo.

Los archivos de entrada del modelo para esta etapa del cálculo son:

- *footprint*
- *vulnerability*

La incertidumbre de la intensidad de amenaza se representa en los datos de *footprint,* y la incertidumbre de daño dada la intensidad de la amenaza se representa en los datos de *vulnerability*. Ambos tipos de incertidumbre están expresados como distribuciones de probabilidad discretas.

El daño efectivo se calcula durante un análisis combinando (*convolving*) la distribución de intensidad de la amenaza con la distribución de daño condicional. En el caso general, la distribución de daño efectivo calculada representa tanto la incertidumbre en la intensidad de la amenaza como en el nivel de daño dado esa intensidad.

Sin embargo, es común en algunos modelos que la distribución de incertidumbre de la amenaza no esté presente en el *footprint*. En estos casos, cada *areaperil* (que representa un área o celda geográfica) en el *footprint* se asigna a un solo rango de intensidad de amenaza con una probabilidad establecida en 1. Aquí, la distribución de daño efectivo aún se genera, pero es idéntica a la distribución de probabilidad de daño condicional en el archivo de *vulnerability* para un solo rango de intensidad.

Con este método, siempre se toma una muestra de la distribución de daño efectivo; sin embargo, las fuentes de incertidumbre representadas pueden ser solo de daño o una combinación de incertidumbre en la intensidad de amenaza y daño, según los archivos del modelo.

Los métodos de Monte Carlo son una amplia clase de algoritmos computacionales que dependen de un muestreo aleatorio repetido para obtener resultados numéricos. El *kernel* de Oasis (ktools) realiza un muestreo de Monte Carlo de pérdidas brutas a partir de distribuciones de probabilidad de daño efectivo mediante la generación de números aleatorios.

La distribución de probabilidad es proporcionada por el cálculo de daño efectivo descrito anteriormente, y los intervalos de daño son suministrados por un tercer archivo de entrada del modelo, el diccionario de daños.

A.5.3. Enfoque matemático

En el proceso de cálculo de riesgo en Oasis LMF, el primer paso es generar un conjunto de eventos representativo de todos los posibles eventos que pueden ocurrir, junto con su intensidad y probabilidad durante un período de tiempo suficientemente largo como para abarcar una distribución completa, incluso de los eventos más extremos. Se suele utilizar una simulación de 10,000 años. Cada evento tiene una probabilidad de ocurrir dentro del período simulado (Oasis LMF 2024).

Para cada evento, se genera una huella de amenaza (*footprint*), que contiene un indicador de amenaza (intensidad, por ejemplo, velocidad del viento, profundidad de inundación, etc.) adecuado que se relaciona con los daños a través de una curva de vulnerabilidad (Oasis LMF 2024).

Las curvas de vulnerabilidad vinculan el indicador de amenaza con un índice de daño promedio (MDR, por sus siglas en inglés), que es la proporción del valor total (por ejemplo, en términos del costo de reemplazo) que se perdería para el activo analizado. En la práctica, los elementos expuestos muestran una alta variabilidad en los daños causados por la misma amenaza debido a muchos factores desconocidos y no modelables, incluso cuando se encuentran muy cerca unos de otros. Esto se tiene en cuenta mediante una distribución de incertidumbre alrededor del índice de daño promedio en cada punto de amenaza, también conocida como incertidumbre secundaria (Oasis LMF 2024).

El cálculo de pérdidas es la parte más importante del núcleo de herramientas *ktools* de Oasis LMF. Para este cálculo, las probabilidades definidas en los archivos de huella de amenaza (*footprint*) y vulnerabilidad se utilizan en conjunto. Estas probabilidades se representan con subíndices i y d para indicar que la incertidumbre radica en la intensidad y en el daño, respectivamente (Blass 2021):

Ecuación 14

$$P_{id} = p^{f}_{i} * p^{v}_{d}$$

Donde:

P_{id} es la probabilidad de que ocurra una intensidad i y cause un daño d.
p^f_i es la masa de probabilidad para el intervalo de intensidad.
p^v_d es la masa de probabilidad para el intervalo de daño.

Este cálculo de P_{id} se realiza para cada combinación de evento, área de amenaza (peril) y función de vulnerabilidad. Luego, P_{id} se suma a través de los intervalos de intensidad:

Ecuación 15

$$P_d = \sum_i P_{id}$$

Esto da como resultado P_d, que es la probabilidad de un intervalo de daño d para cada evento, área de amenaza y función de vulnerabilidad.

Dado que la distribución de probabilidad es discreta, los valores pueden sumarse para construir una función de distribución acumulativa (CDF), lo cual se realiza en el ejecutable *getmodel*. Esta sumatoria sobre los intervalos de intensidad y daño genera una CDF para cada combinación de evento, área de amenaza y vulnerabilidad.

Existen dos enfoques posibles para calcular las pérdidas (Blass 2021):

1. Integración Determinística

En este método, la distribución de probabilidad de daño calculada se integra para obtener el denominado factor de daño. Este factor, multiplicado por el valor total asegurado, da como resultado la pérdida:

Ecuación 16

$$\chi_{E\gamma} = tiv_\gamma * d_{E\gamma}$$

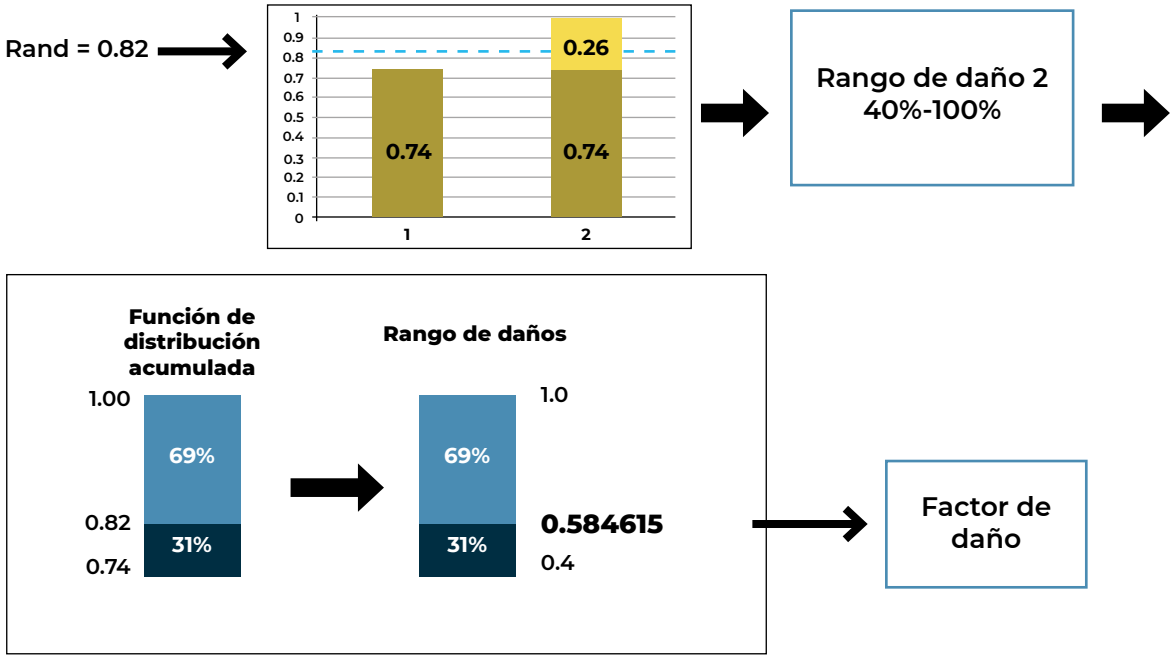
Donde:
$\chi_{E\gamma}$ es la pérdida en un evento ε y cobertura γ.
tiv_γ es el valor total asegurado.
$d_{E\gamma}$ es el factor de daño.

Este método no proporciona una desviación estándar, ya que la integración no permite cálculos de incertidumbre.

2. Muestreo Aleatorio (Monte Carlo)

En este método, se sigue el mismo proceso hasta el cálculo de la CDF. Luego, en lugar de integrar, se utiliza un generador de números aleatorios para seleccionar un valor entre 0 y 1. Como se ilustra en la **Figura 47**, si el número aleatorio generado es 0.82, este se ubica en un intervalo de daño específico (por ejemplo, el intervalo 2). Posteriormente, dentro de ese intervalo, se calcula una proporción específica (por ejemplo, 31%), lo que da como resultado un factor de daño (0.584615 en el ejemplo). A través de este proceso, se selecciona un valor de daño dentro de un rango de posibles valores en el muestreo. Finalmente, al igual que en la ecuación anterior, multiplicando este factor por el valor total asegurado se obtiene la pérdida correspondiente a esta muestra.

Figura 47. Ilustración Gráfica del Enfoque de Muestreo en el Cálculo de Pérdidas



Fuente: Blass (2021) Se selecciona un número aleatorio, el cual se utiliza para muestrear la función de distribución acumulativa (CDF). Esto permite determinar el intervalo de daño correspondiente. Luego, aplicando la misma proporción dentro de ese intervalo de daño, se obtiene el factor de daño de la muestra.

El módulo financiero calcula las pérdidas después de considerar el impacto de las condiciones de las pólizas de las compañías de seguros para proporcionar la pérdida neta que la entidad (re)aseguradora será responsable de cubrir. La compañía de (re)aseguro introduce una lista de todas las pólizas que ha suscrito con información sobre la ubicación y características del riesgo, como el tipo de ocupación, la antigüedad, el material de construcción, la altura del edificio y el costo de reemplazo, así como los términos y condiciones de la póliza. El modelo de catástrofe ejecuta entonces todo el conjunto

de eventos a través del portafolio y calcula la pérdida de cada evento en el modelo para cada póliza. Esto genera una tabla de pérdidas por evento. Estas pérdidas por evento luego se ordenan según su magnitud de mayor a menor para generar la Curva de Excedencia de Pérdidas para los años simulados por el modelo (Oasis LMF 2024).

A.5.4. Avances recientes e innovaciones

En los últimos años, Oasis ha trabajado en la estandarización de datos abiertos para mejorar la interoperabilidad y eficiencia en la industria de seguros. También han lanzado el Oasis Risk Explorer, una herramienta de modelación de riesgos para productos de seguros paramétricos, especialmente diseñada para países vulnerables de bajos ingresos. Además, el software Enterprise Oasis está en las etapas finales de prueba. Esta herramienta permitirá la distribución de trabajo en múltiples máquinas en la nube, reduciendo significativamente los tiempos de ejecución de modelos complejos.

A.5.5. Comunidad de desarrollo

Oasis es apoyado por una comunidad diversa que incluye desarrolladores de modelos independientes, aseguradoras, reaseguradoras, corredores y gobiernos. La plataforma se financia a través de cuotas de suscripción de miembros y comisiones sobre los modelos licenciados. Además, colaboran con diversas organizaciones como el Foro de Desarrollo de Seguros (IDF) y el UNISDR en iniciativas de interoperabilidad y proyectos de exposición global (Oasis 2024b). El repositorio de GitHub es: https://github.com/OasisLMF.

A.5.6. Limitaciones

Aunque Oasis permite una gran flexibilidad y acceso a modelos de catástrofes, tiene costos asociados que vienen del uso de los modelos que son proporcionados por diferentes empresas.

A.5.7. Casos de uso

Oasis se utiliza ampliamente en la industria de seguros y reaseguros para evaluar riesgos de catástrofes y desarrollar productos de seguros paramétricos. Un caso notable es el uso de modelos condicionados por el clima, como el modelo del Danubio desarrollado por el Instituto de Potsdam, y otros modelos similares creados por JBA y Fathom. Estos modelos ayudan a las aseguradoras a comprender mejor el impacto del cambio climático en los riesgos catastróficos. La **Caja 6** muestra un estudio de caso en el que se utilizó tanto CLIMADA como Oasis.

Caja 6. Ejemplo de aplicación de Oasis

Caso de Estudio: Huracán Matthew


Imagen: Adobe Stock

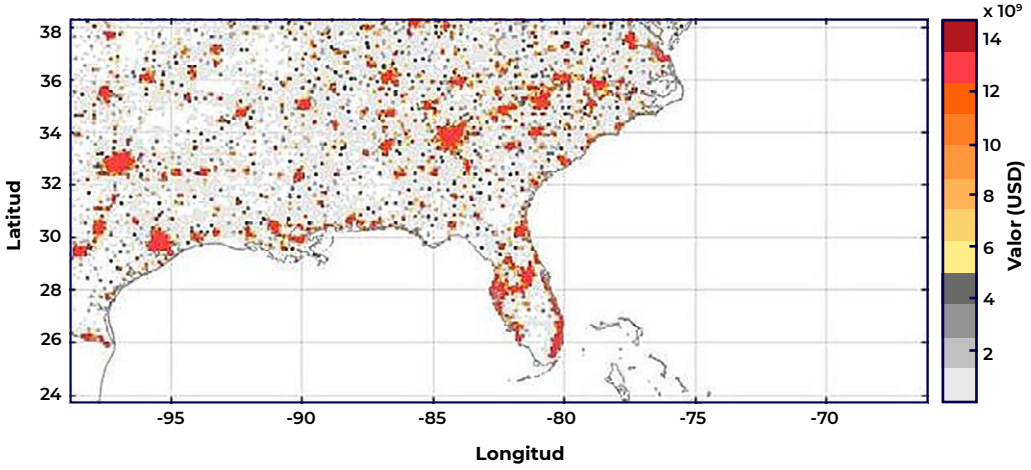
Este estudio de caso examina los impactos de los diferentes parámetros utilizados en modelos de pérdida aplicados al huracán Matthew, utilizando datos de pronóstico del ECMWF y las herramientas de código abierto CLIMADA y Oasis LMF. El análisis evalúa la influencia de variables como el radio de vientos máximos (RMW), los valores de activos y la curva de vulnerabilidad sobre las estimaciones de pérdida.

La evaluación utilizó pronósticos del huracán Matthew para tres fechas distintas (29 de septiembre, 4 de octubre y 7 de octubre de 2016), analizando la trayectoria e intensidad en relación con los daños estimados. Se realizaron pruebas variando el RMW, redistribuyendo los valores de activos y alterando la forma de la curva de vulnerabilidad. También se consideró la implementación de una distribución beta para modelar incertidumbres secundarias.

La modificación del RMW llevó a resultados similares a los de la función original, pero con un leve aumento en los valores. Para el pronóstico del 4 de octubre, el impacto del aumento del radio a 370 km fue menor que el observado en pronósticos anteriores. Para el pronóstico del 7 de octubre, la influencia de un RMW fijo de 3 km fue significativamente mayor, con una reducción de pérdidas en tres órdenes de magnitud, mientras que un RMW de 370 km aumentó las pérdidas en dos órdenes de magnitud. El análisis reveló que la proximidad de las trayectorias a la costa de EE. UU., donde los activos están concentrados, amplifica las pérdidas.

Los resultados confirman que el RMW está directamente relacionado con la intensidad de los ciclones tropicales. Estudios previos (Emanuel, 1989; Carrasco et al., 2014) corroboran la correlación negativa entre el tamaño del ojo del ciclón y su intensificación. Por ejemplo, ciclones compactos, como el huracán Matthew en sus etapas iniciales, exhiben una mayor intensificación debido al RMW reducido.

Los valores de activos en CLIMADA se basan en imágenes satelitales de luz nocturna ajustadas al PIB y redistribuidos según la densidad poblacional (ver la siguiente figura). Cuando se probaron con valores promedio redistribuidos, las pérdidas disminuyeron ligeramente debido a la reducción de valores en regiones de alta densidad y el aumento en áreas menos densas. Este efecto fue particularmente evidente al implementar un RMW de 3 km, disminuyendo aún más las pérdidas debido a la menor probabilidad de impactar áreas densamente pobladas.



La curva estándar de CLIMADA es una función logística con un máximo del 40%. Las pruebas con funciones lineales y escalonadas mostraron resultados con alta variabilidad. La función lineal aumentó las pérdidas debido a la inclusión de daños en velocidades más bajas, mientras que la función escalonada redujo las pérdidas, restringiendo daños a velocidades superiores a 80 m/s. Para los pronósticos del 29 de septiembre y 4 de octubre, la función escalonada no resultó en pérdidas, dada la baja intensidad del huracán.

Entre los parámetros probados, el RMW presentó el mayor impacto en las pérdidas. Las trayectorias influyen significativamente en los resultados, especialmente en pronósticos como el del 29 de septiembre, donde la mayoría de los ciclones afectan al Caribe, resultando en menores pérdidas. El aumento del RMW incrementa la probabilidad de impactar áreas de mayor valor, amplificando las pérdidas. Por otro lado, la redistribución de activos reduce las pérdidas totales al redistribuir los valores de forma más uniforme.

Este estudio confirma que el RMW es la variable más crítica en la previsión de pérdidas, directamente correlacionada con la intensidad del ciclón. La integración de los modelos CLIMADA y Oasis LMF demostró ser eficaz, con una fuerte correlación entre los resultados. Mejoras en las previsiones de intensidad y tamaño de los ciclones podrían refinar las estimaciones de pérdida, especialmente con una mayor inclusión de factores ambientales que influyen en el RMW, como la estabilidad inercial y los flujos de entropía en la superficie. Además, la inclusión de factores como el tamaño del núcleo externo de los ciclones ampliaría la comprensión de los impactos asociados, ofreciendo previsiones más amplias y útiles para la mitigación y planificación de riesgos.

Fuente: König (2017).

A.6. INTERDEPENDENT NETWORKED COMMUNITY RESILIENCE MODELING ENVIRONMENT IN-CORE

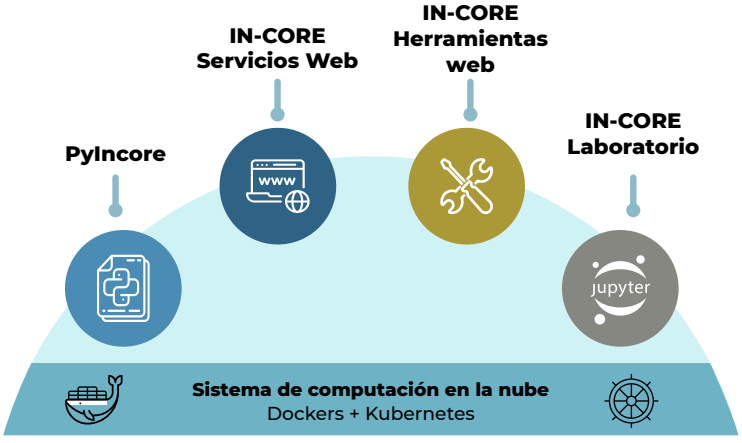
A.6.1. Descripción general

El Interdependent Networked Community Resilience Modeling Environment (IN-CORE) es un software desarrollado por la Universidad Estatal de Colorado para evaluar y mejorar la resiliencia de infraestructuras y comunidades ante desastres. Cualquier amenaza puede ser analizada con tal que pueda representarse como un objeto de amenaza y que sea posible asociar curvas de fragilidad a los elementos expuestos. En la herramienta web *Hazard viewer* es posible observar ejemplos de objetos de amenaza para sismos, tornados, huracanes e inundaciones. IN-CORE integra modelos de simulación y análisis de datos para proporcionar una comprensión integral de cómo diferentes tipos de infraestructura responden ante las amenazas. La plataforma IN-CORE se basa en un clúster de Kubernetes con tecnología de contenedores Docker (IN-CORE 2024).

En la plataforma IN-CORE, los usuarios pueden realizar análisis que modelan el impacto de los desastres y evalúan la resiliencia y recuperación de las comunidades. La plataforma se compone de IN-CORE Lab, pyIncore, herramientas web y servicios web (ver **Figura 48**). Los recursos, como conjuntos de datos de exposición, curvas de fragilidad, archivos de amenazas, entre otros, proporcionados por la comunidad investigadora, se almacenan en los servidores de IN-CORE del National Center for Supercomputing Applications (NCSA) y pueden integrarse de manera fluida para permitir a los usuarios optimizar la planificación de la resiliencia ante desastres en las comunidades y las estrategias de recuperación tras un desastre (IN-CORE 2024).

El usuario debe tener una cuenta de IN-CORE reconocida por el servicio de IN-CORE. Esta cuenta le permite acceder a todos los datos públicos del sistema y crear datos que solo serán accesibles para él.

Figura 48. Componentes de IN-CORE



Fuente: IN-CORE (2024).

PyIncore es un paquete de Python que consta de tres componentes principales: 1) un conjunto de clases de servicio para interactuar con los servicios web IN-CORE que se describen a continuación, 2) análisis IN-CORE y 3) visualización. PyIncore permite a los usuarios analizar el riesgos para la infraestructura en áreas seleccionadas, propagando el efecto del daño físico de la infraestructura y la pérdida de funcionalidad a los impactos sociales y económicos.

Los **servicios web IN-CORE** están escritos en Java con la especificación JAX-RS y están compuestos por un servicio de amenazas, un servicio DFR3 (daños, funcionalidad, reparación, recuperación y restauración), un servicio de datos, un servicio de visualización geoespacial, un servicio semántico y un servicio espacial. Estos servicios permiten a los usuarios crear y acceder a amenazas, fragilidades y datos. Los usuarios pueden acceder y utilizar estos servicios a través de pyIncore y las herramientas web IN-CORE.

IN-CORE Web Tools es un conjunto de visualizadores web para interactuar con los diferentes servicios web de IN-CORE. Los visualizadores permiten a los usuarios navegar, buscar conjuntos de datos, amenazas, curvas de fragilidad, curvas de reparación, etc., ver los metadatos y las visualizaciones, y descargar elementos permitidos.

IN-CORE Lab es un laboratorio Jupyter personalizado con pyIncore instalado y alojado en un sistema de nube de NCSA. Permite a los usuarios desarrollar, ejecutar y probar su modelo científico con pyIncore en su propio espacio de trabajo.

La plataforma IN-CORE puede incorporar datos generados por comunidades, lo que permite a los usuarios optimizar la planificación de la resiliencia comunitaria ante desastres y las estrategias de recuperación posterior al desastre de manera inteligente utilizando modelos de sistemas físicos interdependientes combinados con sistemas socioeconómicos.

Los recursos como los conjuntos de datos de inventario, las fragilidades, los archivos de amenazas, etcétera, proporcionados por la comunidad de investigación se almacenan en los servidores IN-CORE de NCSA y pueden integrarse sin problemas para permitir a los usuarios optimizar la planificación de la resiliencia ante desastres de la comunidad y las estrategias de recuperación posterior al desastre.

Para usar IN-CORE y pyIncore, se requiere instalar Miniconda, una herramienta para gestionar entornos de Python, y luego instalar Jupyter Notebook y la biblioteca pyIncore.

El paquete de visualización asociado con pyIncore se llama pyIncore-viz. Contiene paquetes avanzados de Python y métodos necesarios para visualizar y difundir los resultados de IN-CORE, principalmente a través de Jupyter Notebooks. La librería Matplotlib, utilizada para crear visualizaciones estáticas en Python, ya forma parte de pyIncore como dependencia.

A.6.2. Métodos aplicados

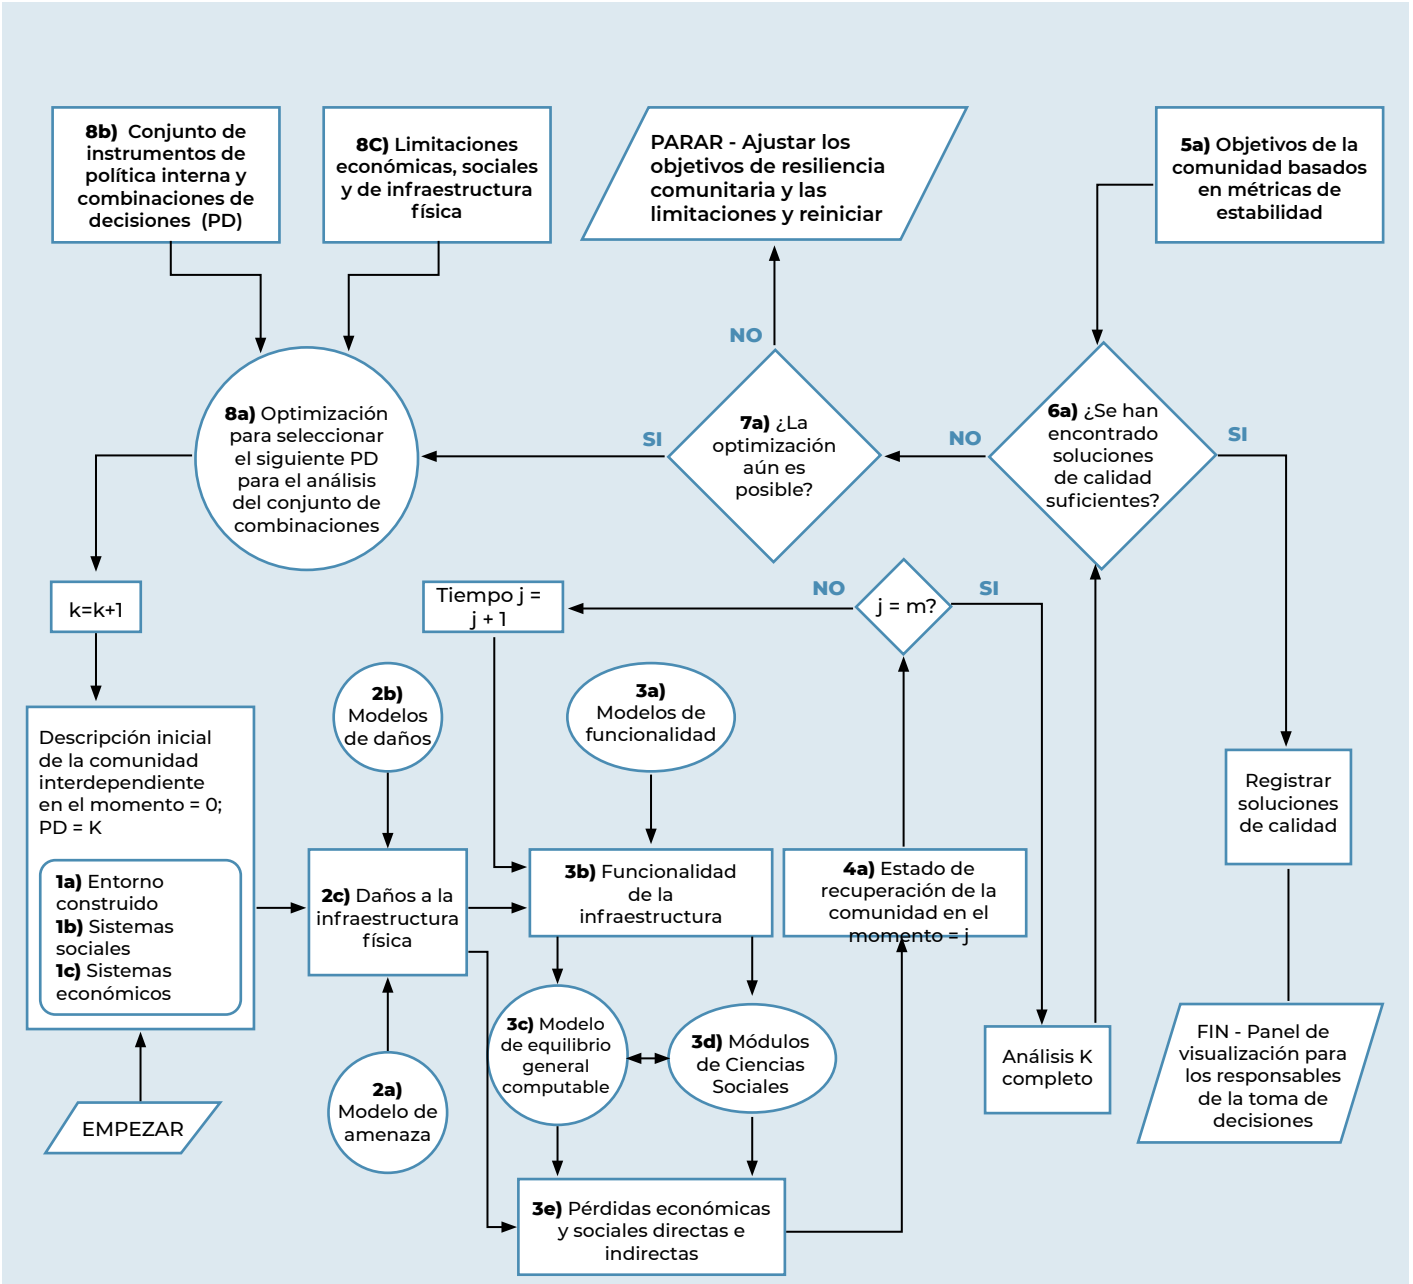
IN-CORE utiliza los siguientes pasos en los análisis de resiliencia: (1) caracterizar el estado actual de una comunidad, incluidas sus vulnerabilidades; (2) simular escenarios de amenaza y los impactos resultantes en los sistemas comunitarios (daños, desplazamiento de la población, pérdida de funciones y recuperación de funciones) para explorar opciones de políticas que mejoren la resiliencia; y (3) el cálculo de estabilidad comunitaria (CSA, por sus siglas en inglés) basada en métricas de resiliencia comunitaria (CRM, por sus siglas en inglés) para las funciones físicas, sociales y económicas de una comunidad que proporcionan indicadores de resiliencia en un momento dado en relación con los objetivos de resiliencia (van de Lindt et al. 2023).

Los algoritmos científicos implementados en IN-CORE se muestran en el diagrama de flujo conceptual de la **Figura 49**, gran parte del cual se completó durante los primeros cinco años de desarrollo (van de Lindt et al. 2023).



Imagen: Flickr - BID Ciudades sostenibles / Santa Marta, Colombia

Figura 49. Diagrama de flujo conceptual de los algoritmos de IN-CORE



Fuente: van de Lindt et al. (2023).

El sistema IN-CORE se organiza en varios módulos interdependientes que permiten describir, analizar y planificar la resiliencia de una comunidad, integrando información de infraestructuras, sistemas sociales y económicos. El módulo de Descripción de la Comunidad Interdependiente, que se ubica en la parte inferior izquierda de la **Figura 49**, está compuesto por tres componentes clave: el entorno construido, los sistemas sociales y los sistemas económicos. El componente de entorno construido reúne datos espaciales generalmente en formato de sistemas de información geográfica (GIS), que incluyen huellas de edificios, infraestructura como redes de electricidad, agua y gas, y la red de transporte. Este módulo describe cómo estas infraestructuras se interrelacionan con los edificios, facilitando la conexión entre los diferentes sistemas de la comunidad. Los sistemas sociales, por su parte, incluyen datos sobre la población y los hogares, que se asignan a edificios específicos, proporcionando información detallada sobre características demográficas como edad, sexo, educación, y ocupación, y vinculando a las personas con instituciones sociales y lugares de trabajo. Estos datos provienen de diversas fuentes públicas, como el Censo de los Estados Unidos y el American Community Survey. El componente de Sistemas Económicos describe la distribución espacial de los trabajos y las industrias, y utiliza modelos de equilibrio general computable (CGE) para simular cómo interactúan los hogares, las empresas y el gobierno local para generar actividad económica. Este modelo considera datos sobre ingresos, distribución laboral e indicadores de la fuerza laboral, proporcionando un panorama integral de la economía local.

En cuanto al daño a la infraestructura física, el módulo de Daño a la Infraestructura Física combina los datos del entorno construido con los modelos de amenaza y los modelos de daño para evaluar cómo los desastres afectan las infraestructuras. Los modelos de amenaza pueden ser de dos tipos: Tier 1, que simulan amenazas como sismos, huracanes, inundaciones y tornados usando conjuntos de datos contenidos en IN-CORE, y Tier 2, que permiten simulaciones más avanzadas en donde las amenazas son suministradas por el usuario. Estos modelos utilizan funciones de fragilidad para estimar el daño esperado en función de la intensidad de la amenaza. El proceso también puede tener cuenta los daños causados por fenómenos en cascada, como la interacción entre viento y marejada en huracanes o el daño por sismo y tsunami.

El módulo de Funcionalidad de la Infraestructura Física evalúa la capacidad de los edificios y otros componentes de infraestructura para seguir funcionando tras un desastre, según el nivel de daño sufrido. Esta evaluación se realiza utilizando modelos de funcionalidad que determinan si un edificio o infraestructura puede seguir desempeñando su función prevista. Estos modelos pueden ser definidos por el usuario y consideran la disponibilidad de servicios esenciales como agua y electricidad. Los resultados de este análisis se utilizan en el modelo CGE para estimar los impactos económicos de los daños, considerando la condición de los edificios y la infraestructura funcional, así como los datos sociales y económicos.

El módulo de Recuperación de la Comunidad analiza cómo se recupera la comunidad a lo largo del tiempo, evaluando tanto la recuperación física de los edificios como la restauración de la estabilidad social y económica. Se utiliza un enfoque basado en modelos de recuperación de viviendas y otras infraestructuras, que considera las políticas de financiación y las estadísticas de recuperación. Este

análisis permite seguir la evolución de la recuperación en diferentes áreas de la comunidad y ajustar las estrategias de intervención en función del progreso.

Finalmente, el módulo de Soluciones y Optimización permite evaluar la efectividad de diferentes políticas de resiliencia. Este módulo compara diversas estrategias de mitigación y respuesta a desastres, considerando las limitaciones financieras y sociales de la comunidad. A través de este análisis, IN-CORE ayuda a los responsables de la toma de decisiones a identificar las mejores opciones para mejorar la resiliencia de la comunidad, ya sea mediante la mitigación de riesgos o la mejora de la capacidad de respuesta ante un desastre. Las salidas del sistema proporcionan información valiosa para optimizar el uso de los recursos disponibles y desarrollar estrategias eficaces para la resiliencia.

Además, IN-CORE tiene la capacidad de propagar la incertidumbre en las predicciones sobre las características de los hogares a nivel de edificio, así como en las predicciones sobre la estabilidad de la población. La incertidumbre se propaga mediante simulación de Monte Carlo (MCS), lo que permite al analista obtener realizaciones de la amenaza, la asignación de la población sintética a un hogar o cualquier otro análisis, siempre que se conozcan las estadísticas subyacentes (van de Lindt et al. 2023).

Los Análisis incorporados en la plataforma se resumen en la **Tabla 38**.

Tabla 38. Análisis incorporados en la plataforma IN-CORE

Tipo de Análisis	Descripción
Daño en puentes	Este análisis calcula el daño en puentes basado en un tipo específico de amenaza. Actualmente, se admiten terremotos, tsunamis, tornados y huracanes. El proceso de cálculo del daño estructural es similar al de otras infraestructuras. Primero, se obtiene una curva de fragilidad según el tipo de amenaza y las características del puente. Con la fragilidad, se calcula la intensidad de la amenaza en la ubicación del puente. Con esta información, se determina la probabilidad de exceder cada estado límite y la probabilidad de daño. En el caso de terremotos, si el conjunto de datos del puente incluye información del suelo, el valor medio de la fragilidad puede ajustarse para considerar la licuefacción en el daño. Los resultados de este análisis son un archivo CSV con las probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Recuperación de Conjuntos de Edificios	El código genera dos archivos de salida: building-recovery.csv y cluster-recovery.csv.
Daño en edificios	Este análisis calcula el daño en edificios en función de un tipo específico de amenaza. Actualmente, se admiten terremotos, tsunamis, tornados, huracanes e inundaciones. El proceso de cálculo del daño estructural es similar al de otras infraestructuras. Primero, se obtiene una curva de fragilidad basada en el tipo de amenaza y las características del edificio. Con esta fragilidad, se calcula la intensidad de la amenaza en la ubicación del edificio. A partir de esta información, se determina la probabilidad de exceder cada estado límite y la probabilidad de daño. En caso de un terremoto, se puede usar la información del suelo para ajustar las probabilidades de daño y considerar los efectos de la licuefacción. Los resultados de este análisis son un archivo CSV con las probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Pérdida Económica en Edificios	Este análisis calcula la pérdida económica en edificios basada en el valor de tasación del edificio, el daño medio y un multiplicador de inflación. El usuario debe proporcionar la tasa de inflación (como porcentaje) entre el año de tasación y el año de interés (actual, fecha del evento, etc.), así como un multiplicador opcional de ocupación. El análisis puede aplicarse a resultados de daño medio del edificio para componentes estructurales, no estructurales sensibles al desplazamiento, no estructurales sensibles a la aceleración o daños en contenidos. El resultado de este análisis es un archivo CSV con las pérdidas estructurales basadas en el daño.
Funcionalidad de Edificios	El análisis de funcionalidad de edificios calcula las probabilidades de funcionalidad considerando dos situaciones: que los edificios se encuentren al menos en un estado de daño 2 o mayor, o que los edificios no estén dañados, pero no tengan acceso a energía eléctrica. Se asume que la disponibilidad de energía eléctrica depende de la interdependencia entre edificios y subestaciones, y entre edificios y postes cercanos. Si tanto el poste más cercano al edificio como la subestación de la que depende están funcionales, se considera que el edificio puede recibir energía eléctrica. Los resultados de este análisis son: 1) un archivo CSV con muestras de probabilidades de funcionalidad para comparación directa con salidas de probabilidad de estado límite de Monte Carlo y 2) un archivo CSV con probabilidades de funcionalidad

Tipo de Análisis	Descripción
Daño No Estructural en Edificios	Este análisis calcula el daño no estructural en edificios basado en un tipo específico de amenaza. Actualmente, se admiten terremotos, inundaciones y huracanes. El proceso es similar a la evaluación de otros daños estructurales. Las probabilidades de daño se obtienen mediante curvas de fragilidad y una definición de amenaza. Cada sitio de edificio tendrá un PGA (aceleración máxima del suelo), una medida de la amenaza de terremoto para cada escenario. También se puede considerar el efecto de licuefacción, definido como un cambio en las condiciones de esfuerzo en el cual un material que normalmente es sólido se comporta como un líquido. Los valores del Factor de Modificación de Licuefacción (LMF) se implementan como factores de multiplicación para los valores medios de fragilidad y deben estar presentes en el conjunto de datos. Este análisis puede incluir varios tipos de curvas de fragilidad asignadas al edificio: sensibles a la aceleración (AS) y sensibles al desplazamiento (DS). El código cubre fragilidades normales y lognormales con 3 estados límite y genera un archivo CSV de salida con los estados de daño correspondientes. El segundo archivo de salida es un JSON con información sobre la amenaza y las fragilidades
Daño Estructural en Edificios	Este análisis calcula el daño estructural en edificios en función de un tipo específico de amenaza. Actualmente, se admiten terremotos, tsunamis, tornados, huracanes e inundaciones. El proceso de cálculo del daño estructural es similar al de otras infraestructuras. Primero, se obtiene una curva de fragilidad según el tipo de amenaza y las características del edificio. A partir de esta fragilidad, se calcula la intensidad de la amenaza en la ubicación del edificio. Con esta información, se determina la probabilidad de exceder cada estado límite y la probabilidad de daño. En el caso de un terremoto, se puede utilizar información del suelo para ajustar las probabilidades de daño y considerar los efectos de licuefacción. Los resultados de este análisis son un archivo CSV con las probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Decisión de Compra de Propiedades	Este análisis ayuda a identificar propiedades candidatas para compra y permite a los profesionales e investigadores evaluar los posibles resultados de equidad de su selección bajo diferentes escenarios. El resultado de este análisis es un archivo CSV con los edificios que deben considerarse para compra según los criterios establecidos. Esto puede ayudar a los profesionales locales a identificar propiedades candidatas para la selección de compra y permite a los profesionales e investigadores evaluar los posibles resultados de equidad de su selección.
Choques de Capital	Este análisis agrega los estados de funcionalidad de los edificios y calcula las pérdidas totales de capital por sector. El choque del stock de capital para un edificio individual es igual a la probabilidad de funcionalidad multiplicada por el valor del edificio. Esto da la pérdida del stock de capital en el inmediato aftermath de un desastre. El análisis agrupa cada una de estas pérdidas individuales según su sector económico asociado y calcula la pérdida total del stock de capital para ese sector en particular. El resultado de este análisis es un archivo CSV con las pérdidas de edificios agregadas por sector y la pérdida total calculada del stock de capital.
Daño Combinado de Edificios por Viento, Oleaje y Marejada	Este análisis determina el estado máximo de daño general de los edificios debido a los daños por viento, inundación y oleaje. Los resultados de este análisis son un archivo CSV con el estado máximo de daño de cada amenaza y el daño máximo general, así como un archivo CSV con las probabilidades de daño combinadas de las tres amenazas.

Tipo de Análisis	Descripción
Pérdida Combinada de Edificios por Viento, Oleaje y Surge	Este análisis determina la pérdida total de edificios debido a los daños por viento, inundación y oleaje. El resultado de este análisis es un archivo CSV con los componentes individuales de pérdida estructural y de contenido, así como la pérdida total.
Recuperación de Edificios Comerciales	Este análisis calcula el tiempo de recuperación necesario para cada edificio comercial desde cualquier estado de daño hasta su restauración completa. Actualmente, se admiten tornados como amenaza. La metodología incorpora un enfoque de simulación de Monte Carlo en múltiples capas y determina el tiempo de recuperación en dos etapas, que incluye el retraso y la reparación. El modelo de retraso fue modificado según el marco REDi y calcula los resultados finales derivados de factores que impiden la recuperación, como la inspección posterior al desastre, las reclamaciones de seguros, el financiamiento y los permisos gubernamentales. El modelo de reparación sigue el enfoque FEMA P-58 y está controlado por funciones de fragilidad. El resultado de este análisis es un archivo CSV con probabilidades de recuperación por etapas a nivel de edificio.
Daño Acumulado en Edificios	Este análisis calcula el daño en los edificios basado en un tipo específico de amenaza. El proceso para calcular el daño estructural se realiza externamente y los resultados para terremotos y tsunamis se importan al análisis. Luego, se calculan los intervalos de daño a partir de los estados límite combinados. El resultado de este análisis es un archivo CSV con las probabilidades de daño.
Daño a las Instalaciones de Energía Eléctrica	Este análisis calcula el daño a las instalaciones de energía eléctrica en función de un tipo específico de amenaza. Actualmente, las amenazas admitidas son: terremoto, tsunami, tornado y huracán. El proceso para calcular el daño estructural es similar al de otras infraestructuras. Primero, se obtiene una fragilidad según el tipo de amenaza y las características de la instalación de energía eléctrica. A partir de esta fragilidad, se calcula la intensidad de la amenaza en la ubicación de la instalación. Con esta información, se determina la probabilidad de exceder cada estado límite y la probabilidad de daño. En el caso de un terremoto, se puede usar información del suelo para modificar las probabilidades de daño e incluir los efectos de licuefacción. Los resultados de este análisis son un archivo CSV con las probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Costo de Reparación de Instalaciones de Energía Eléctrica	Este análisis estima los costos de reparación de las instalaciones de energía eléctrica para diferentes escenarios de simulación, basándose en sus estados de daño, costos de reemplazo y ratios de daño.
Restauración de Instalaciones de Energía Eléctrica	Este análisis calcula el tiempo de reparación y el cambio porcentual en la funcionalidad de una instalación de energía eléctrica a lo largo del tiempo, basado en curvas de restauración de entrada. Las curvas de restauración se obtienen según el tipo de amenaza y la clase de la instalación eléctrica, por ejemplo, subestaciones de baja tensión, plantas de energía grandes, etc. Con base en la curva de restauración aplicable, se puede obtener el porcentaje de cambio en la funcionalidad a medida que varía el tiempo; también se puede calcular el tiempo de reparación en diferentes niveles de cambio porcentual en la funcionalidad invirtiendo la función de restauración.

Tipo de Análisis	Descripción
Análisis de Funcionalidad de Redes de Energía Eléctrica (EPN)	Este análisis calcula la funcionalidad de las redes de energía eléctrica. El cálculo utiliza entradas de un análisis de fallos Monte Carlo, utilizando información sobre el daño de las instalaciones de energía eléctrica, así como la topología de la red de líneas eléctricas, para determinar la probabilidad de funcionalidad y los estados de fallo de la red de instalaciones eléctricas correspondiente mediante un análisis de accesibilidad. El resultado del análisis consiste en un archivo CSV con las probabilidades de funcionalidad para las instalaciones eléctricas y un archivo CSV con los estados de fallo de la funcionalidad.
Métrica de Equidad	El algoritmo calcula métricas de equidad para caracterizar la desigualdad en la provisión de servicios de infraestructura entre dos grupos de interés (por ejemplo, ingresos bajos frente a ingresos no bajos, minorías frente a no minorías, etc.). Las métricas se basan en el índice T de Theil, un indicador común para medir la desigualdad en la distribución de un recurso escaso (por ejemplo, ingresos). Las métricas también pueden aplicarse para evaluar la inequidad en distintos escenarios con otros recursos de interés. Para calcular las métricas, se define y calcula un recurso escaso en una aplicación de infraestructura. Este recurso puede ser cualquier valor relevante definido por el usuario, como una puntuación de resiliencia (es decir, la probabilidad de provisión de servicios) o el tiempo de recuperación. La herramienta incluye una clase auxiliar donde se define y prepara el tiempo de recuperación como recurso escaso. Otros recursos también pueden explorarse si son proporcionados por el usuario. La métrica de equidad permite evaluar la equidad en la provisión actual de servicios de infraestructura, además de valorar los beneficios de equidad de un plan de renovación específico, y puede integrarse en un proceso general de toma de decisiones. Las métricas de salida proporcionan la siguiente información: 1) Índice T de Theil - cuantificación total de la desigualdad en la distribución del recurso escaso en una comunidad (desigualdad distributiva); 2) Desigualdad Entre Zonas (BZI) - cantidad de desigualdad atribuida a las diferencias de recursos entre grupos (inequidad restaurativa); y 3) Desigualdad Dentro de Zonas (WZI) - cantidad de desigualdad debida a diferencias de recursos dentro de grupos individuales.
Modelo de Equilibrio General Computable (CGE) de Galveston	Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales. Este modelo utiliza múltiples fuentes de datos para reflejar las interacciones entre los hogares, las empresas y las entidades gubernamentales pertinentes que contribuyen a la actividad económica. El modelo se estructura en: (1) hogares que maximizan la utilidad, suministrando trabajo y capital, y usando sus ingresos para pagar bienes y servicios (tanto producidos localmente como importados) y para impuestos; (2) el sector de producción, con empresas perfectamente competitivas que maximizan beneficios utilizando insumos intermedios, capital, tierra y trabajo para producir bienes y servicios para el consumo interno y la exportación; (3) el sector gubernamental que recauda impuestos y usa estos ingresos para financiar servicios públicos; y (4) el resto del mundo. El resultado de este análisis consiste en archivos CSV con información sobre la oferta doméstica, el ingreso bruto, la demanda de factores antes y después de un desastre, y el recuento de hogares.
Daño a Instalaciones de Gas	Este análisis calcula el daño a instalaciones de gas basado en una amenaza específica. Actualmente, la amenaza compatible es terremotos. El proceso para calcular el daño estructural es similar al de otras infraestructuras del entorno construido. Primero, se obtiene una fragilidad basada en el tipo de amenaza y en los atributos de la instalación de gas. Luego, se calcula la intensidad de la amenaza en la ubicación de la instalación. Con esta información, se determina la probabilidad de superar cada estado límite, junto con la probabilidad de daño. En el caso de un terremoto, la información del suelo puede utilizarse para modificar las probabilidades de daño e incluir el daño debido a licuefacción. Los resultados de este análisis incluyen un archivo CSV con las probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.

Tipo de Análisis	Descripción
Recuperación Secuencial de Vivienda a Nivel de Hogar	Este análisis calcula la serie de estados de recuperación de vivienda para cada hogar utilizando un conjunto de datos de desplazamiento poblacional, una matriz de probabilidad de transición (TPM) y un vector de estado inicial. La computación clasifica las unidades familiares en cinco zonas para asignarles una vulnerabilidad social. Usando esta vulnerabilidad junto con la TPM y el vector de estado inicial, un cálculo de cadena de Markov simula los estados más probables, generando un historial de cambios en la recuperación de vivienda para cada hogar. El resultado de la computación es un historial de cambios en la recuperación de vivienda para cada unidad familiar en formato CSV.
Recuperación de Vivienda	El análisis predice los valores de los edificios y los cambios en el valor a lo largo del tiempo tras un evento de desastre. El modelo se calibra en función de datos demográficos, datos de parcelas y trayectorias de valor de los edificios después del huracán Ike (2008) en Galveston, Texas. El modelo predice el valor de los edificios a nivel de parcela durante 8 años de observación. Los modelos dependen de datos censales (Censo Decenal o Encuesta de la Comunidad Americana, ACS) y datos de parcelas previos al evento de desastre (año -1) como insumos para la predicción. El ejemplo de Galveston, TX, utiliza datos del Censo Decenal de 2010, datos del Distrito de Evaluación de Galveston County (GCAD) y resultados de otros análisis (es decir, Daño en Edificios, Asignación de Unidades de Vivienda, Desplazamiento Poblacional). Los resultados en formato CSV contienen los valores de los edificios para los 6 años posteriores al evento de desastre (con el año 0 siendo el año del impacto).
Asignación de Unidades de Vivienda	Este análisis configura un inventario detallado de infraestructura crítica con características a nivel de unidad de vivienda. El proceso alinea el inventario de unidades de vivienda con sistemas físicos, como el inventario de edificios y los nodos de demanda de una red de agua potable. La asignación de unidades de vivienda a los puntos de dirección (edificios) proporciona un marco para contabilizar la incertidumbre en la estructura de la comunidad, lo que permite analizar estadísticamente los impactos de las amenazas. El resultado de este análisis es un archivo CSV con características detalladas de los hogares y unidades de vivienda (número de personas, raza, tipo de tenencia, vacancia) asignadas a unidades habitacionales individuales vinculadas a edificios específicos.
Problema de Diseño de Redes Interdependientes (INDP)	Este análisis utiliza un enfoque descentralizado para resolver el Problema de Diseño de Redes Interdependientes (INDP), una familia de modelos de Programación Entera Mixta (MIP) centralizados, que buscan la estrategia óptima para la restauración de sistemas de redes interdependientes interrumpidos, cumpliendo con restricciones presupuestarias y operativas.
Modelo de Equilibrio General Computable (CGE) de Joplin	Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales y utiliza múltiples fuentes de datos para reflejar las interacciones entre hogares, empresas y entidades gubernamentales relevantes, según contribuyen a la actividad económica. El modelo considera: (1) hogares que maximizan la utilidad, suministrando trabajo y capital para pagar bienes y servicios (producidos localmente o importados) e impuestos; (2) el sector productivo, con empresas competitivas y maximizadoras de beneficios que usan insumos intermedios, capital, tierra y trabajo para producir bienes y servicios para consumo doméstico y exportación; (3) el sector gubernamental, que recauda impuestos y financia servicios públicos; y (4) el resto del mundo. El resultado de este análisis son archivos CSV con la oferta doméstica, ingreso bruto, demanda de factores antes y después del desastre y recuento de hogares.

Tipo de Análisis	Descripción
Modelo Empírico de Restauración de Edificios de Joplin	Este modelo genera una realización aleatoria del tiempo de restauración para un edificio dañado por un tornado, estimando el tiempo necesario para alcanzar un nivel específico de funcionalidad. Los niveles de funcionalidad en este modelo están definidos según Koliou y van de Lindt (2020) y van desde el Nivel de Funcionalidad 4 (FL4, el nivel de funcionalidad más bajo) hasta el Nivel de Funcionalidad 0 (FL0, funcionalidad completa). Las distribuciones empleadas en este código fueron generadas a partir de un conjunto de datos empírico recopilado en un estudio longitudinal de campo después del tornado de 2011 en Joplin, MO. Estas distribuciones representan el tiempo de recuperación de un edificio desde un nivel inicial de funcionalidad hasta un nivel superior (por ejemplo, de FL3 a FL0). El modelo se aplica exclusivamente a los arquetipos T1 a T5, que incluyen solo edificios residenciales según Memari et al. (2018). El resultado del modelo son valores en formato CSV que indican el tiempo de restauración previsto del edificio.
Modelo de Equilibrio General Computable (CGE) Habilitado por Aprendizaje Automático - Joplin	El análisis “Modelo de Equilibrio General Computable (CGE) Habilitado por Aprendizaje Automático - Joplin” combina aprendizaje automático avanzado con modelos tradicionales de CGE para ofrecer perspectivas únicas sobre los impactos económicos de escenarios de desastres en Joplin. Entrenado con un conjunto de datos integral de numerosos desastres simulados y sus efectos económicos, este enfoque híbrido destaca en predecir las dinámicas complejas de la economía de la ciudad en diversas crisis. Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales y utiliza múltiples fuentes de datos para reflejar las interacciones de hogares, empresas y entidades gubernamentales relevantes, que contribuyen a la actividad económica. Este modelo se estructura en torno a: (1) hogares que maximizan su utilidad, ofreciendo trabajo y capital y destinando sus ingresos al pago de bienes y servicios (tanto locales como importados) y a impuestos; (2) el sector productivo, con empresas competitivas y maximizadoras de beneficios que utilizan insumos intermedios, capital, tierra y trabajo para producir bienes y servicios para el consumo nacional y la exportación; (3) el sector gubernamental, que recauda impuestos y financia servicios públicos; y (4) el resto del mundo. Los resultados de este análisis son archivos CSV que incluyen el suministro doméstico, ingresos brutos, demanda de factores antes y después del desastre, y el conteo de hogares.
Machine Learning Enabled Computable General Equilibrium (CGE) - Salt Lake City	El análisis “Machine Learning Enabled Computable General Equilibrium (CGE) - Salt Lake City” combina el aprendizaje automático avanzado con modelos tradicionales de Equilibrio General Computable (CGE) para ofrecer perspectivas sin precedentes sobre los impactos económicos de los escenarios de desastre en Salt Lake City. Entrenado con un conjunto de datos exhaustivo de desastres simulados y sus efectos económicos, este enfoque híbrido destaca en la predicción de las complejas dinámicas de la economía de la ciudad bajo diversas crisis. Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales. Utiliza múltiples fuentes de datos para reflejar las interacciones entre los hogares, las empresas y las entidades gubernamentales relevantes, que contribuyen a la actividad económica. El modelo está basado en los siguientes componentes: • Hogares que maximizan su utilidad y ofrecen trabajo y capital, utilizando los ingresos para pagar bienes y servicios (tanto locales como importados) y impuestos. • El sector de producción, con empresas perfectamente competitivas que maximizan sus beneficios utilizando insumos intermedios, capital, tierra y trabajo para producir bienes y servicios destinados tanto al consumo interno como a la exportación. • El sector gubernamental, que recauda impuestos y utiliza esos ingresos para financiar la provisión de servicios públicos. • El resto del mundo, que interactúa con la economía local. • El resultado de este análisis son archivos CSV que incluyen el suministro doméstico, el ingreso bruto, la demanda de factores antes y después del desastre, así como el conteo de hogares.

Tipo de Análisis	Descripción
Mean Damage	El proceso para calcular el daño estructural utiliza valores de daño medio y desviación estándar a partir de tablas de ratios de daño. Las cuatro probabilidades de estado de daño se multiplican por el daño medio y se agregan para obtener el daño medio de cada estructura individual (edificio, puente, instalación de agua, etc.). El resultado de este análisis es un archivo CSV con las probabilidades de daño.
Probabilidad de estado límite de Monte Carlo	Este análisis calcula una probabilidad de estado límite utilizando un proceso estocástico. La probabilidad de estado límite y el estado de daño se derivan utilizando el diccionario de estados de daño en el conjunto de datos de infraestructura de entrada. La probabilidad de estado límite se calcula a partir de todas las ejecuciones estocásticas, y el estado límite muestra todas las posiciones de la infraestructura como una cadena de estados fallidos (0) y no fallidos (1) de cada ejecución individual. El resultado de este análisis son dos archivos CSV: uno con la probabilidad de estado límite, llamado base_name_failure_probability.csv con las unidades de vivienda asignadas, y otro con el estado de fallo, llamado base_name_failure_state.csv. utilizando un proceso estocástico. La probabilidad de estado límite y el estado de daño se derivan utilizando el diccionario de estados de daño en el conjunto de datos de infraestructura de entrada. La probabilidad de estado límite se calcula a partir de todas las ejecuciones estocásticas, y el estado límite muestra todas las posiciones de la infraestructura como una cadena de estados fallidos (0) y no fallidos (1) de cada ejecución individual. El resultado de este análisis son dos archivos CSV: uno con la probabilidad de estado límite, llamado base_name_failure_probability.csv con las unidades de vivienda asignadas, y otro con el estado de fallo, llamado base_name_failure_state.csv.
Modelo de optimización para retrofit de múltiples objetivos	Este análisis calcula una serie de modelos de programación lineal para la optimización de objetivos simples y múltiples relacionados con el impacto del clima extremo en una comunidad, en términos de tres funciones objetivo: minimizar la pérdida económica, minimizar la reubicación de la población y maximizar la funcionalidad de los edificios. El análisis utiliza un conjunto de estrategias de mitigación determinado por el tipo de amenaza, como el refuerzo sísmico en edificios existentes o la reubicación en caso de tsunamis o inundaciones. Los parámetros incluyen el nivel inicial y final de retroalimentación de un edificio, el costo del retrofit y un coeficiente de objetivo que mide la resiliencia de la comunidad. El modelo de optimización implementado en pyIncore tiene tres objetivos: pérdida económica, dislocación poblacional y funcionalidad de los edificios. El proceso de cálculo se realiza resolviendo de manera iterativa modelos lineales con restricciones, usando pasos epsilon. Los resultados en formato CSV contienen colecciones de asignaciones óptimas de recursos.
Funcionalidad de interdependencia en cascada de redes	Este análisis calcula la funcionalidad en cascada basada en las interdependencias entre redes de instalaciones de energía eléctrica (EPF) y redes de distribución de agua (WDS). El análisis utiliza la ecuación de Leontief para calcular las dependencias funcionales entre dos redes interdependientes, considerando la funcionalidad de cada nodo. Estas dependencias capturan los efectos en cascada sobre la funcionalidad de la infraestructura, expresados en términos de tiempos discretizados. El resultado del cálculo consiste en un conjunto de datos con la funcionalidad en cascada de la EPN, acompañada de los valores discretos originales.

Tipo de Análisis	Descripción
Daño en tuberías	Este análisis calcula el daño en las tuberías en función de una amenaza específica. Actualmente, las amenazas soportadas son: terremoto y tsunami. El proceso para calcular el daño estructural es similar al de otras partes del entorno construido. Primero, se obtiene una fragilidad basada en el tipo de amenaza y los atributos de la tubería. A continuación, se calcula la intensidad de la amenaza en la ubicación de la tubería. Con esta información, se determina la probabilidad de superar cada estado límite y la probabilidad de daño. Si el conjunto de datos de la tubería contiene información sobre el suelo, el valor medio de la fragilidad asociada puede modificarse para tener en cuenta la licuefacción en el daño. Los resultados de este análisis son un archivo CSV con probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Daño en tuberías con tasa de reparación	Este análisis calcula el daño en las tuberías de agua en función de una amenaza específica. Actualmente, la amenaza soportada es: terremoto. El proceso para calcular el daño estructural es similar al de otras partes del entorno construido. Primero, se obtiene una fragilidad basada en el tipo de amenaza y los atributos de la tubería. A continuación, se calcula la intensidad de la amenaza en la ubicación de la tubería. Con esta información, se determina la probabilidad de superar cada estado límite y la probabilidad de daño. Si el conjunto de datos de la tubería contiene información sobre el suelo, el valor medio de la fragilidad asociada puede modificarse para tener en cuenta la licuefacción en el daño. Los resultados de este análisis son un archivo CSV con probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.
Análisis de funcionalidad de tuberías	Este análisis calcula la funcionalidad de las tuberías utilizando los cálculos de la tasa de reparación derivados del análisis de daño de las tuberías. El cálculo se realiza generando muestras de Monte Carlo a partir de desviaciones de muestras de Poisson del análisis de daño, que se utilizan como entrada en experimentos de Bernoulli para determinar posteriormente la funcionalidad promedio. Los resultados de este análisis son dos archivos CSV: uno con la probabilidad de falla, denominado base_name_failure_probability.csv, y otro con los estados de falla, denominado base_name_failure_state.csv.
Costo de reparación de tuberías de agua	Este análisis estima los costos de reparación de las tuberías de agua para diferentes escenarios de simulación, basándose en sus estados de daño, costos de reemplazo y ratios de daño.
Restauración de tuberías	Este análisis calcula el tiempo de restauración de las tuberías de agua después del impacto de una amenaza específica. El análisis no depende del tipo de amenaza, ya que trabaja con los resultados del análisis de daño de tuberías con tasa de reparación y las curvas de restauración. Las curvas de restauración se obtienen según el tipo de amenaza y la clase específica del diámetro de la tubería. Basándose en la curva de restauración aplicable, se determina el tiempo necesario para reparar cada tubería. Se consideran la tasa de fugas, la tasa de roturas, la longitud de la tubería y el número de trabajadores disponibles para calcular los tiempos de reparación. Uno de los insumos de este análisis es el resultado del análisis de daño de tuberías con tasa de reparación. El resultado de este análisis es un archivo CSV con el tiempo estimado para reparar cada tubería.

Tipo de Análisis	Descripción
Desplazamiento de población	Este análisis calcula el desplazamiento de población en función de una amenaza específica. Primero, las unidades de vivienda, con características detalladas (tenencia, tamaño del hogar, ocupada o vacía), se asignan a los puntos de dirección (edificios). Esto se realiza mediante el análisis de asignación de unidades de vivienda. Después de asignar las unidades de vivienda, el evento de amenaza, definido a través de los servicios de Fragilidad y Amenaza, determina la pérdida de valor para cada estructura, lo cual sirve como insumo para el cálculo del desplazamiento. El desplazamiento se calcula a partir de cuatro probabilidades, basadas en una distribución beta aleatoria de los cuatro factores de daño presentados por Bai et al. 2009, los cuales corresponden a la pérdida de valor. La suma de estas probabilidades multiplicada por las probabilidades de los estados de daño se usa como la probabilidad de desplazamiento. Dado que el proceso para determinar qué hogares se desplazan es probabilístico, se importa un valor entero para iniciar el generador de números aleatorios, lo que determina si un hogar se desplaza. Además, se tienen en cuenta las características del grupo de bloques, como los porcentajes de población afroamericana e hispana. El resultado de este análisis es un archivo CSV con los hogares desplazados y las variables relacionadas
Recuperación de edificios residenciales	Este análisis calcula el tiempo de recuperación necesario para cada edificio residencial desde cualquier estado de daño hasta lograr la restauración total. Actualmente, las amenazas soportadas son los tornados. La metodología emplea un enfoque de simulación de Monte Carlo de múltiples capas y determina el tiempo de recuperación en dos etapas, que incluye tanto el período de demora como el período de reparación. El modelo de demora se modificó según el marco REDi y calcula los resultados finales considerando factores que retrasan la recuperación, como la inspección posterior al desastre, las reclamaciones de seguros y la emisión de permisos de construcción. El modelo de reparación sigue el enfoque FEMA P-58 y utiliza funciones de fragilidad de Koliou y van de Lindt (2020). El resultado de este análisis es un archivo CSV con probabilidades de recuperación en pasos de tiempo a nivel de edificio.
Daño en carreteras	Este análisis calcula el daño en las carreteras en función de una amenaza específica. Actualmente, las amenazas soportadas son: terremoto y tsunami. El proceso para calcular el daño estructural es similar al de otras partes del entorno construido. Primero, se obtiene una fragilidad basada en el tipo de amenaza y los atributos de las carreteras. A continuación, se calcula la intensidad de la amenaza. Con esta información, se determina la probabilidad de superar cada estado límite y la probabilidad de daño. Si el conjunto de datos de la carretera contiene información sobre el suelo, el valor medio de la fragilidad asociada puede modificarse para tener en cuenta la licuefacción en el daño. Los resultados de este análisis son un archivo CSV con probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades.

Tipo de Análisis	Descripción
Modelo de Equilibrio General Computable (CGE) de Salt Lake City	Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales. Este modelo utiliza múltiples fuentes de datos para reflejar las interacciones de los hogares, las empresas y las entidades gubernamentales relevantes en su contribución a la actividad económica. El modelo se basa en (1) hogares que maximizan la utilidad, proporcionando trabajo y capital, utilizando los ingresos para pagar bienes y servicios (tanto producidos localmente como importados) y pagar impuestos; (2) el sector de producción, con empresas perfectamente competitivas que maximizan sus beneficios utilizando insumos intermedios, capital, tierra y trabajo para producir bienes y servicios tanto para el consumo doméstico como para la exportación; (3) el sector gubernamental que recauda impuestos y utiliza los ingresos fiscales para financiar la provisión de servicios públicos; y (4) el resto del mundo. El resultado de este análisis son archivos CSV con el suministro doméstico, ingreso bruto, demanda de factores previos y posteriores al desastre, y el número de hogares.
Modelo de Equilibrio General Computable (CGE) de Seaside	Un modelo de equilibrio general computable (CGE) se basa en principios económicos fundamentales. Este modelo utiliza múltiples fuentes de datos para reflejar las interacciones de los hogares, las empresas y las entidades gubernamentales relevantes en su contribución a la actividad económica. El modelo se basa en (1) hogares que maximizan la utilidad, proporcionando trabajo y capital, utilizando los ingresos para pagar bienes y servicios (tanto producidos localmente como importados) y pagar impuestos; (2) el sector de producción, con empresas perfectamente competitivas que maximizan sus beneficios utilizando insumos intermedios, capital, tierra y trabajo para producir bienes y servicios tanto para el consumo doméstico como para la exportación; (3) el sector gubernamental que recauda impuestos y utiliza los ingresos fiscales para financiar la provisión de servicios públicos; y (4) el resto del mundo. El resultado de este análisis son archivos CSV con simulaciones CGE, suministro doméstico y empleo.
Vulnerabilidad social	Este análisis calcula un puntaje de vulnerabilidad social para cada zona asociada en los datos del censo. El cálculo extrae la zonificación y un puntaje de vulnerabilidad social obtenido al comparar características demográficas de interés con los valores promedio nacionales. El resultado del cálculo es un conjunto de datos en formato CSV.
Puntaje de vulnerabilidad social	Este análisis calcula un puntaje de vulnerabilidad social para cada zona asociada en los datos del censo. El cálculo extrae la zonificación y un puntaje de vulnerabilidad social obtenido al comparar características demográficas de interés con los valores promedio nacionales. El resultado del cálculo es un conjunto de datos en formato CSV.
Daño a la red eléctrica por tornado (EPN)	Este análisis calcula el daño en la red eléctrica (EPN) basado en una amenaza particular. Actualmente, la amenaza admitida es: tornado. El proceso para calcular el daño estructural es similar al de otras partes del entorno construido. Primero, se obtienen las fragilidades basadas en el tipo de amenaza y los atributos de las torres y postes de la red. A partir de la fragilidad, se calcula la intensidad de la amenaza en la ubicación de la infraestructura. Con esta información, se calcula la probabilidad de exceder cada estado límite, así como la probabilidad de daño. Los resultados de este análisis son un archivo CSV con probabilidades de daño y un archivo JSON con información sobre la amenaza y las fragilidades. Dependiendo de los datos de entrada, este análisis también proporciona información sobre el número de postes dañados para cada nodo, el costo de reparación para cada nodo, el costo total de reparación de la red y el tiempo total de reparación de la red.

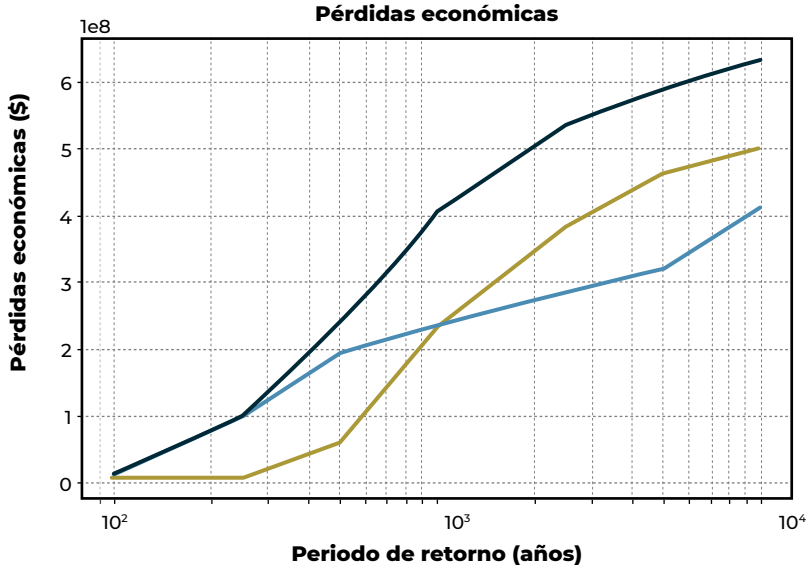
Tipo de Análisis	Descripción
Recuperación del flujo de tráfico	Este análisis calcula el daño a los puentes, primero llamando al análisis de daño de puentes. Luego, utiliza nodos y enlaces en el camino de flujo de tráfico y los datos de Promedio Diario de Tráfico (ADT) de los puentes para calcular la recuperación de la red de flujo de tráfico post-desastre. Además, el análisis puede utilizarse en cálculos estocásticos con un valor entero importado para inicializar el generador de números aleatorios. El resultado de este análisis es un archivo CSV con las líneas de tiempo de la trayectoria de recuperación y los datos correspondientes.
Recuperación del transporte	Este análisis calcula el daño a los puentes, primero llamando al análisis de daño de puentes. Luego, utiliza nodos y enlaces en el camino de transporte y los datos de Promedio Diario de Tráfico (ADT) de los puentes para calcular la recuperación de la red de transporte post-desastre. Además, el análisis puede utilizarse en cálculos estocásticos con un valor entero importado para inicializar el generador de números aleatorios. El resultado de este análisis es un archivo CSV con las líneas de tiempo de la trayectoria de recuperación y los datos correspondientes.
Daño a instalaciones de agua	Este análisis calcula el daño a las instalaciones de agua basado en una amenaza particular. Las amenazas actualmente soportadas son: terremoto y tsunami. El proceso para calcular el daño estructural es similar al de otras partes del entorno construido. Primero, se obtiene una fragilidad según el tipo de amenaza y las características del edificio. Basándose en la fragilidad, se calcula la intensidad de la amenaza en la ubicación del edificio. Con esta información, se calcula la probabilidad de superar cada estado límite, junto con la probabilidad de daño. En el caso de una amenaza por terremoto, la información del suelo puede utilizarse para modificar las probabilidades de daño e incluir el daño debido a la licuefacción.
Funcionalidad de la red de agua	Este análisis calcula la funcionalidad de las redes de agua. El cálculo utiliza entradas del análisis de fallas Monte Carlo, utilizando información sobre el daño a las instalaciones de agua, así como datos de funcionalidad de las tuberías, para determinar la probabilidad de funcionalidad y los estados de fallo para la red de instalaciones de agua correspondiente mediante un análisis de accesibilidad. El resultado del análisis consiste en un archivo CSV con las probabilidades de funcionalidad de las instalaciones de agua y un archivo CSV con los estados de fallo de funcionalidad.
Análisis de Costos de Reparación de Instalaciones de Agua	Este análisis estima los costos de reparación de las instalaciones de agua para diferentes escenarios de simulación, basados en sus estados de daño, costos de reemplazo y proporciones de daño.
Restauración de Instalaciones de Agua	Este análisis calcula el tiempo de reparación y el porcentaje de cambio en la funcionalidad con el tiempo para la restauración de las instalaciones de agua, basándose en las curvas de restauración mapeadas. Las curvas de restauración se obtienen según el tipo de amenaza y la clase de la instalación de agua, por ejemplo, planta de tratamiento, planta de bombeo, tanque de almacenamiento de agua, etc. Según la curva de restauración aplicable, es posible obtener el porcentaje de cambio en la funcionalidad variando el tiempo; también es posible calcular el tiempo de reparación a diferentes niveles de cambio en la funcionalidad invirtiendo la función de restauración.

A.6.3. Enfoque matemático

IN-CORE utiliza curvas de fragilidad para realizar los cálculos de daño. Primero, se obtiene una fragilidad basada en el tipo de amenaza y los atributos del edificio (o cualquier otro elemento expuesto). Con base en la fragilidad, se calcula la intensidad de la amenaza en la ubicación del edificio. Con esta información, se calcula la probabilidad de exceder cada estado límite, junto con la probabilidad de daño. En el caso de la amenaza sísmica, la información del suelo se puede utilizar para modificar las probabilidades de daño e incluir el daño debido a la licuefacción (IN-CORE 2024).

La **Figura 50** muestra un ejemplo de curva de riesgo obtenida por IN-CORE. La amenaza sísmica-tsunami en la Zona de Subducción de Cascadia (CSZ) se utiliza en este ejemplo para demostrar las capacidades multiamenaza del software. El análisis de amenaza sísmico-tsunami probabilístico (PSTHA; Park et. al. 2017) resultó en mapas de amenaza tanto de terremotos como de tsunamis para siete intervalos de recurrencia (100, 250, 500, 1,000, 2,500, 5,000, y 10,000 años). Los daños a los edificios se calculan en IN-CORE superponiendo los mapas de amenaza sobre los edificios y determinando las medidas de intensidad específicas del sitio. Las medidas de intensidad de desplazamiento espectral y flujo de momento se utilizan para el sismo y el tsunami, respectivamente. Luego, se implementan las curvas de fragilidad para determinar la probabilidad de que cada edificio sufra: (1) daños insignificantes, (2) moderados, (3) graves o (4) completos. Estas probabilidades se utilizan posteriormente para informar una simulación de Monte-Carlo en la que se calcula la probabilidad de falla de los edificios. Dentro de la documentación de IN-CORE no se encontró referencia a una función específica para el cálculo del EAD, pero debido a que IN-CORE funciona en el entorno de Python, el usuario puede obtener el área bajo la curva aplicando las funciones disponibles en Python.

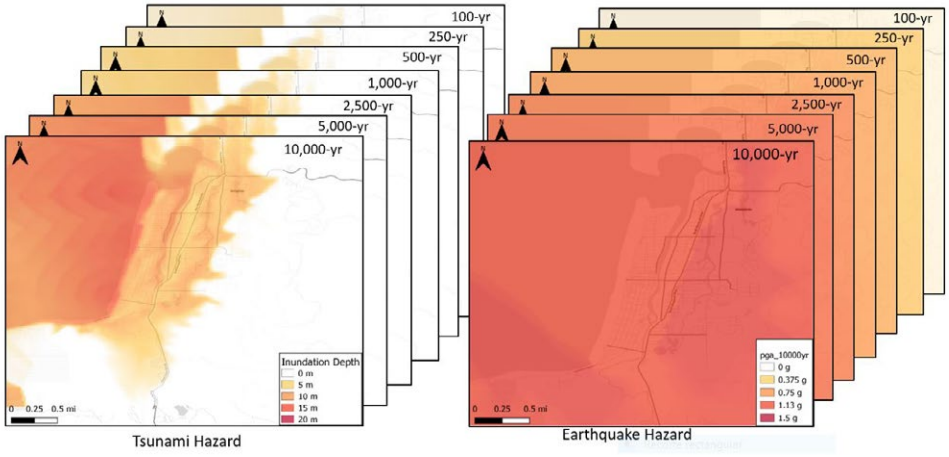
Figura 50. Ejemplo de curva de riesgo obtenida por IN-CORE



Fuente: IN-CORE (2024).

Nota: la línea azul corresponde a las pérdidas económicas por sismo, la línea café a las pérdidas económicas por tsunami y la línea negra a las pérdidas multiamenaza.

Figura 51. Mapas de amenaza para tsunami y sismo



Fuente: IN-CORE (2024).

A.6.4. Avances recientes e innovaciones

La última versión es IN-CORE v5.3.0 publicada en April 12 de 2024.

A.6.5. Comunidad de desarrollo

IN-CORE es desarrollado por un equipo interdisciplinario de investigadores de la Universidad Estatal de Colorado, en colaboración con otras instituciones académicas, agencias gubernamentales y el sector privado. Esta comunidad trabaja en conjunto para actualizar y mejorar continuamente el software, asegurando que se mantenga a la vanguardia de la investigación en resiliencia de infraestructuras.

A.6.6. Limitaciones

Una de las principales limitaciones de IN-CORE es que requiere que el usuario tenga conocimientos de codificación en Python.

A.6.7. Casos de uso

IN-CORE ha sido usado solamente en Estados Unidos. La **Caja 7** muestra uno de los ejemplos que utiliza es software como tutorial y que se encuentra documentado por van de Lindt et al. (2023).

Caja 7. Ejemplo de aplicación de IN-CORE

Caso de Estudio: Seaside, Oregón (Terremoto y Tsunami Sucesivos)



Imagen: Adobe Stock

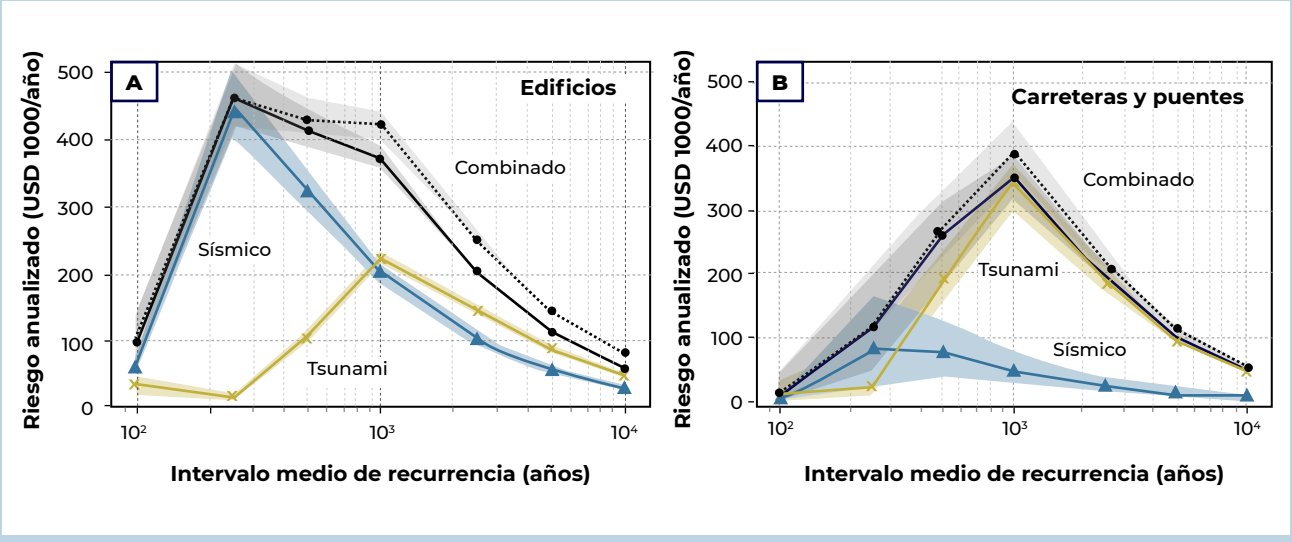
Seaside, una pequeña ciudad costera en el noroeste del Pacífico de los Estados Unidos fue seleccionada como caso de prueba para aplicar el sistema IN-CORE, dada su vulnerabilidad ante sismo y tsunami originados en la Zona de Subducción de Cascadia. El estudio generó las capas de amenaza asociadas sismo y tsunami, enfocándose en cinco medidas de intensidad del tsunami: profundidad del flujo, velocidad, flujo de momento, tiempo de llegada y duración de la inundación.

Posteriormente, se realizó un análisis de daños multirriesgo para evaluar los impactos combinados del terremoto y el tsunami mediante un enfoque estocástico, que toma en cuenta los daños acumulados debido al sismo y la posterior inundación por tsunami. El análisis probabilístico de daños por sismo y tsunami se integra como un paso dentro de un sistema de soporte de decisiones centrado en la resiliencia, que incluye la evaluación de pérdidas económicas directas e indirectas.

El análisis además considera varios componentes del entorno construido, incluidos los sectores de transporte, energía y agua, así como las características demográficas de la población. Los daños, las pérdidas económicas, y la conectividad con las instalaciones críticas se analizaron para mostrar las pérdidas económicas por tipo de amenaza e infraestructura.

Dentro del análisis se establecieron metas de rendimiento: 1) robustez (por ejemplo, un nivel aceptable de daño) y 2) rapidez (por ejemplo, un tiempo aceptable para la recuperación). Un aspecto clave de este marco fue que las metas se establecieron en función del intervalo medio de recurrencia de las amenazas. Los resultados destacaron el impacto de considerar diferentes metas de rendimiento, la introducción de medidas ex ante y ex post, y las interdependencias entre los diversos sistemas de infraestructura sobre la resiliencia de las infraestructuras. Además, este estudio mostró cómo el volumen de escombros aumenta con el intervalo medio de recurrencia (MRI) y cómo la ubicación del perfil máximo de escombros a través de la costa está relacionada con el límite máximo de la subida del tsunami.

La figura que se muestra a continuación presenta el riesgo económico anualizado medio para (a) edificios y (b) la red de transporte (carreteras y puentes) en función del intervalo medio de recurrencia. El riesgo se desagrega para las amenazas sísmica (azul), tsunami (rojo) y combinado (negro). En el panel izquierdo (A), el riesgo máximo para los edificios ocurre en el evento de 250 años y se debe casi por completo al movimiento del suelo. Por otro lado, en el panel derecho (B), el riesgo máximo para las carreteras y puentes ocurre en el evento de 1000 años, principalmente debido al tsunami. Esta comparación resalta la necesidad de evaluar el riesgo tanto en términos de tipo de amenaza como de tipo de infraestructura para la toma de decisiones sobre la resiliencia comunitaria.



Este caso de estudio demuestra la importancia de integrar análisis de riesgos multirriesgos y evaluar la infraestructura local en términos de vulnerabilidad ante sismo y tsunami. Los resultados obtenidos no solo proporcionan una comprensión de los riesgos y las posibles pérdidas económicas, sino que también informan las estrategias para mejorar la resiliencia comunitaria frente a eventos de gran magnitud.

Fuente: van de Lindt et al. (2023).

A.7. CLIMADA (CLIMATE ADAPTATION)

A.7.1. Descripción General

CLIMADA (CLIMate ADAptation) es una herramienta de modelado cuantitativo de riesgos climáticos desarrollada para evaluar el riesgo socioeconómico de eventos climáticos extremos. Es una plataforma de código abierto, disponible en GitHub[26], y fue desarrollada principalmente en Python, MATLAB y Octave. La herramienta permite analizar riesgos de diferentes tipos de amenazas climáticas (ciclones tropicales, inundaciones, sequías, etc.) a escalas globales, regionales y locales, proporcionando estimaciones espaciales explícitas del riesgo tanto en la actualidad como en proyecciones futuras. CLIMADA implementa un modelo de evaluación de riesgos totalmente probabilístico (Aznar-Siguan y Bresch 2019).

CLIMADA proporciona un marco para que los usuarios combinen datos de exposición, amenaza y vulnerabilidad para calcular el riesgo. Los usuarios pueden crear datos de impacto probabilísticos a partir de conjuntos de eventos, observar cómo el cambio climático afecta a estos impactos y ver cómo las medidas de adaptación pueden cambiarlos de manera efectiva. CLIMADA también permite estudios de eventos individuales, conjuntos de eventos históricos y pronósticos (ETH Zurich 2017c).

Además, se han realizado esfuerzos por tener interoperabilidad e integración de CLIMADA con otras herramientas como Oasis LMF (Blass 2021) y OpenQuake[27].

A.7.2. Métodos Aplicados

CLIMADA implementa un modelo probabilístico de evaluación de riesgos utilizando técnicas de última generación como la simulación de Monte Carlo. Este enfoque permite integrar diferentes escenarios de desarrollo económico e impacto climático, utilizando datos históricos y de teledetección para producir mapas de amenaza, vulnerabilidad y riesgo. El modelo considera la combinación de amenaza, exposición (activos y personas) y vulnerabilidad para calcular el riesgo. Además, incluye funciones de daño que relacionan la intensidad de un evento con sus consecuencias económicas sobre activos como personas, edificios e infraestructuras públicas. CLIMADA opera de manera coherente a nivel mundial a alta resolución (10 km), así como en aplicaciones locales a las resoluciones más altas (100 m) sin embargo, el usuario puede utilizar la información con el nivel de detalle que tenga disponible. La herramienta proporciona estimaciones espacialmente explícitas del riesgo de amenazas múltiples tanto en la actualidad como en las proyecciones futuras (Munich Climate Insurance Initiative 2020). CLIMADA permite evaluar un portafolio completo de medidas de adaptación, cuantificando el potencial de aversión al daño y la relación costo-beneficio para cada medida (Munich Climate Insurance Initiative 2020). Las medidas de adaptación incluyen, por ejemplo, la construcción de obras de protección, la planificación espacial, los enfoques basados en los ecosistemas, las regulaciones de construcción y

[26] El código está alojado en GitHub (https:// github.com/CLIMADA-project/climada_python) bajo la licencia GNU GPL (GNU Operating System, 2007) (Aznar-Siguan & Bresch, 2019)(Aznar-Siguan & Bresch, 2019).

[27] Comunicación verbal con Universidad de Naciones Unidas.

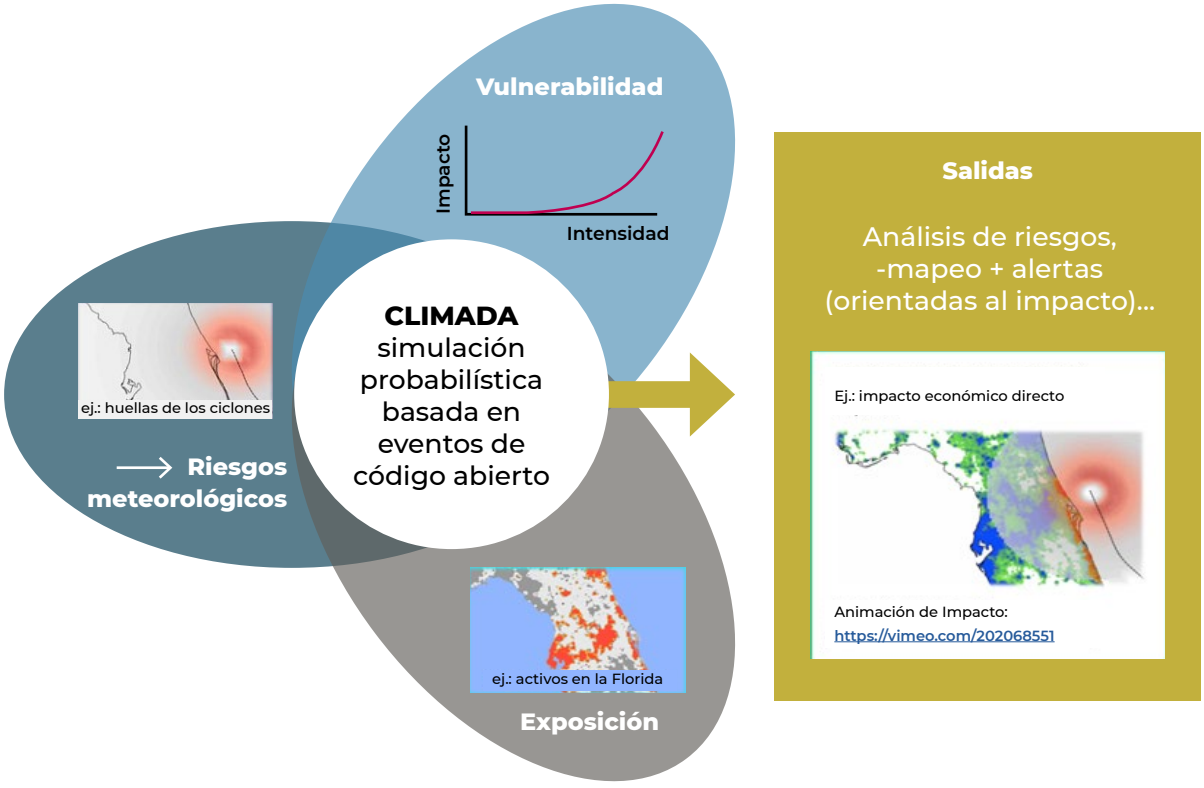
la transferencia de riesgos (seguro) contra algunos de los eventos climáticos más extremos. En este contexto, CLIMADA implementa la metodología de Economía de la Adaptación al Clima (Aznar-Siguan y Bresch 2019).

El diseño del software es modular y está orientado a objetos, ofreciendo un marco colaborativo simple y una estrategia de paralelización que permite cálculos escalables en clústeres (Aznar-Siguan y Bresch 2019).

El primer paso en el análisis de costo-beneficio es determinar el riesgo actual (ver **Figura 52**). En esencia, CLIMADA implementa el concepto de riesgo como en el IPCC (2014). CLIMADA combina la amenaza (por ejemplo, una huella de viento de un ciclón tropical), la exposición (por ejemplo, una distribución de activos) y la vulnerabilidad (relación funcional entre la intensidad de la amenaza y el impacto) para calcular el riesgo (Aznar-Siguan y Bresch 2019).

Además, con CLIMADA es posible realizar análisis de incertidumbre globales incluyendo la incertidumbre en la amenaza, la exposición y la función de impacto a través de los métodos implementados en el módulo Unsequa (Kropf et al. 2022).

Figura 52. Conceptualización de CLIMADA



Fuente: Aznar-Siguan y Bresch (2019).

A.7.3. Enfoque matemático

CLIMADA proporciona un enfoque probabilístico basado en eventos que no depende de una hipótesis de distribución de probabilidad a priori. El modelo de daño de CLIMADA se puede utilizar para una amplia variedad de aplicaciones, por ejemplo, de manera determinista para evaluar el daño de un solo evento o para cuantificar el riesgo basado en un (gran) conjunto de eventos probabilísticos (Aznar-Siguan y Bresch 2019). La exposición puede darse en términos de un valor que no necesariamente es monetario, por ejemplo, en número de personas.

El motor de cálculo de CLIMADA utiliza las funciones de daño o vulnerabilidad para calcular el daño de una amenaza en los elementos expuestos y almacena todas las métricas de evaluación de riesgos resultantes. La arquitectura que utiliza la herramienta para el cálculo de riesgo se muestra en la **Figura 53**. El valor de la amenaza se asigna a la coordenada del centroide del elemento expuesto y la relación de daño derivada de las funciones de daño se traduce en un daño directo multiplicándola por el valor expuesto como muestra la **Ecuación 17** (Aznar-Siguan y Bresch 2019):

Ecuación 17

$$\chi_{ij} = val_j f_{imp}(h_{ij}|\Upsilon_j)$$

Donde χ_{ij} y h_{ij} son, respectivamente, el daño y la intensidad de la amenaza debido al evento i en la ubicación j, val_j el valor de exposición en la ubicación j, Υ_j son los parámetros de exposición j que caracterizan su vulnerabilidad y f_{imp} la función de daño. El daño se obtiene para cada elemento expuesto y cada evento que lo afecta (histórico o estocástico). Con base en este daño para el evento y la frecuencia de cada evento, cualquier métrica de riesgo puede ser obtenida. A continuación, se muestran las ecuaciones que utiliza la herramienta, que han sido derivadas de Cardona et al. (2012).

- Daño anual esperado (EAI) en la exposición j contenida en el atributo eai_exp:

Ecuación 18

$$EAI_j = \sum_{\bar{\imath}}^{N_{hist}} E\,[X|E_{\bar{\imath},j}]\,F(E_{\bar{\imath}})$$

Ecuación 19

$$EAI_j = \sum_{\bar{\imath}=1}^{N_{hist}} \sum_{\hat{\imath}}^{N_{hist}} x_{\hat{\imath}} F(E_{\hat{\imath}}) = \sum_{i=1}^{Nev} x_{ij} F(E_i)$$

Donde X es la variable aleatoria de daño, E su expectativa, E_i es un evento y F su frecuencia (anual). N_{hist} es el número de eventos históricos, $\bar{\imath}$ representa un evento histórico $\hat{\imath}$ representa a todos los miembros del conjunto del evento $\bar{\imath}$, y Nev representa el número total de eventos. Se asume la independencia de los eventos.

- El daño anual promedio (AAI) está contenido en el atributo aai_agg y es la adición de EAI en todas las exposiciones:

Ecuación 20

$$AAI = \sum_{j=1}^{Nexp} EAI_j$$

Donde $Nexp$ es el número de elementos expuestos.

- Daño máximo probable (PMI): PMI representa el daño que se supera a una frecuencia anual baja fija (normalmente de 1/1500 a 1/250). Se obtiene de la curva de excedencia de daño calculada con el método calc_freq_curve. Teniendo en cuenta el teorema de probabilidad total, esta curva se aproxima mediante la discretización de la **Ecuación 21**.

Ecuación 21

$$v\,(x) = \frac{1}{T\,(x)} = P\,(X > x) = \sum_{\bar{i}}^{Nhist} \int P(X > x|h)p\,(h|E_i)dhF\,(E_i)$$

Donde $v\,(x)$ es la frecuencia de excedencia del daño x, $T\,(x)$ su período de retorno equivalente, y h la intensidad de la amenaza. $p\,(h|E_i)$ es la función de densidad de probabilidad de h dado que el evento histórico E_i tuvo lugar y se calcula utilizando los miembros del conjunto del evento. La probabilidad de exceder un valor de daño dada la intensidad h, $P(X > x|h)$, se calcula utilizando los valores de exposición y sus funciones de daño. CLIMADA asume que los daños de un evento en diferentes exposiciones son independientes.

CLIMADA también incluye un módulo para la cuantificación de incertidumbre y análisis de sensibilidad (Kropf et al. 2022). El módulo unsequa utiliza un enfoque basado en Monte Carlo y aplica metodologías estándar de análisis de incertidumbre y sensibilidad. Su flujo de trabajo comienza con la definición de variables de entrada y parámetros, estableciendo distribuciones de probabilidad para los parámetros que afectan las variables clave del modelo: amenaza, exposición, función de vulnerabilidad y medidas de adaptación, con las cuales se generan muestras de los valores de estos parámetros según sus respectivas distribuciones de probabilidad.

A continuación, el motor de CLIMADA calcula los resultados del modelo para cada muestra, obteniendo métricas de riesgo o evaluación de opciones de adaptación. Los resultados pueden ser analizados y visualizados para entender la distribución de las salidas del modelo. También es posible calcular índices de sensibilidad para evaluar la influencia de cada parámetro de entrada sobre las métricas del modelo (Kropf et al. 2022).

Las distribuciones de los parámetros pueden ser de cualquier tipo, incluyendo uniformes, gaussianas, sesgadas o discretas. CLIMADA permite el uso de cualquier distribución disponible en la librería SciPy. stats de Python.

Para definir la incertidumbre de cada variable, el usuario debe especificar un método que determine su valor en función de los parámetros inciertos. El módulo unsequa ofrece métodos auxiliares para apoyar esta parametrización, permitiendo dos enfoques principales: la perturbación directa de una variable mediante métodos estadísticos o la incorporación de parámetros inciertos en el modelo subyacente que genera la variable. Como cada variable es independiente, es posible utilizar ambos enfoques simultáneamente dentro del mismo estudio.

El análisis de incertidumbre y sensibilidad es computacionalmente costoso, ya que el tiempo de cálculo crece con el número de muestras y la complejidad del modelo. Factores como la resolución espacial de la exposición o el número de eventos de la amenaza afectan el tiempo requerido. En modelos externos como los hidrológicos, el tiempo de simulación del modelo base también influye. Si los cálculos son prohibitivamente largos, se puede optar por precomputar muestras o emplear modelos sustitutos.

En la etapa final, se caracterizan y visualizan los valores de salida del modelo, utilizando herramientas gráficas y estadísticas para comprender las incertidumbres más allá de valores medios y desviaciones estándar. Los índices de sensibilidad cuantifican la influencia de cada parámetro incierto sobre los resultados del modelo. Dado que CLIMADA es no lineal, solo se consideran índices de sensibilidad globales, calculados con algoritmos disponibles en la librería SALib de Python, como Sobol, efectos elementales de Morris y FAST (Kropf et al. 2022). Cada método tiene requisitos específicos de muestreo y puede proporcionar resultados distintos, aunque en general coinciden en identificar los parámetros más influyentes.

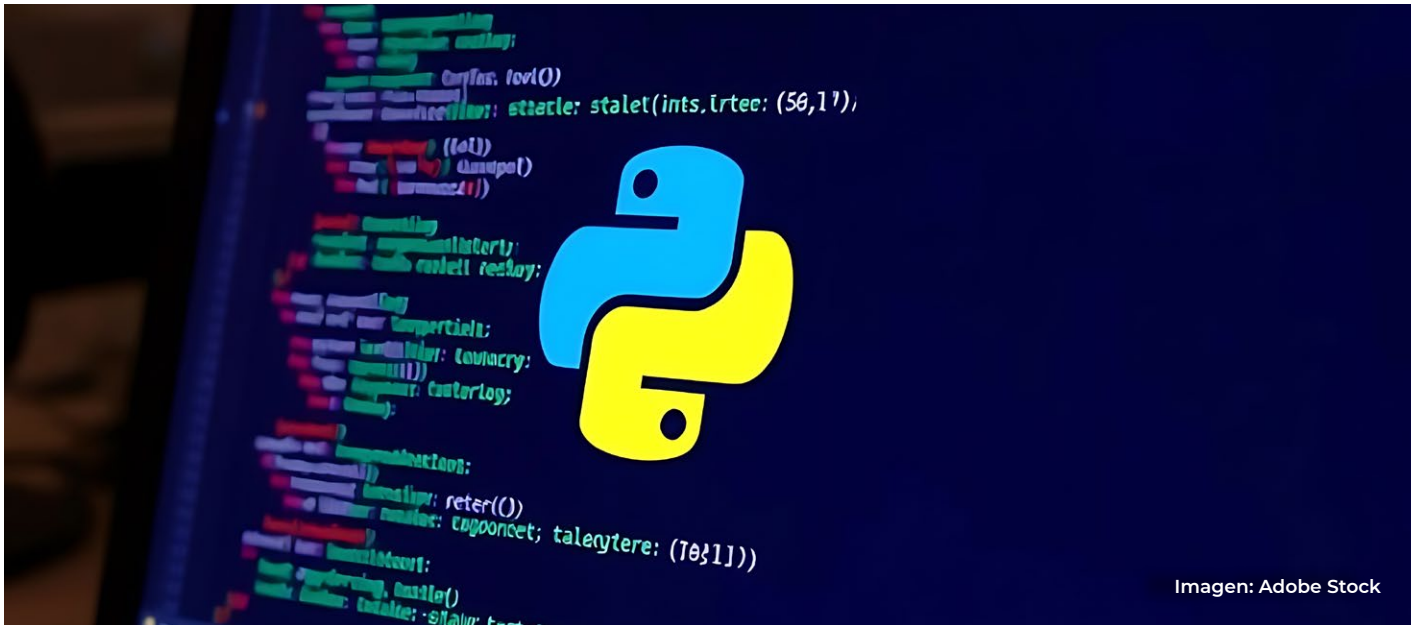
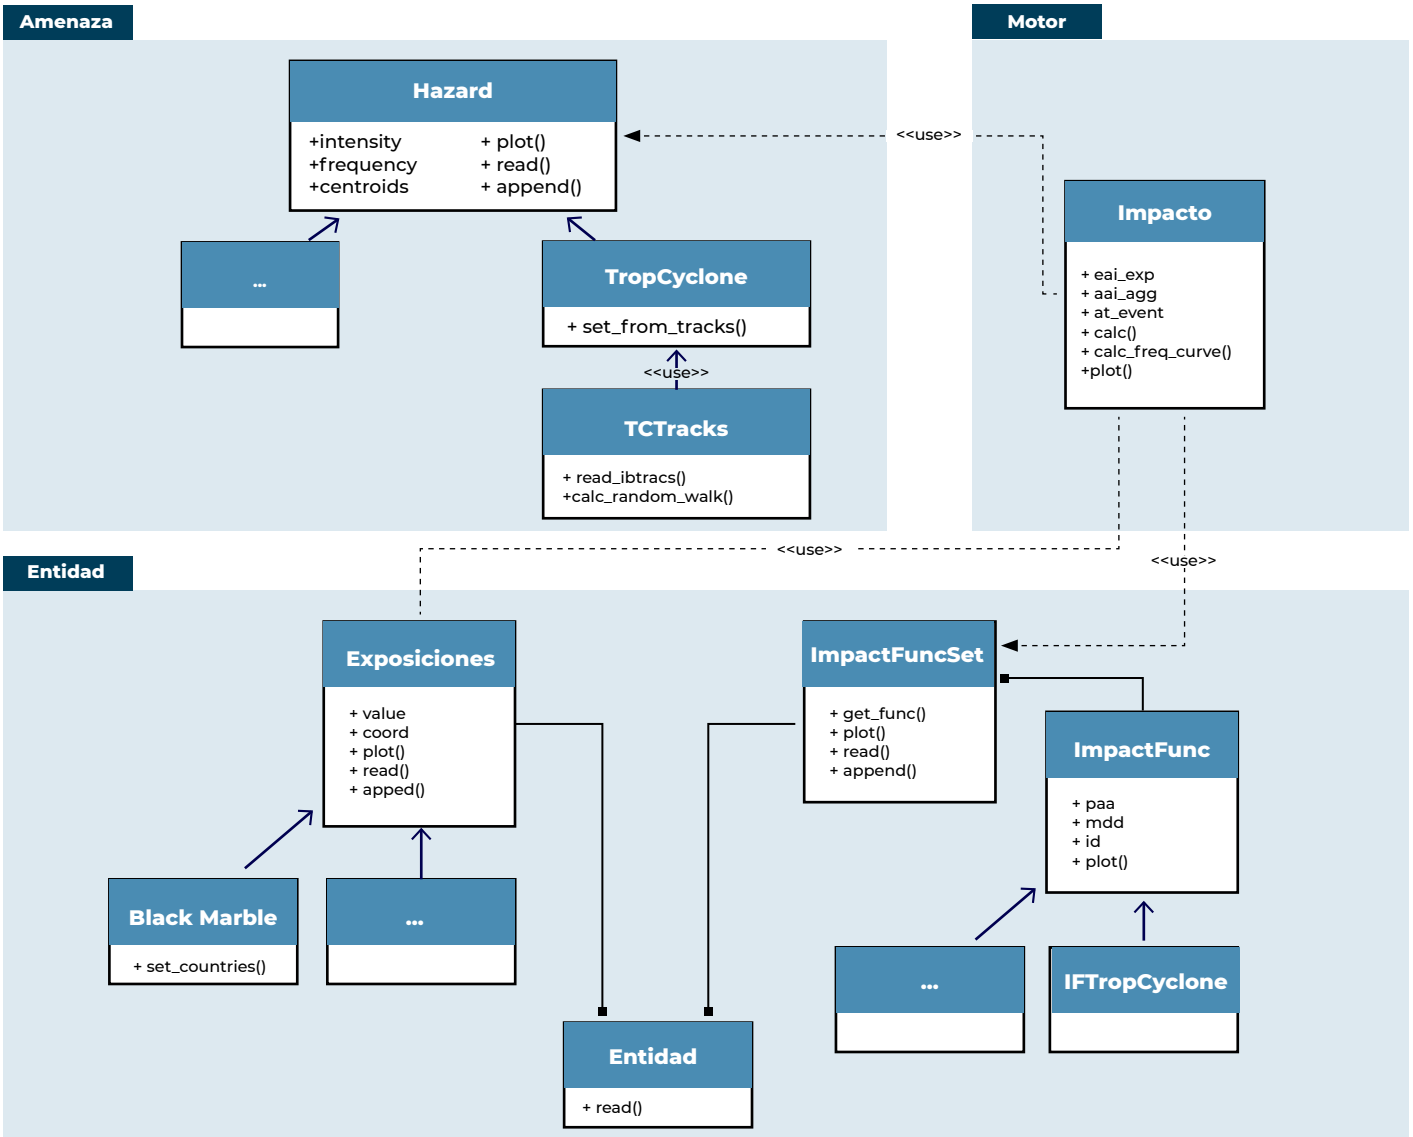


Imagen: Adobe Stock

Figura 53. Arquitectura de evaluación de riesgos simplificada de CLIMADA



Fuente: Aznar-Siguan y Bresch (2019).

A.7.4. Avances Recientes e Innovaciones

Recientemente, CLIMADA ha mejorado su rendimiento, escalabilidad y mantenibilidad. La herramienta incluye coberturas globales de amenazas climáticas como ciclones tropicales, inundaciones fluviales, sequías agrícolas y tormentas invernales europeas, con conjuntos de eventos históricos y probabilísticos disponibles bajo diferentes escenarios de forzamiento climático.

A.7.5. Comunidad de Desarrollo

CLIMADA es desarrollada y mantenida por el grupo de investigación Weather and Climate Risks (WCR) en ETH Zurich. La comunidad de desarrollo es activa y promueve el uso interdisciplinario de la plataforma, fomentando la colaboración internacional. La disponibilidad de CLIMADA como software de código abierto bajo la licencia GNU GPL3 ha sido fundamental para construir confianza en los resultados.

A.7.6. Limitaciones

Una de las principales limitaciones de CLIMADA es que requiere que el usuario tenga conocimientos de codificación en Python. Por otro lado, cabe destacar que, aunque CLIMADA fue originalmente diseñada para analizar amenazas climáticas, también puede realizar cálculos de riesgo para cualquier tipo de amenaza, siempre que esta sea representada como un objeto de tipo Hazard y se pueda asociar una curva de daño a los elementos expuestos.

A.7.7. Casos de Uso

CLIMADA se ha aplicado en más de veinte estudios de adaptación climática en todo el mundo, donde sirvió como una base sólida para la evaluación de riesgos y para abordar y comunicar las incertidumbres (Munich Climate Insurance Initiative 2020).



Imagen: Adobe Stock

Caja 8. Ejemplo de aplicación de CLIMADA

Estudio de Caso: El Huracán Irma y su Impacto en los Territorios No Autónomos del Caribe



Imagen: Adobe Stock

La región del Caribe incluye diecinueve territorios no autónomos. La llegada del huracán Irma en septiembre de 2017, un huracán de Categoría 5, ofrece un caso de estudio para comparar las respuestas gubernamentales y los impactos en estos territorios. La trayectoria del huracán afectó varias islas, incluidas naciones soberanas como Antigua y Barbuda y San Cristóbal y Nieves, así como territorios como San Bartolomé, Sint Maarten, Anguila y las Islas Vírgenes de los EE.UU.

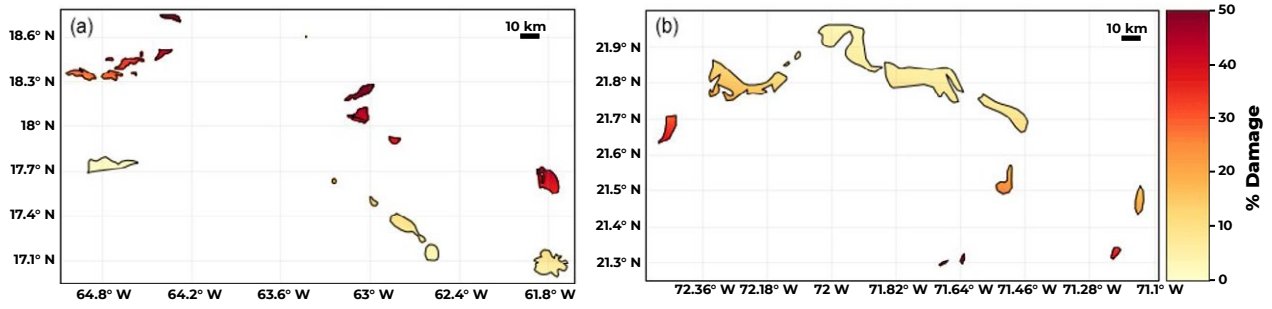
Históricamente, estas islas han dependido de sectores primarios como la agricultura, pero han cambiado hacia el turismo y las finanzas offshore. Este cambio económico tiene implicaciones para el impacto financiero de los desastres, dada la importante función del turismo y las finanzas en sus economías.

Para la estimación del valor económico expuesto se utilizó el conjunto de datos Black Marble, que emplea datos nocturnos de satélites de la NASA, para estimar la distribución espacial del valor económico en las islas afectadas. Este método implica la desagregación de los datos del PIB nacional a una resolución de 500 metros, ajustada por sesgos de distribución en áreas urbanas y suburbanas mediante una transformación cuadrática.

El daño del ciclón tropical se modeló utilizando la clase TropCyclone de CLIMADA, incorporando trayectorias históricas de ciclones tropicales y la velocidad del viento después del impacto en tierra. La función de daño utilizada se basa en las velocidades del viento, con ajustes para áreas urbanas y niveles de ingresos variados.

El estudio evaluó el riesgo combinando la amenaza del ciclón tropical con la exposición económica. Los modelos probabilísticos predijeron los niveles de daño para varios períodos de retorno, revelando que todas las islas enfrentan riesgos significativos por ciclones intensos. El análisis estimó que el daño para un evento con un período de retorno de 100 años podría superar USD 1 mil millones, con islas individuales como las Islas Vírgenes de los EE.UU. requiriendo una preparación financiera considerable.

Daño económico calculado por CLIMADA como porcentaje de la exposición local (por píxel). (a) Antillas Menores; (b) Islas Turcas y Caicos.



Las estimaciones de daño se compararon con otras fuentes como EM-DAT, el Centro Nacional de Huracanes y ECLAC. Los resultados del modelo CLIMADA fueron consistentes con estas fuentes, demostrando estimaciones fiables dentro del rango esperado. Se observó variabilidad en las estimaciones de daño debido a las diferencias en las fuentes de datos y metodologías, pero las predicciones del modelo fueron generalmente robustas.

El análisis de incertidumbre mostró que los factores socioeconómicos son los mayores contribuyentes a la variabilidad en las estimaciones de daño. Las simulaciones de Monte Carlo indicaron que los eventos extremos podrían causar daños sustanciales, que van desde USD 12.5 hasta 21 mil millones para los escenarios más extremos.

Al aplicar técnicas avanzadas de modelado y aprovechar los datos satelitales, el estudio proporciona valiosas ideas sobre el impacto financiero del huracán Irma y ofrece un marco para mejorar la preparación y respuesta ante desastres. Los resultados pueden ayudar a los gobiernos metropolitanos y a las administraciones territoriales a desarrollar estrategias efectivas para mitigar los riesgos futuros y mejorar la resiliencia.

Fuente: Aznar-Siguan y Bresch (2019).

A.8. CATSIM (CATASTROPHE SIMULATION TOOL)

A.8.1. Descripción general

CATSIM (Catastrophe Simulation Tool) es un modelo desarrollado por IIASA (International Institute for Applied Systems Analysis) diseñado para ayudar a los responsables de políticas, especialmente en países en desarrollo, a elaborar estrategias de financiación pública para antes y después de los desastres. El modelo permite la entrada de datos nacionales y plantea preguntas de "qué pasaría si", mostrando las mejores combinaciones de estrategias financieras para adaptarse a las circunstancias nacionales actuales (IIASA 2024b) .

CATSIM proporciona un marco económico basado en el riesgo para evaluar los impactos económicos de los desastres y analizar los costos y beneficios de las medidas para reducir dichos impactos (Hochrainer-Stigler et al., 2013). Utiliza simulaciones estocásticas de riesgos en una región específica y examina la capacidad del gobierno y del sector privado para financiar actividades de respuesta y recuperación. El modelo también analiza las obligaciones contingentes del gobierno, las brechas financieras que pueden surgir tras un desastre y las opciones para reducir la vulnerabilidad, incluidas estrategias de gestión financiera. Además, incorpora un marco simple de crecimiento económico para evaluar los impactos macroeconómicos de los desastres y los costos y beneficios de las medidas destinadas a mitigar esos efectos (Hochrainer-Stigler et al. 2015).

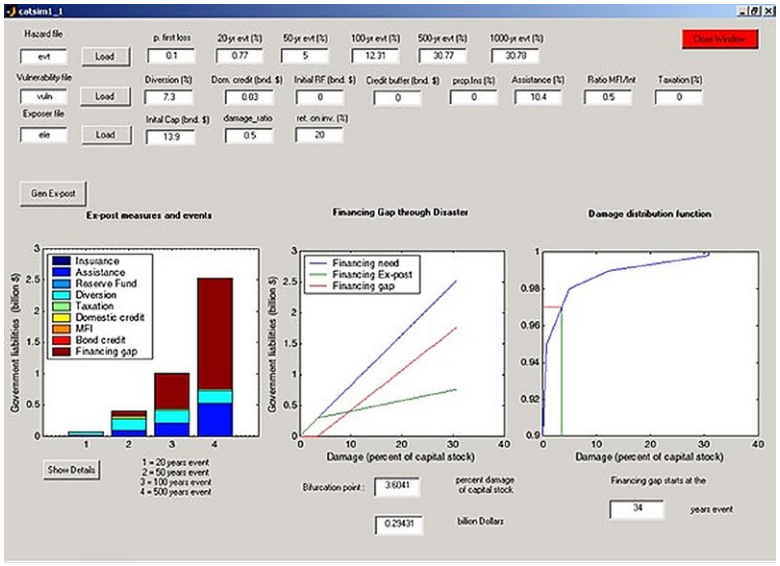
Los resultados que proporciona incluyen (Hochrainer-Stigler et al. 2013):

- **Evaluación de obligaciones contingentes y déficits de financiamiento:** Identifica las posibles brechas de financiamiento que un país podría enfrentar ante desastres.
- **Análisis costo-beneficio de opciones de reducción de vulnerabilidad y riesgo:** Permite valorar la eficacia económica de diferentes estrategias de gestión del riesgo, como la prevención, los fondos de reserva nacionales o los seguros soberanos.
- **Soporte en la planificación de políticas:** Ayuda a los gobiernos a decidir la asignación de recursos entre medidas preventivas (gasto ex-ante) y de respuesta post-desastre (gasto ex-post), considerando su impacto en la resiliencia económica.

CATSIM es una aplicación independiente con una interfaz gráfica fácil de usar que permite al usuario definir parámetros para amenaza, vulnerabilidad y elementos expuestos. La interfaz gráfica del software se muestra en la **Figura 54**.

Dado que CATSIM se centra en la toma de decisiones a nivel nacional, ni los datos de entrada ni los resultados tienen naturaleza geoespacial. En general, los resultados se presentan mediante gráficos interactivos que permiten a los usuarios modificar parámetros y realizar análisis de sensibilidad (Hochrainer-Stigler et al. 2015).

Figura 54. Interfaz gráfica de CATSIM



Fuente: IIASA (2024b).

A.8.2. Métodos aplicados

CATSIM utiliza un enfoque modular que incluye:

- **Evaluación del riesgo (Módulo 1):** Define parámetros para las amenazas, la vulnerabilidad y los elementos expuestos.
- **Análisis de estrategias financieras (Módulo 2):** Evalúa los costos y beneficios de diversas estrategias financieras para gestionar el riesgo, incluyendo su impacto en indicadores económicos clave como el crecimiento económico y la deuda.

CATSIM utiliza simulaciones estocásticas de desastres en una región específica para analizar la capacidad de los gobiernos y del sector privado para financiar la recuperación y la respuesta tras un evento. A través de simulaciones de Monte Carlo, el modelo evalúa los riesgos de desastres y permite al usuario ajustar parámetros para probar diferentes supuestos relacionados con amenazas, exposición, vulnerabilidad, condiciones económicas generales y la capacidad de respuesta del gobierno.

Como herramienta interactiva de fortalecimiento de capacidades, CATSIM ilustra los compromisos y las decisiones que enfrentan las autoridades para aumentar la resiliencia frente a los riesgos de desastres (Hochrainer-Stigler 2014; Hochrainer-Stigler et al. 2013)

Desde una perspectiva metodológica, CATSIM aborda el problema de decisión y modelización como un problema de decisión en dos etapas bajo incertidumbre. El objetivo principal es garantizar un financiamiento suficiente y oportuno para las obligaciones gubernamentales posteriores a un desastre, incluyendo la provisión de alivio al sector privado y la reconstrucción de activos públicos (Hochrainer-Stigler et al. 2013). Las etapas que se consideran son:

- **Primera etapa (ex-ante):** El gobierno puede asignar parte de su presupuesto a la reducción del riesgo (como construir un dique) o adquirir seguros y otros instrumentos financieros de protección para los activos públicos (infraestructura, edificios públicos) y obligaciones de ayuda al sector privado. Estas medidas, sin embargo, reducen el presupuesto disponible para actividades regulares de desarrollo, generando costos de oportunidad.

- **Segunda etapa (ex-post):** Tras un desastre, se toman decisiones presupuestarias para financiar las necesidades de recuperación. Sin embargo, financiar las pérdidas únicamente con recursos ex-post también afecta el presupuesto destinado a inversiones.

El déficit de recursos que no se puede cubrir con opciones ex-ante ni ex-post se denomina “brecha de recursos”. Esta brecha impacta negativamente variables macroeconómicas clave como el PIB, los ingresos del gobierno y su posición presupuestaria, aumentando la vulnerabilidad financiera y los riesgos futuros (Hochrainer-Stigler et al. 2013) .

CATSIM se implementa en cinco pasos principales (Hochrainer-Stigler et al., 2013):

1. **Modelado del riesgo de pérdidas directas de activos:** Se calculan las probabilidades de pérdidas en términos monetarios, en función de la frecuencia e intensidad de las amenazas, los elementos expuestos y su vulnerabilidad física.
2. **Resiliencia financiera y económica:** Se mide la capacidad del gobierno y del estado para acceder a ahorros que financien la reconstrucción de infraestructura pública y la ayuda al sector privado. La resiliencia depende de las condiciones económicas generales del país.
3. **Vulnerabilidad financiera:** Se evalúa simulando los riesgos para el sector público y la capacidad financiera del gobierno para cubrir sus responsabilidades post-desastre en diferentes escenarios de magnitud.
4. **Impacto de la brecha de recursos:** Se analizan las consecuencias de esta brecha en variables macroeconómicas como el crecimiento económico y la deuda externa, que reflejan impactos en los flujos económicos, complementando la estimación de riesgos a los activos.
5. **Desarrollo de estrategias de gestión del riesgo:** Se diseñan estrategias que fortalezcan la resiliencia del sector público y mejoren el portafolio de gestión del riesgo. Estas estrategias se revisan continuamente para evaluar su impacto en la reducción de la vulnerabilidad financiera dentro del marco de modelación.

En el primer paso de CATSIM, se evalúa el riesgo de pérdidas directas en términos de la probabilidad de pérdidas en los activos de un país o región específicos. Siguiendo las prácticas generales, el riesgo se modela como una función de la amenaza, los elementos expuestos a dichas amenazas y su vulnerabilidad física (Hochrainer-Stigler et al. 2013):

- **Amenazas naturales:** Eventos como terremotos, huracanes o inundaciones se describen por su intensidad (por ejemplo, caudales máximos para inundaciones) y recurrencia (como eventos de 1 en 100 años, es decir, con una probabilidad del 1%).
- **Exposición:** La exposición de los elementos en riesgo se estima como el capital total, tanto público como privado.
- **Vulnerabilidad física:** Describe el grado de daño que puede sufrir el capital debido a la amenaza. El método estándar consiste en estimar curvas de vulnerabilidad o fragilidad, que relacionan el grado de pérdidas con la intensidad de la amenaza.

Con base en esta información, se pueden establecer las pérdidas potenciales provocadas por eventos destructivos en términos del porcentaje de capital perdido en un país, estado o región. Los datos sobre los periodos de retorno y las pérdidas sirven como insumos para CATSIM, generando distribuciones de frecuencia de pérdidas que relacionan probabilidades con activos destruidos.

A.8.3. Avances recientes e innovaciones

Se está desarrollando una versión basada en web para proporcionar datos personalizados a los países que han participado en talleres, permitiendo una evaluación interactiva de su riesgo ante eventos extremos.

Además, el equipo de Riesgo y Resiliencia de IIASA ha desarrollado un módulo CATSIM que cuantifica el impacto interindustrial de los desastres. Este modelo estima los costos económicos de los desastres en diversos sectores, teniendo en cuenta las estructuras productivas existentes en la economía y el tiempo estimado de recuperación tras el desastre. El modelo puede calibrarse utilizando conjuntos de datos comúnmente disponibles, como tablas de insumo-producto, y permite a los usuarios visualizar el beneficio económico de una mejor preparación fiscal (recuperación más rápida ante desastres). Este módulo de software ha sido creado como parte del marco CATSIM y puede utilizarse en evaluaciones de políticas y actividades de fortalecimiento de capacidades. Se están planeando desarrollos adicionales de software, que incluirán herramientas de interfaz y otras visualizaciones (IIASA 2024a).

Durante los últimos ocho años, la interfaz de usuario y el marco del modelo subyacente de CATSIM han sido probados, ajustados y mejorados en distintos niveles. Estos avances se basaron en más de 20 talleres de alto nivel con actores clave realizados en países como Turquía, Filipinas, India, Nepal, México, varias naciones del Caribe, y en Madagascar, en 2012 y 2015 (Hochrainer-Stigler et al. 2015).

A.8.4. Comunidad de desarrollo

IIASA ha trabajado extensamente con diversas organizaciones internacionales como el Banco Mundial y el Banco Interamericano de Desarrollo (BID). Además, ha colaborado con países específicos, como México y varias naciones del Caribe, para aplicar y optimizar el uso de CATSIM en la gestión del riesgo de desastres.

A.8.5. Limitaciones

El modelo ha sido desarrollado para análisis nacionales con el objetivo de evaluar impactos macroeconómicos y estrategias financieras para la gestión del riesgo de desastres. No está orientado a evaluación de riesgo a escalas locales. La versión actual de CATSIM es una aplicación independiente, lo que puede limitar su integración con otras herramientas y sistemas utilizados en la gestión de riesgos de desastres.

Además, CATSIM requiere de datos nacionales detallados, lo que puede ser un desafío para algunos países con limitaciones en la disponibilidad y calidad de los datos.

A.8.6. Casos de uso

CATSIM se ha utilizado en varios proyectos del Banco Mundial y su Informe sobre el Desarrollo Mundial para estimar el riesgo de desastres en más de 80 países. También contribuyó a una iniciativa del Banco Interamericano de Desarrollo para establecer el Regional Insurance Facility para Centroamérica, que ayuda a pequeños países a agrupar riesgos y acceder a capital externo para cubrirlos. Además, CATSIM fue clave en el diseño de la Caribbean Catastrophe Insurance Facility (CCRIF) en 2007, el primer fondo regional de gestión de riesgos de desastres, respaldado por el Banco Mundial y donantes como el Departamento de Desarrollo Internacional del Reino Unido. En 2007, se celebró un taller en Barbados con países del Caribe para discutir estrategias de gestión de riesgos, lo que ayudó a identificar formas eficientes de abordar los riesgos de desastres (IIASA 2024c).

Entre 2011 y 2012, IIASA utilizó CATSIM para apoyar un estudio del gobierno de Madagascar sobre la integración de la gestión de riesgos de desastres y el cambio climático en el desarrollo económico, tras el impacto del ciclón Gafilo, que causó 363 muertes y daños equivalentes al 5% del PIB (ver **Caja 9** para más detalles de este caso de estudio).

Finalmente, el análisis de CATSIM está informando deliberaciones sobre el Mecanismo de Pérdidas y Daños de la Convención Marco de las Naciones Unidas sobre el Cambio Climático, incluyendo la creación de un fondo global que absorba diferentes niveles de riesgos y apoye las actividades de reducción de riesgos y financiamiento en países vulnerables (IIASA 2024c).



Imagen: Flickr - BID Ciudades sostenibles / Panamá

Caja 9. Implementación del Modelo CATSIM en Madagascar



Imagen: Adobe Stock

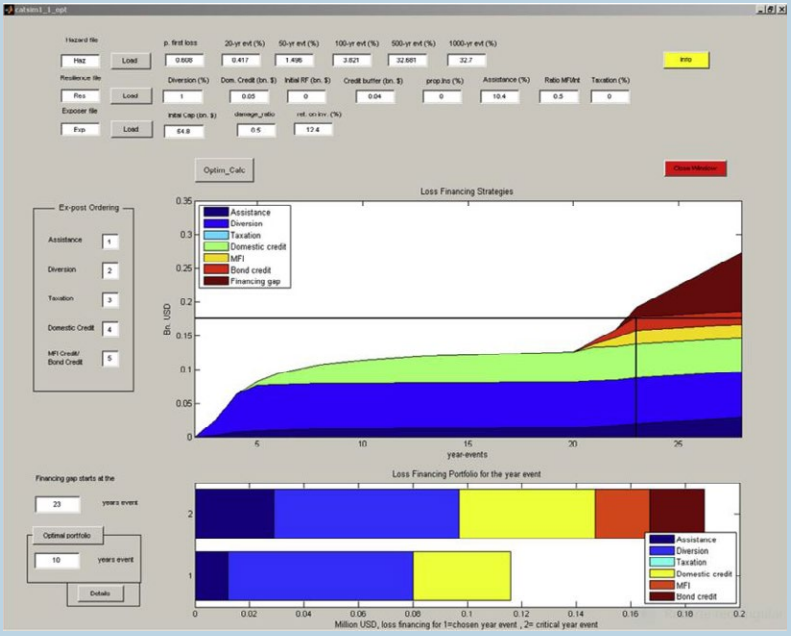
En mayo de 2012, Madagascar implementó el modelo CATSIM para integrar la gestión del riesgo de desastres en la planificación fiscal y de desarrollo, con apoyo del Banco Mundial y el GFDRR. El objetivo fue evaluar estrategias de manejo de riesgos ante eventos como ciclones, que generan pérdidas económicas considerables.

Taller de 2012: Evaluación Preliminar del Riesgo

El modelo CATSIM fue presentado en un taller con más de 30 representantes de ministerios (finanzas, educación e infraestructura). Se analizaron pérdidas históricas, estimaciones preliminares de riesgo y posibles brechas financieras frente a desastres.

Resultados del análisis probabilístico:

- Eventos de 100 años: pérdidas estimadas en 1,047 millones de USD.
- Pérdidas anuales esperadas: 55 millones de USD en promedio.
- Recursos internos disponibles: hasta 50 millones de USD, insuficientes para eventos mayores a 23 años de retorno.



Vulnerabilidad financiera y brecha de recursos para Madagascar utilizando las estimaciones base de riesgo directo. Nota: La figura central muestra los períodos de retorno en el eje x y los recursos necesarios/disponibles en el eje y. La figura inferior es un gráfico interactivo que permite a los usuarios explorar los detalles de la asignación fiscal alternativa de recursos en diferentes períodos de retorno.

- Principales hallazgos: Se identificaron brechas significativas en datos de exposición y vulnerabilidad física, priorizando su mejora para análisis futuros.

Taller de 2015: Evaluación Actualizada

Con datos más detallados, el gobierno revisó las estrategias financieras, destacando opciones como seguros y fondos de reserva. Se discutieron modelos internacionales (FONDEN y CCRIF) para adaptar mecanismos de protección financiera.

Retos y Recomendaciones

Fortalecimiento institucional y datos: Es crucial mejorar la recopilación y el intercambio de información interministerial.

Financiamiento sostenible: Implementar instrumentos financieros mixtos para cubrir eventos frecuentes y extremos.

Planeación integral: Integrar la gestión del riesgo con prioridades nacionales como educación y salud.

El uso de CATSIM en Madagascar resalta la necesidad de equilibrar el desarrollo económico con la resiliencia ante desastres, fomentando cooperación interinstitucional y preparación para eventos futuros.

Fuente: Hochrainer-Stigler et al. (2015).

A.9. RISKCHANGES

A.9.1. Descripción General

Desarrollado de forma colaborativa por la Universidad de Twente y el Centro de GeoInformática del Instituto Asiático de Tecnología (UN-SPIDER Regional Support Office), RiskChanges funciona como un sistema de soporte de decisiones espaciales de código abierto basado en la nube (RiskChanages 2021).

RiskChanges ofrece un conjunto de funciones diseñadas para realizar evaluaciones de riesgo. Su funcionalidad multiusuario facilita la colaboración entre diferentes partes interesadas, permitiendo el intercambio de datos y la generación colectiva de conocimientos. Además, soporta evaluaciones multiamenaza considerando las interacciones y efectos acumulativos. Entre sus capacidades también se incluyen análisis de múltiples activos, evaluación de vulnerabilidades, modelado de escenarios de riesgo, comparación de riesgos y análisis espacial avanzado con visualización (PreventionWeb 2023).

A.9.2. Métodos Aplicados

La plataforma permite a los usuarios analizar riesgos asociados a múltiples amenazas naturales y antropogénicas, considerando sus interacciones; evaluar riesgos para diversos tipos de activos con características espaciales variables; acceder y compartir una base de datos de curvas de vulnerabilidad física; comparar riesgos actuales con proyecciones futuras y diferentes alternativas de reducción de riesgos; realizar análisis espaciales de riesgos mediante una interfaz web de mapas (RiskChanges 2021).

La sección de exposición en RiskChanges permite calcular la interacción entre elementos expuestos y amenazas previamente cargados en la plataforma. Para realizar este cálculo, es necesario combinar una capa de elementos en riesgo (EAR) con una capa de amenaza, seleccionándolas desde las opciones disponibles en las secciones correspondientes del sistema de gestión de datos. Además, es posible agregar los resultados a niveles administrativos específicos utilizando capas previamente definidas. Si no se desea esta agregación, el cálculo se realizará a nivel de la capa EAR. Una vez configuradas estas opciones, el sistema calcula la exposición y los resultados pueden visualizarse o descargarse en formato tabular.

A partir de la exposición calculada, es posible estimar las pérdidas totales en función del tipo de elemento en riesgo (EAR). Antes de proceder, es esencial haber definido previamente las conexiones entre valores y poblaciones en la sección EAR. Los usuarios pueden seleccionar el tipo de cálculo deseado, y a partir de una lista de exposiciones precalculadas, generar estimaciones de pérdida. Los resultados se presentan en un formato visual y tabular, ofreciendo información detallada para evaluar los impactos de diferentes eventos (RiskChanges 2021).

El cálculo del riesgo en RiskChanges se basa en las pérdidas previamente estimadas. Los usuarios pueden optar por un análisis de riesgo para una amenaza única o para múltiples amenazas. En el caso de análisis multiamenaza, el proceso incluye pasos adicionales para integrar las combinaciones de pérdidas asociadas a diferentes periodos de retorno. Los resultados finales incluyen métricas como la pérdida promedio anual (AAL) y se presentan en formatos visuales y tabulares.

La interfaz de visualización en RiskChanges proporciona una ventana de capas en la esquina superior izquierda, donde los usuarios pueden navegar entre los datos calculados o agregados previamente, incluyendo amenazas, elementos en riesgo, exposición, pérdidas y riesgos. Los mapas interactivos permiten aplicar filtros, editar estilos (como paletas de colores y opacidad), y realizar comparaciones lado a lado entre capas.

A.9.3. Avances Recientes e Innovaciones

RiskChanges tiene capacidad para visualizar y comparar resultados de diversas maneras y permite un análisis integral y flexible de escenarios de riesgo. La plataforma integra datos directamente desde servidores de mapas y admite la carga de información personalizada en formatos GIS. Además, su infraestructura basada en la nube facilita el acceso, el procesamiento de datos y la colaboración en tiempo real entre múltiples usuarios, optimizando la gestión y la toma de decisiones en entornos multiamenaza (RiskChanges 2021). La última versión es la 2.1.0 de junio de 2022.

A.9.4. Comunidad de Desarrollo

RiskChanges fue desarrollada por la Universidad de Twente y el Centro de GeoInformática del Instituto Asiático de Tecnología (UN-SPIDER Regional Support Office) sin embargo no es claro que continúe su desarrollo a la fecha.

A.9.5. Limitaciones

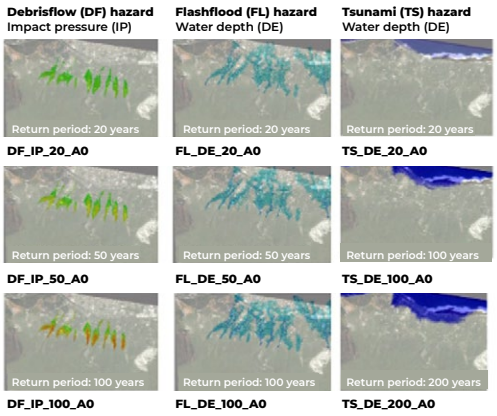
La plataforma requiere que los usuarios tengan conocimientos básicos en sistemas de información geográfica (GIS) y en la interpretación de datos de riesgos. Además, la documentación es muy limitada por lo que no hay claridad sobre el detalle de los métodos utilizados.

A.9.6. Casos de Uso

RiskChanges tiene aplicaciones en diversas áreas, incluyendo la evaluación y mapeo de riesgos, la planificación de la reducción de riesgos, la preparación y respuesta ante desastres, y la adaptación al cambio climático. PreventionWeb (2023) menciona que existen aplicaciones en Nepal, India, el Caribe y los países de la Comunidad de Desarrollo de África Austral (SADC), sin embargo, se encontró poca información sobre aplicaciones. La información disponible en la plataforma CMINE se muestra en la **Caja 10**.

Caja 10. Ejemplos de uso de RiskChanges

En el sitio web de la plataforma CMINE (https://www.cmine.eu/topics/35391/page/home) se presentan los siguientes tres casos de aplicación, aunque con información limitada. Los ejemplos solo muestran la información de amenaza que se usó y que no es generada directamente por la plataforma, sin presentar un ejemplo del tipo de resultados que produce RiskChanges. Desafortunadamente, no fue posible encontrar más información.

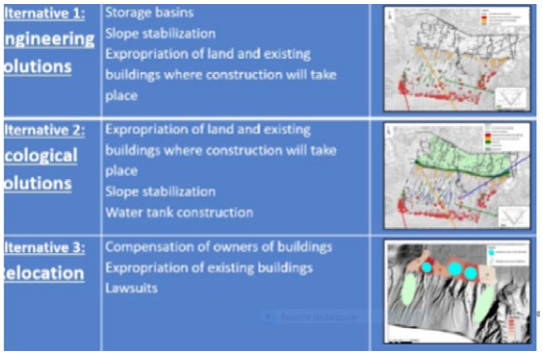


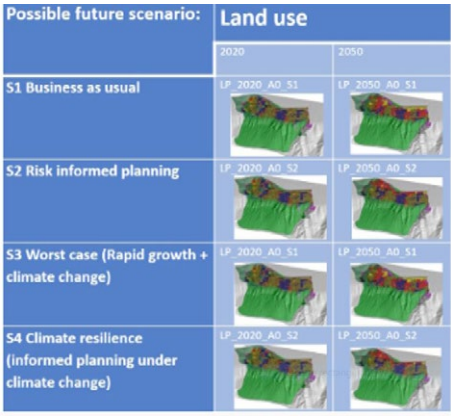
Situación actual

Simulación de una inundación fluvial en el río Koshi, en el norte de Nepal. El modelo de elevación es una estimación satelital WorldDEM Neo de 5m de resolución, que está disponible comercialmente en todo el mundo. Se utiliza una condición de contorno de descarga para simular un evento de flujo extremo. Los coeficientesde rugosidad de la superficie se estiman utilizando el uso integrado de WorldCover 10m.

Alternativa de reducción de riesgos

Simulación de inundaciones repentinas en la zona de Grande-Bay en Dominica. Esta zona se vio gravemente afectada en 2017 por el huracán María. Se cargó aquí un modelo de elevación personalizado con una resolución de 10 metros, aunque se podría obtener un resultado similar utilizando el conjunto de datos de elevación de 30 metros de Copernicus. El uso de la tierra y las precipitaciones se cargaron utilizando las herramientas integradas de FastFlood. Los edificios y las carreteras se muestran utilizando la descarga automática de datos de Open Street Maps.





Escenarios futuros

El río Geul es un pequeño sistema fluvial del sur de los Países Bajos con una extensión menor en Bélgica y Alemania. En 2021, el fenómeno de precipitaciones extremas que aazotó el noroeste del continente europeo provocó inundaciones en esta zona y daños importantes en ciudades como Valkenburg.

Esta simulación utiliza estimaciones automáticas de infiltración, canal y elevación. Se define una segunda área de modelo para Valkenburg utilizando el algoritmo de aumento de escala. La extensión de inundación observada, publicada por el Ministerio Nacional de Agua e Infraestructura, se muestra como una superposición.

Fuente: RiskChanges (2021).

A.10. FLOODRISK - QGIS PLUGIN

A.10.1. Descripción general

FloodRisk es un plugin para QGIS gratuito y de código abierto que proporciona una evaluación de las consecuencias de las inundaciones, incluyendo la pérdida de vidas humanas y los daños económicos directos. El plugin permite a los usuarios realizar una evaluación simple de riesgo considerando eventos fijos donde la probabilidad de cada uno se estima por separado y se calculan las consecuencias de manera determinista.

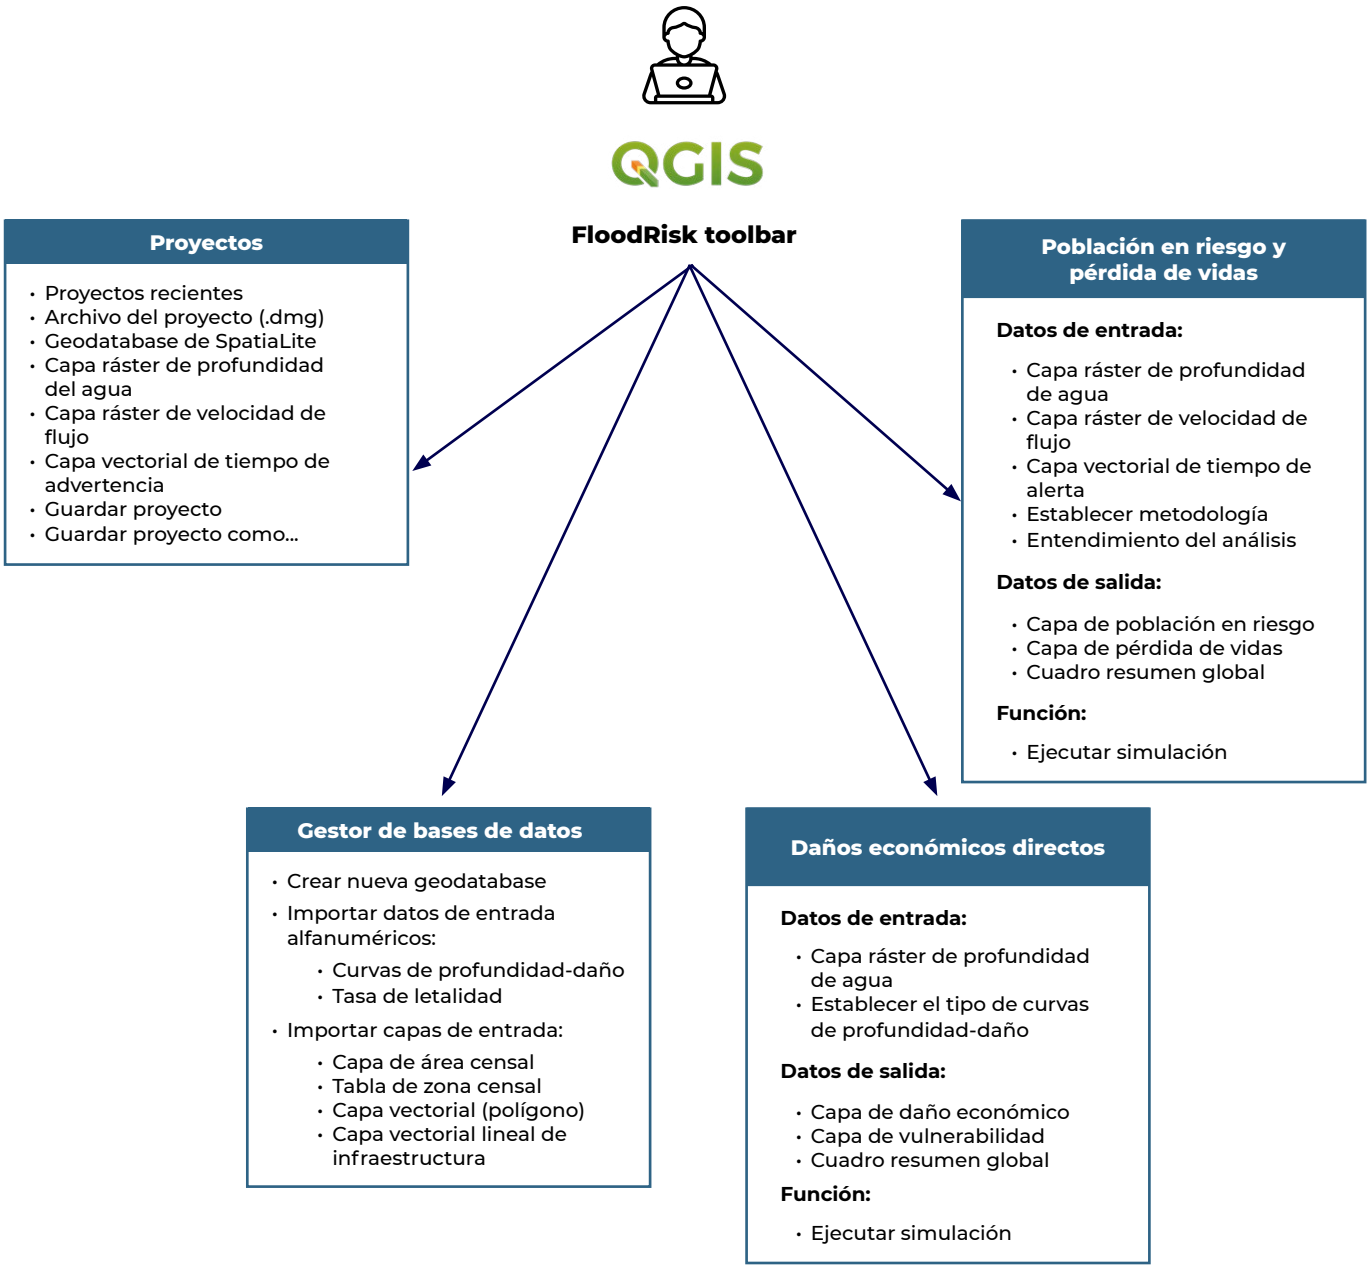
Incluye tipos de costos directos tangibles e intangibles, da cuenta de estrategias de mitigación estructurales y no estructurales, se puede utilizar para el análisis de dinámicas futuras (considerando la dinámica de riesgos) y promueve la colaboración y la comunicación a través de un enfoque de código abierto (Albano et al. 2017c).

La interfaz de usuario de FloodRisk se compone de cinco formularios principales (**Figura 55**). Estos formularios permiten guiar al usuario para llenar la base de datos con sus propios datos para crear o cambiar archivos de proyectos de FloodRisk y para realizar análisis de riesgos, es decir, evaluación de daños económicos por inundación y estimación de pérdida de vidas. La barra de herramientas permite la activación de los formularios principales. Además, FloodRisk contiene varios otros formularios (accesibles desde los formularios principales) para representar datos de entrada y salida como gráficos, tablas y mapas.



Imagen: Adobe Stock

Figura 55. Interfaz gráfica de usuário de de FloodRisk



Fuente: Albano et al. (2017c).

A.10.2. Métodos aplicados

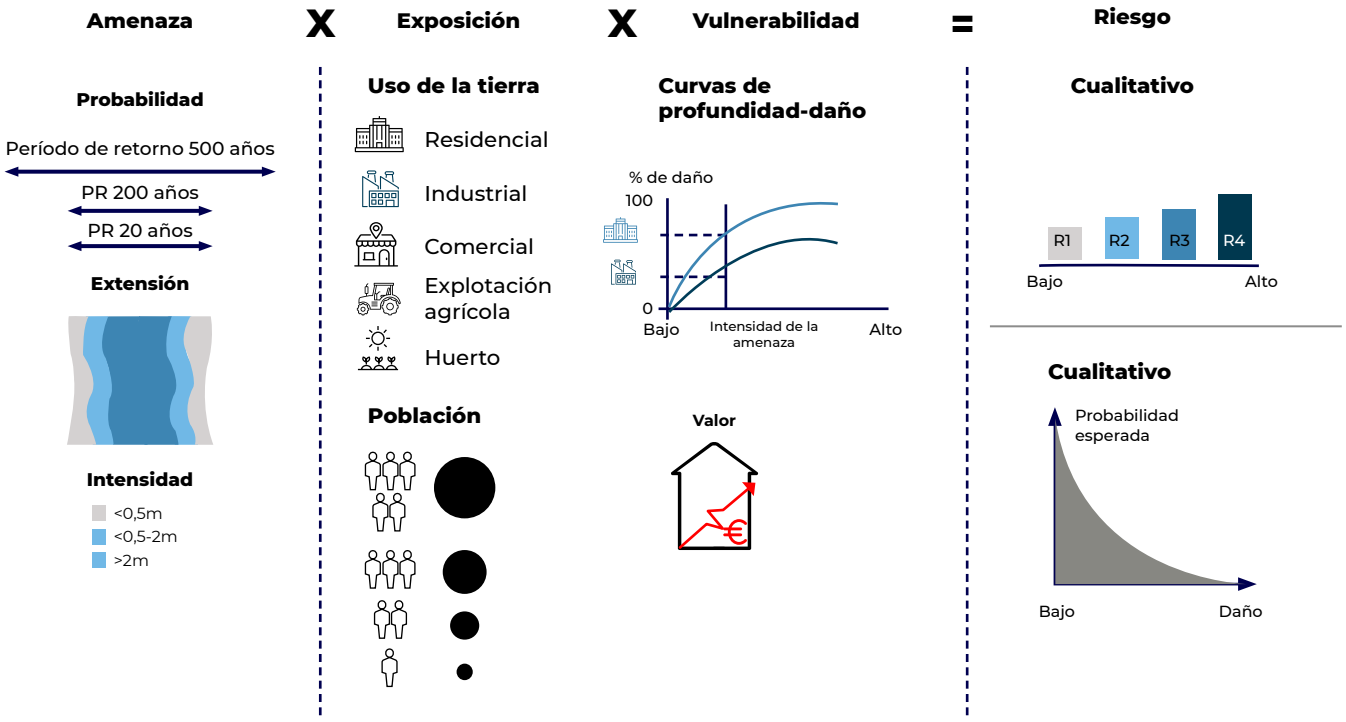
FloodRisk utiliza curvas de daño en función de la profundidad para evaluar los daños económicos directos a propiedades residenciales, comerciales e industriales. Para la estimación de la pérdida de vidas humanas, el plugin primero genera un mapa de la población en riesgo superponiendo el mapa de inundación con el mapa de densidad de población. Posteriormente, la pérdida de vidas se obtiene multiplicando la población en riesgo por la tasa de fatalidad seleccionada por el usuario. Estos resultados se muestran en forma de tablas, gráficos (histogramas) y mapas (Albano et al. 2017c).

El plugin permite estimar las consecuencias de las inundaciones, incluida la pérdida de vidas y los daños económicos directos, en consonancia con el enfoque de la Directiva Europea sobre Inundaciones. El complemento integra varias técnicas de evaluación del riesgo de inundación, incluidos enfoques meteorológicos, hidrológicos y socioeconómicos, dentro de un marco SIG. Esta herramienta apoya a los responsables de la toma de decisiones en la evaluación de las estrategias de mitigación de inundaciones y promueve prácticas sostenibles de gestión de riesgos.

El marco de trabajo del plug-in FloodRisk se basa en el método de pérdida unitaria y, por lo tanto, los parámetros que definen los elementos expuestos, las cifras de daño máximo y las funciones de daño afectan en gran medida los resultados. Además, FloodRisk permite el uso de un enfoque basado en objetos, que utiliza un gran número de tipos de objetos, como un mapa de edificios o un enfoque de uso del suelo (es decir, modelos basados en superficies agregadas, donde la entrada de datos de exposición tiene la forma de un mapa de uso del suelo) (Albano et al. 2017c).

El marco conceptual de FloodRisk (ver **Figura 56**) se basa en la modelación de inundaciones con diferentes períodos de retorno, que combinada con información de exposición y vulnerabilidad, permite el cálculo de los daños: con los daños por inundación correspondientes a diferentes probabilidades, se puede construir una curva de probabilidad de pérdida, a partir de la cual se puede calcular el daño anual esperado (EAD). Por último, en el modelo de daños se pueden implementar diferentes medidas de reducción de riesgo de inundación con el fin de calcular su eficacia. Con respecto a la evaluación de la vulnerabilidad, FloodRisk sigue un enfoque estándar, que refleja tanto el potencial de un receptor determinado para experimentar daños en caso de inundación como la cuantificación del número de propiedades o personas que pueden estar expuestas a un evento de inundación determinado en caso de que ocurra. Por lo tanto, el riesgo de inundación se evalúa mediante la combinación de los receptores expuestos a la amenaza y la susceptibilidad, el valor y la resiliencia de estos receptores. La susceptibilidad describe la propensión de un receptor particular a experimentar daño durante un evento de inundación dado. El enfoque estándar, utilizado en FloodRisk, para definir la susceptibilidad de los elementos en riesgo y estimar los daños directos por inundación es el uso de funciones de daño. Estas funciones definen, para los respectivos elementos en riesgo, la relación entre las características de la amenaza y exposición y el daño que se puede esperar en las circunstancias dadas. El valor se utiliza para expresar el grado de daño a un receptor, y puede expresarse en términos monetarios, como valor máximo de los activos, o por impactos intangibles (por ejemplo, el número de personas que pierden la vida) (Albano et al. 2017c).

Figura 56. Representación gráfica del enfoque FloodRisk



Fuente: Albano et al. (2017b).

A.10.3. Avances recientes e innovaciones

FloodRisk tuvo 5 versiones, la última de ellas generada en octubre de 2020. Posteriormente, fue reemplazado por FloodRisk2 para QGIS 3.x proporcionando la evaluación de las consecuencias de las inundaciones, en términos de pérdida de vidas y daños económicos directos, y la evaluación cuantitativa de los beneficios en términos de reducción de daños como resultado de las medidas de mitigación (FloodRiskGroup 2021). La versión más reciente del plugin, FloodRisk2, desarrollada para QGIS 3.x, incluye características adicionales y mejoras con respecto a la versión anterior para QGIS 2.x. Entre estas mejoras se encuentran una mayor integración con QGIS y mejoras en la interfaz de usuario. Investigaciones recientes han explorado la capacidad del complemento para analizar las incertidumbres en las evaluaciones de daño por inundaciones, enfatizando la necesidad de curvas de vulnerabilidad específicas del sitio y una clasificación detallada de los edificios para reducir la incertidumbre epistémica (Albano et al. 2018).

A.10.4. Comunidad de desarrollo

FloodRisk está desarrollado y mantenido por la comunidad FloodRiskGroup en GitHub vinculada a la Universidad de Basilicata.

A.10.5. Limitaciones

Una de las limitaciones del plugin FloodRisk es que realiza estimaciones de riesgo basadas en eventos con una probabilidad asociada, este enfoque generalmente implica el uso de unos pocos eventos, y no está originalmente diseñada para ejecutar cientos de simulaciones. Además, aunque el plugin permite la elección de tasas de fatalidad, estas pueden no representar adecuadamente las condiciones específicas de cada escenario de inundación.

A.10.6. Casos de uso

FloodRisk ha sido utilizado en proyectos para la evaluación de riesgos de inundación en Europa. Se utilizó en el estudio de caso de la inundación de 2006 en la cuenca de Ilisua en Rumania (Albano et al. 2017a) y en el caso de estudio del Valle del río Serio (Albano et al. 2017b) que se describe en la **Caja 11**.



Imagen: Adobe Stock

Caja 11. Ejemplo de aplicación de FloodRisk

Implementación de FloodRisk en el Valle del Serio: Estudio de Caso

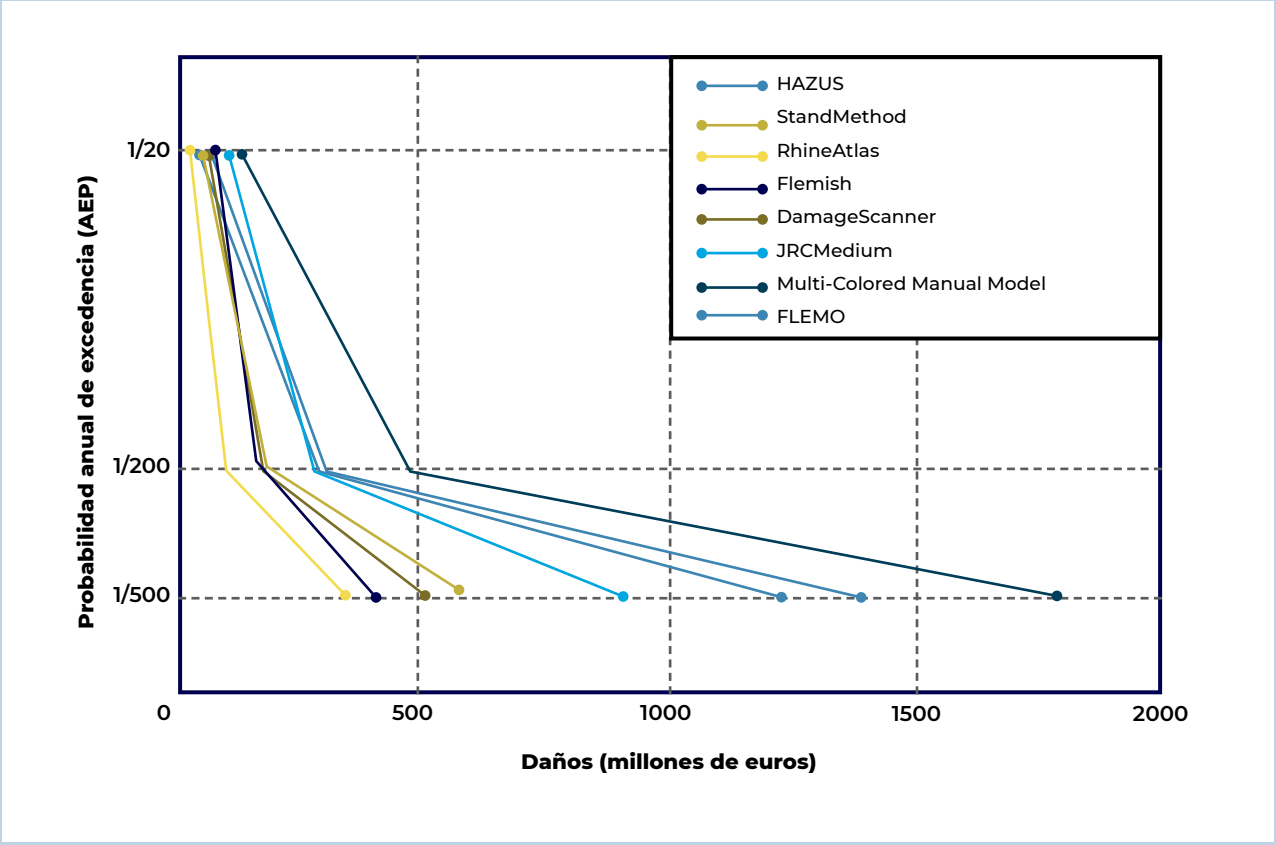


Imagen: Adobe Stock

Con una extensión de aproximadamente 600 km², el Valle del Río Serio abarca 52 municipios con una población total de 200,000 habitantes. El objetivo fue evaluar la viabilidad del enfoque de FloodRisk en un contexto real, con limitaciones de datos y recursos, enfocándose en la eficacia de los resultados para cumplir con los Planes de Gestión de Riesgos de Inundación.

Se adoptaron los mapas de amenaza de la cuenca del río Po existentes, que muestran áreas inundadas para diferentes periodos de retorno. La distribución espacial de la profundidad del agua se estimó con base en niveles de agua en diversas secciones transversales proporcionadas por la autoridad de cuenca del río Po. Además, se utilizaron mapas de uso del suelo y datos censales para identificar los activos en riesgo.

Las curvas de riesgo obtenidas con FloodRisk utilizando 8 curvas de daño diferentes se muestran en la siguiente figura:



FloodRisk permitió evaluar el impacto de medidas estructurales y no estructurales en la reducción del riesgo socioeconómico. Se realizó un análisis de costo-efectividad de medidas locales de reconstrucción y mantenimiento de las obras de protección fluviales, así como de medidas no estructurales como sistemas de alerta temprana.

Los resultados de FloodRisk están condicionados por la disponibilidad y calidad de los datos, lo cual genera incertidumbres significativas, especialmente en las curvas de daño por profundidad. Se realizó un análisis de sensibilidad enfocado en estas curvas, críticas para la estimación cuantitativa de riesgos económicos.

El enfoque FloodRisk demostró ser efectivo para el análisis de riesgos y la elaboración de mapas de riesgo de inundación cualitativos y cuantitativos. Aunque enfrenta desafíos como la disponibilidad de datos y la incertidumbre, ofrece una herramienta robusta para apoyar la toma de decisiones en la gestión de riesgos de inundación y la planificación de medidas de mitigación.

Fuente: Albano et al. (2017b)

A.11. FLOODRISE

A.11.1. Descripción general

FloodRISE (Flood Resilience, Insurance, and Spatial Equity) es un proyecto liderado por la Universidad de California, Irvine, que se enfoca en mejorar la resiliencia ante inundaciones mediante el desarrollo de simulaciones de amenaza de inundación de alta resolución. El proyecto tiene como objetivo proporcionar visualizaciones de riesgo de inundación que sean útiles para la toma de decisiones locales, involucrando a las comunidades en el proceso de co-desarrollo de mapas de amenaza de inundación.

A.11.2. Métodos aplicados

FloodRISE utiliza simulaciones de amenaza de inundación a escala métrica para evaluar riesgos en diferentes tipos de inundaciones (costeras, fluviales, pluviales). El enfoque incluye la participación iterativa de las partes interesadas a través de reuniones, encuestas y sesiones de capacitación para desarrollar mapas de amenaza de inundación personalizados para cada comunidad.

A.11.3. Avances recientes e innovaciones

El proyecto ha abordado desafíos emergentes en inundaciones costeras, incluyendo inundaciones compuestas. Además, ha desarrollado visualizaciones de amenaza de inundación que son accesibles en línea a través de visores, mejorando la comprensión y la gestión del riesgo de inundaciones en las comunidades involucradas.

A.11.4. Comunidad de desarrollo

FloodRISE es desarrollado por un equipo interdisciplinario de investigadores de la Universidad de California, Irvine, en colaboración con diversas partes interesadas, incluyendo autoridades locales, residentes y otros actores relevantes. Este enfoque colaborativo ha sido fundamental para el éxito del proyecto.

A.11.5. Limitaciones

La principal limitación identificada es que, aunque no se encontró información específica, parece que la herramienta solo está orientada a la visualización de la amenaza a pesar de indicar en su página web que es una contribución al análisis de riesgo y toma de decisiones. Otras limitaciones del proyecto FloodRISE incluyen la necesidad de datos de alta resolución y la dependencia de la participación continua de las partes interesadas locales para mantener la relevancia y precisión de las visualizaciones.

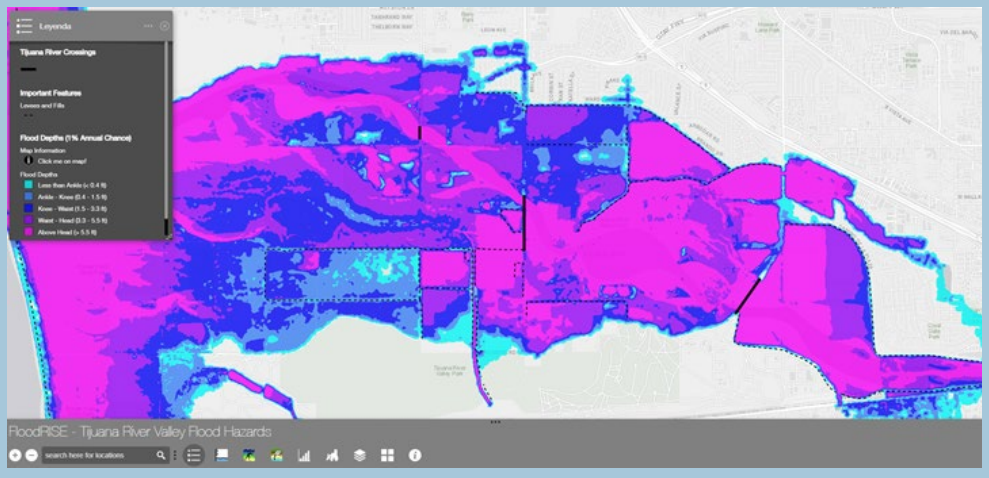
A.11.6. Casos de uso

FloodRISE ha sido implementado en varias comunidades, incluyendo el Valle del Río Tijuana y Newport Beach, donde ha ayudado a mejorar la preparación y respuesta ante inundaciones. Los mapas de amenaza de inundación desarrollados han sido utilizados para planificar y ejecutar medidas de mitigación y adaptación a inundaciones.

Caja 12. Ejemplo de aplicación de FloodRise

Amenaza de inundación Río Tijuana

El sitio web del proyecto muestra la herramienta de visualización de mapas que se muestra en la siguiente figura. No se encontró información adicional.



Fuente: FloodRise (2024).

A.12. DELFT-FIAT

A.12.1. Descripción General

Delft-FIAT (Flood Impact Assessment Tool) es una herramienta desarrollada por el Instituto de Investigación Deltares que se utiliza para evaluar de manera rápida los impactos económicos directos causados por inundaciones en infraestructuras, edificios, y carreteras. Esta herramienta, de código abierto y basada en Python, es especialmente útil en la planificación de la adaptación climática, ya que permite modelar rápidamente los impactos de diferentes escenarios de inundaciones y las medidas de mitigación correspondientes. Delft-FIAT destaca por su capacidad de automatización y flexibilidad, lo que la convierte en una solución adaptable a diferentes necesidades de análisis.

Delft-FIAT es rápido y puede automatizarse. Permite realizar múltiples simulaciones mediante scripts o interfaces personalizadas, haciendo posible calcular automáticamente cientos o incluso miles de estimaciones de daños. Esta capacidad facilita la evaluación del riesgo futuro asociado a factores cambiantes como el aumento del nivel del mar, la frecuencia de tormentas, el incremento de precipitaciones y el crecimiento de la población y la economía. Además, permite evaluar la eficacia de distintas intervenciones, como mejoras en los sistemas de drenaje, construcción de diques, muros marítimos, bombas de drenaje, elevación de viviendas o medidas de protección contra inundaciones, tanto en las condiciones actuales como bajo escenarios cambiantes (Deltares 2024b).

Las simulaciones de Delft-FIAT suelen tardar aproximadamente un minuto por escenario y pueden ejecutarse en modo batch para analizar múltiples escenarios definidos por el usuario. Su arquitectura flexible permite a los usuarios utilizar el software de diversas maneras sin modificar el código. Por ejemplo, pueden probar distintas funciones de daño por profundidad o incorporar categorías de daños más allá de los tradicionales, como daños a infraestructuras o interrupciones en el transporte o los negocios (Deltares 2024b).

Cualquier tipo de daño que pueda describirse mediante una función de daño por profundidad puede analizarse con Delft-FIAT. Además, los datos de exposición pueden modificarse fácilmente, y los mapas de amenaza (mapas de inundación) pueden provenir de cualquier fuente. Delft-FIAT también es personalizable, permitiendo su integración con interfaces de usuario diseñadas a medida para facilitar su uso por personas con menos experiencia técnica. Asimismo, puede conectarse con herramientas como PowerBI, ArcGIS Online o software de modelado de inundaciones, e incluso integrarse en sistemas operativos de pronóstico (Deltares 2024b).

El software también admite scripts personalizados para responder a preguntas específicas. Por ejemplo, se pueden analizar los impactos de la incertidumbre en la altura del piso de los edificios o en las funciones de daño. Esto permite realizar análisis de sensibilidad o integrar estas incertidumbres directamente en las estimaciones de daños (Deltares 2024b). Otra aplicación de Delft-FIAT es la estimación de puntos de inflexión, es decir, el momento en que una intervención de adaptación deja de cumplir con los niveles de servicio deseados. Al ejecutar simulaciones bajo condiciones futuras, es posible identificar estos puntos de inflexión. Los usuarios también pueden seleccionar métricas específicas para evaluar los niveles de servicio, como los daños anuales esperados, el número de viviendas inundadas en un evento con un periodo de retorno de 10 años o el número de hogares afectados cuyos ingresos estén por debajo del nivel de pobreza (Deltares 2024b).

A.12.2. Métodos Aplicados

Delft-FIAT emplea una metodología basada en funciones de daño por profundidad para evaluar los daños económicos de las inundaciones. Este enfoque permite que cualquier tipo de daño que pueda ser descrito con una función de daño por profundidad sea modelado en la herramienta. Además, su arquitectura flexible permite modificar fácilmente los datos de exposición y adaptar los mapas de amenaza que se utilizan como insumo. El software está diseñado para procesar grandes volúmenes de datos de forma rápida.

A.12.3. Avances Recientes e Innovaciones

El código de Delft-FIAT se encuentra actualmente en proceso de reestructuración para mejorar su rendimiento y flexibilidad, y será liberado como software de código abierto una vez finalizado.

Entre las nuevas funcionalidades en desarrollo se incluyen (Deltares 2024b):

- Generación automática de un informe resumido personalizado para cada simulación, con métricas como:
  - Número de viviendas dañadas
  - Cantidad de hospitales afectados
  - Longitud de carreteras inundadas por encima de un umbral definido por el usuario
- Cálculo de daños ponderados por equidad, para respaldar análisis de costo-beneficio más equitativos.
  Evaluación de impactos en el bienestar, con el objetivo de realizar evaluaciones más equitativas de las opciones de adaptación.
- Creación de un constructor de modelos para Delft-FIAT, diseñado para facilitar y acelerar la configuración y modificación de modelos en Delft-FIAT.

A.12.4. Comunidad de Desarrollo

Deltares, una organización de investigación aplicada en los campos de agua y subsuelo, lidera el desarrollo de Delft-FIAT. El software es de código abierto y está disponible bajo la licencia GNU GPL v3. La comunidad de usuarios incluye principalmente expertos en riesgos de inundaciones y especialistas en modelado hidrológico, quienes pueden contribuir al desarrollo y mejorar las capacidades del software a través de plataformas como GitHub.

A.12.5. Limitaciones

Su precisión depende de la calidad de los datos de entrada, especialmente los mapas de inundación y las funciones de daño. Además, aunque la herramienta es altamente automatizable, la configuración inicial y la adaptación de los datos de entrada pueden requerir un conocimiento técnico considerable.

A.12.6. Casos de Uso

Delft-FIAT ha sido implementado en comunidades con abundancia de datos y en aquellas con recursos limitados. Es la base del modelo nacional de daños de los Países Bajos y ha contribuido a proyectos en Estados Unidos, Australia, Asia, África, Europa, el Caribe, América Central y del Sur, así como en pequeños estados insulares en desarrollo (Deltares 2024b).

También forma parte de FloodAdapt, una herramienta de apoyo a la toma de decisiones para acelerar la planificación de la adaptación climática, actualmente en uso en proyectos piloto en Estados Unidos, Europa, Asia y África (Deltares 2024b).

Adicionalmente, Delft-FIAT ha sido aplicado en proyectos como interTwin, donde se integró con otros modelos para evaluar riesgos de inundación y desarrollar estrategias de mitigación. Ha servido como recurso clave para gobiernos y organizaciones al planificar la adaptación al cambio climático y evaluar la efectividad de diversas medidas de mitigación de inundaciones.

Caja 13. Ejemplo de aplicación de Delft-FIAT

Caribe resiliente: aumento del nivel del mar y potencial de adaptación en el Caribe

Deltares y el Banco Mundial, en colaboración con la Agencia de Gestión de Emergencias y Desastres del Caribe, evaluaron los impactos del aumento del nivel del mar como resultado de un aumento de las inundaciones y la erosión costeras en la región utilizando Delft-FIAT. El objetivo del estudio es derivar indicadores para estimar el potencial resiliente de cada país de la región y su potencial de adaptación.



Fuente: Deltares (2024a).

A.13. HEC-FDA

A.13.1. Descripción General

El software HEC-FDA (Hydrologic Engineering Center - Flood Damage Reduction Analysis) es una herramienta desarrollada por el Cuerpo de Ingenieros del Ejército de los Estados Unidos (USACE). Su principal objetivo es evaluar y cuantificar los daños económicos asociados con eventos de inundación, ayudando a la toma de decisiones en proyectos de reducción de riesgos por inundaciones. HEC-FDA emplea métodos probabilísticos para analizar la relación entre la frecuencia de inundaciones y los daños potenciales, permitiendo estimar beneficios y costos asociados con diferentes medidas de mitigación de riesgos.

A.13.2. Métodos Aplicados

HEC-FDA (Flood Damage Reduction Analysis) integra datos hidrológicos e hidráulicos, combinándolos con información económica sobre estructuras y contenido para calcular el daño potencial en función de diferentes escenarios de inundación. Esto se logra a través de análisis de frecuencia de inundaciones, curvas de daño, y funciones de vulnerabilidad, permitiendo una evaluación detallada y probabilística de los riesgos y beneficios económicos en proyectos de mitigación.

La metodología aplicada en HEC-FDA se enfoca en la evaluación del riesgo de inundación, el cual se define como la combinación de la probabilidad de que ocurra un evento de inundación y sus consecuencias.

En este contexto, la amenaza se refiere al evento que causa el daño, que en este caso es una inundación. HEC-FDA considera la amenaza mediante funciones hidrológicas e hidráulicas, las cuales describen la frecuencia, el caudal, el nivel del agua, la extensión y la profundidad de la inundación. El desempeño se refiere a la capacidad de un sistema, como un dique o presa, para responder ante la amenaza. HEC-FDA evalúa el desempeño utilizando la elevación del dique y una curva de respuesta del sistema, que relaciona la carga de la amenaza con la probabilidad de que el sistema falle (USACE 2024a).

Las consecuencias se miden en términos del daño económico que resulta de una inundación. Para ello, HEC-FDA emplea funciones que relacionan el nivel de agua con el porcentaje de daño en las estructuras y sus contenidos, integrando esta información en una curva de daño-frecuencia.

La exposición describe quiénes y qué están en riesgo de ser dañados por la inundación. Generalmente, en HEC-FDA la exposición se representa mediante inventarios de estructuras que contienen información sobre la población y las propiedades potencialmente afectadas por la inundación. HEC-FDA representa la vulnerabilidad utilizando funciones que correlacionan la profundidad del agua con el porcentaje de daño, además de considerar características estructurales como la elevación del primer piso.

Como resultado del análisis, HEC-FDA calcula el Daño Anual Esperado (EAD), una métrica que combina la probabilidad de que ocurra un evento de inundación con sus consecuencias económicas. Este cálculo se realiza integrando la información de la relación entre la frecuencia del nivel de agua, el daño por nivel de agua y la curva de daño-frecuencia (USACE 2024a).

Además de EAD, HEC-FDA genera métricas de desempeño que incluyen la Probabilidad Anual de Excedencia (AEP), que mide la probabilidad de que se supere un nivel específico en cualquier año, y la Probabilidad Condicional (CNP), que indica la probabilidad de que un objetivo específico no se supere, dado que ocurre un evento hidrometeorológico. HEC-FDA permite, de esta manera, una evaluación detallada del riesgo de inundación, proporcionando tanto un análisis de los daños económicos potenciales como una evaluación de la capacidad de los sistemas de protección para manejar estos riesgos (USACE 2024a).

Una vez calculado el EAD, se interpola entre los años de análisis, se descuenta al año base y se amortiza para calcular el Daño Anual Equivalente Promedio (Average Annual Equivalent Damage). Este proceso asegura que se consideren las fluctuaciones en los daños esperados a lo largo del tiempo, ajustándolos a un valor presente que facilita la comparación entre diferentes alternativas de mitigación de riesgos de inundación (USACE 2024b).

A.13.3. Enfoque matemático

La cuantificación de incertidumbre en HEC-FDA aplica la simulación de Monte Carlo para considerar explícitamente la incertidumbre en los parámetros básicos utilizados para determinar los daños por inundación. Con este enfoque, cada parámetro de entrada se puede expresar como una distribución empírica o analítica, y los valores de los parámetros para cada simulación de Monte Carlo se seleccionan utilizando números aleatorios. Este proceso puede aplicarse a todas las variables de entrada que se definen con incertidumbre en el análisis. HEC-FDA depende de un generador de números aleatorios y de las distribuciones empíricas y analíticas en el motor estadístico para ejecutar la simulación de Monte Carlo (USACE 2024c).

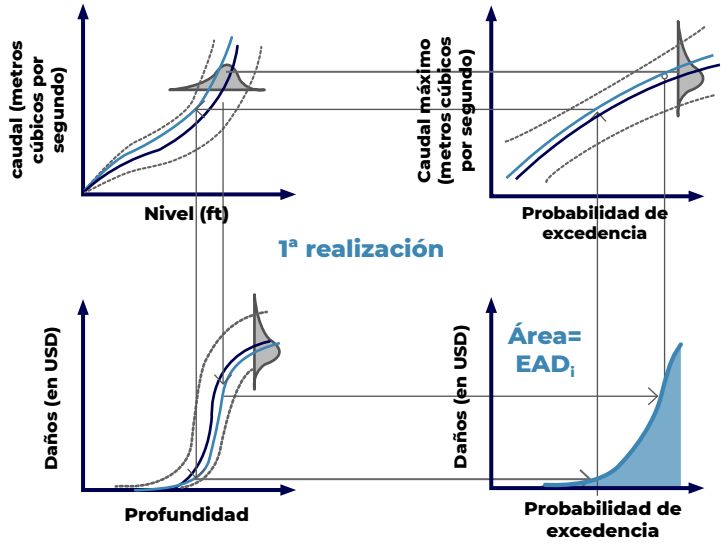
La incertidumbre se puede incluir explícitamente en el análisis asumiendo una distribución de densidad de probabilidad que mejor se ajuste para describir el rango de funciones probables. La simulación de Monte Carlo reemplaza una distribución de probabilidad por una muestra muy grande de valores aleatorios de esa distribución y evalúa cada miembro de la muestra para formar una nueva muestra del resultado del análisis.

El enfoque implementado en HEC-FDA se denomina muestreo de curvas y utiliza un muestreo aleatorio para alterar cada función en el cálculo de riesgo dentro de su incertidumbre, produciendo una realización de cada función. Cada función completa (frecuencia de caudal, nivel de agua, daño por inundación, etc.) se reemplaza por la función muestreada aleatoriamente para generar una gran muestra de curvas de salida.

Para realizar el cálculo de riesgo tradicional, se obtiene el caudal máximo de una cierta frecuencia y se relaciona con un nivel de agua, luego ese nivel se relaciona con un punto en la curva de vulnerabilidad o de daño por nivel para todas las frecuencias, con el fin de desarrollar una distribución de probabilidad para los daños (una curva de frecuencia de daños). El proceso de muestreo de curvas de Monte Carlo hace lo mismo, pero en lugar de una relación punto a punto, el proceso muestrea una curva completa dentro de su rango de incertidumbre. HEC-FDA utiliza la simulación de Monte Carlo para generar una nueva iteración de una curva seleccionando aleatoriamente parámetros dentro de las bandas de incertidumbre que rodean la curva. Al seleccionar aleatoriamente los parámetros que representan, por ejemplo, una curva de frecuencia de caudal, la curva varía aleatoriamente, modelando la naturaleza aleatoria de los eventos hidrológicos. Cada vez, se obtiene una nueva curva de la cual extraer datos. Este proceso se repite muchas veces para desarrollar una muestra de EAD que, al graficarse, puede describirse utilizando medidas de tendencia central y dispersión (es decir, media y percentiles). La muestra de EAD representa toda la incertidumbre inherente a las entradas utilizadas en la estimación.

La **Figura 57** ilustra el proceso para una realización del muestreo de curvas, que produce una estimación de EAD. Los límites de incertidumbre y distribución están representados por las curvas en forma de campana y las líneas punteadas. Con un muestreo aleatorio repetido (análisis de Monte Carlo), las distribuciones de incertidumbre se reproducen para capturar explícitamente la incertidumbre en el cálculo de riesgo y las métricas de riesgo. Se necesitan miles de realizaciones para reproducir completamente la incertidumbre en torno a cada función y, por lo tanto, en torno al EAD.

Figura 57. Cálculo de riesgo incluyendo la incertidumbre con muestreo de curvas



Fuente: USACE (2024c).

Matemáticamente, el EAD se define mediante una ecuación que integra la función de densidad de probabilidad del daño esperado a lo largo de todo el dominio de probabilidad, capturando así la gama completa de posibles daños en un solo valor, como se muestra en la **Ecuación 22.**

Ecuación 22

$$E\,[\mathrm{X}] = \int_{-\infty}^{\infty} x\, f_x(x)\, dx = \int_{-\infty}^{\infty} (\,1 - F_x(x))\, dx =$$

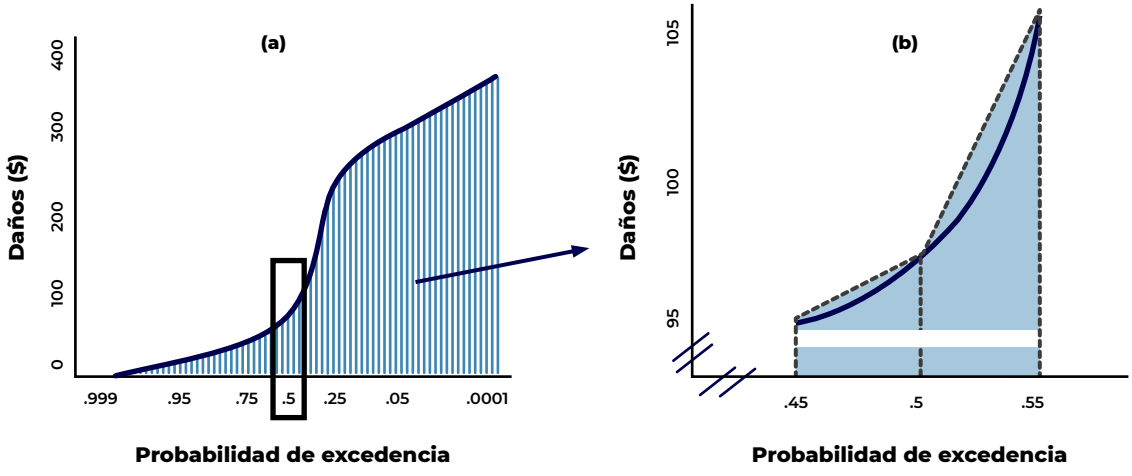
$$F_x(X) = P(X \le x) \text{ y } 1 - F_x(X) = P\,(X \le x)$$

Donde:
X = consecuencias, como por ejemplo el daño causado por la inundación, pérdida de vidas, o costos de atención de emergencia.

$E\,[X]$ = valor esperado de las consecuencias
x = valor de las consecuencias
$F_x(x)$ = función de densidad de la probabilidad de X
$F_x(x)$ = función de distribución acumulada de X

Esta integración se realiza gráficamente por HEC-FDA, utilizando la regla trapezoidal para calcular el área bajo la curva de daño-frecuencia. Un ejemplo de la regla trapezoidal se muestra en el panel (a) de la **Figura 58**. Para un intervalo de probabilidad de excedencia, el área bajo la curva se calcula como un trapezoide donde la parte superior del trapezoide es una línea recta entre los dos valores de la función. Este cálculo se repite en intervalos de probabilidad de excedencia entre 0 y 1. Como se muestra en el panel (b) de la figura, la precisión de la estimación del EAD se puede mejorar seleccionando intervalos de frecuencia más pequeños. HEC-FDA utiliza intervalos de frecuencia muy pequeños en el cálculo (USACE 2024d).

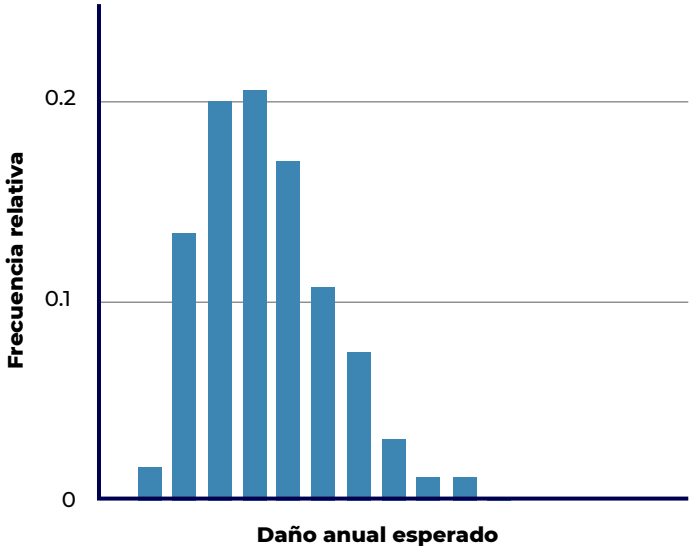
Figura 58. Regla trapezoidal para la integración de la curva



Fuente: USACE (2024d).

La **Figura 59** muestra un ejemplo de estimaciones de EAD resultantes del análisis de Monte Carlo, describiendo el impacto de las incertidumbres de conocimiento en el EAD.

Figura 59. Muestra de EAD incorporando la incertidumbre epistémica utilizando Montecarlo



Fuente: USACE (2024c).

La distribución de Daño Equivalente Promedio Anual (AAED) se calcula asumiendo una correlación perfecta entre la distribución del daño anual esperado (EAD) del año base y el EAD de los años futuros. En otras palabras, el primer percentil del EAD del año base y el primer percentil del EAD futuro se utilizan para calcular el primer percentil del AAED (USACE 2024e).

La reducción de daños se calcula como la diferencia entre los daños sin proyecto y los daños con proyecto, y esos daños pueden expresarse en términos de daño anual esperado o daño anual equivalente promedio. Se asume una correlación perfecta entre las dos distribuciones, de modo que el primer percentil de la reducción de daños se calcula restando el primer percentil del daño sin proyecto del primer percentil del daño con proyecto (USACE 2024f).

Además del EAD, las métricas de funcionamiento del sistema de protección contra inundaciones también son útiles y muy importantes. Estas métricas incluyen la Probabilidad de Excedencia Anual (AEP), la Probabilidad de Excedencia a Largo Plazo (LTEP) y la garantía, o Probabilidad Condicional de No Excedencia (CNP). La AEP y la LTEP pueden calcularse de manera determinística, mientras que la garantía es una estadística que requiere la incorporación de incertidumbre en la evaluación de riesgos (USACE 2024g).

A.13.4. Avances Recientes e Innovaciones

Entre las mejoras más recientes de HEC-FDA, se destaca la actualización a la versión 1.4.3, la cual incluye ajustes en la forma de calcular daños durante eventos de inundación poco frecuentes, como aquellos utilizados en la evaluación de seguridad de presas. Esta versión ha sido certificada por el Centro de Expertos en Planificación para la Gestión de Riesgos de Inundaciones del USACE, asegurando su aplicabilidad y precisión en estudios de planificación y seguridad de infraestructuras hidráulicas.

A.13.5. Comunidad de Desarrollo

El desarrollo de HEC-FDA está a cargo del Hydrologic Engineering Center del USACE, un centro especializado en la creación de herramientas y software para la gestión de recursos hídricos. La comunidad de desarrollo incluye ingenieros, científicos y planificadores que colaboran en la mejora continua del software, asegurando que cumpla con las necesidades técnicas y normativas en los estudios de gestión de riesgos de inundaciones. Además, la plataforma se mantiene activa con actualizaciones y certificaciones que reflejan los últimos avances en la gestión del riesgo.

A.13.6. Limitaciones

El software requiere datos detallados y precisos sobre la hidrología local, las estructuras existentes, y su vulnerabilidad a inundaciones. Sin estos datos, los resultados pueden ser imprecisos o no representativos. Además, la complejidad de su interfaz y la necesidad de conocimientos técnicos avanzados pueden dificultar su uso por parte de personal no especializado.

A.13.7. Casos de Uso

HEC-FDA se utiliza principalmente en la planificación de proyectos de mitigación de riesgos de inundación. Ha sido implementado en estudios de seguridad de presas, evaluación de riesgos en áreas urbanas, y en la planificación de infraestructura para reducir la vulnerabilidad ante inundaciones.



Imagen: Flickr - BID Ciudades sostenibles / Salina Cruz, México

Caja 14. Ejemplo de aplicación de HEC-FDA

Evaluación de Daños por Inundaciones en la Cuenca del Río Neka (Irán) utilizando HEC-FDA



Imagen: Adobe Stock

La cuenca del río Neka, situada en el extremo este de la provincia de Mazandarán (Irán), representa una región crítica para la gestión del riesgo de inundaciones. Su ubicación estratégica y características geográficas, como su origen en las alturas de Shah Kooh, su desembocadura en el Mar Caspio y su amplia cobertura forestal (80%), hacen de esta cuenca un área de estudio relevante.

El río Neka recorre aproximadamente 160 km y drena un área de 2004 km². Su pendiente longitudinal es del 1.9%, con un cauce que se vuelve más sinuoso al aproximarse a la ciudad de Neka.

Se calcularon caudales de inundación para periodos de retorno de 2, 5, 10, 20, 25, 50, 100 y 200 años con HEC-RAS, integrando coeficientes de rugosidad de Manning obtenidos mediante estudios hidráulicos y visitas de campo.



El análisis de daños por inundaciones se llevó a cabo de la siguiente manera:

- Se identificaron seis tipos de cobertura basados en el uso del suelo (residencial, comercial, industrial, público, parques y agrícola).
- Las profundidades de flujo obtenidas de HEC-RAS para diferentes periodos de retorno se almacenaron en formato compatible con HEC-FDA.
- Se utilizaron curvas de daño para cada cobertura de suelo.

Del análisis se obtuvieron los siguientes resultados:

- Se obtuvo la pérdida anual promedio en la región urbana de Neka, lo que permite priorizar intervenciones.
- Mapas de riesgos y zonificación: Con las salidas del modelo HEC-FDA, se generaron mapas de zonificación de riesgo de inundaciones, útiles para la planificación urbana y mitigación de riesgos.
- Gestión de desastres: Los resultados proporcionan insumos clave para diseñar mapas de rescate y planes de manejo de desastres, incluyendo estrategias de seguros contra inundaciones.

Fuente: Mohammadi et al. (2014).

A.14. OPENQUAKE

A.14.1. Introducción a OpenQuake

OpenQuake es una herramienta Open Source desarrollada en Python por el Global Earthquake Model (GEM) Foundation. Está diseñada para la evaluación del riesgo sísmico a través de modelos probabilísticos. OpenQuake permite a los usuarios simular eventos sísmicos y evaluar sus posibles impactos en términos de daños y pérdidas. El motor de OpenQuake se instala como un software independiente que puede ser manejado a través de un Plugin de QGIS.

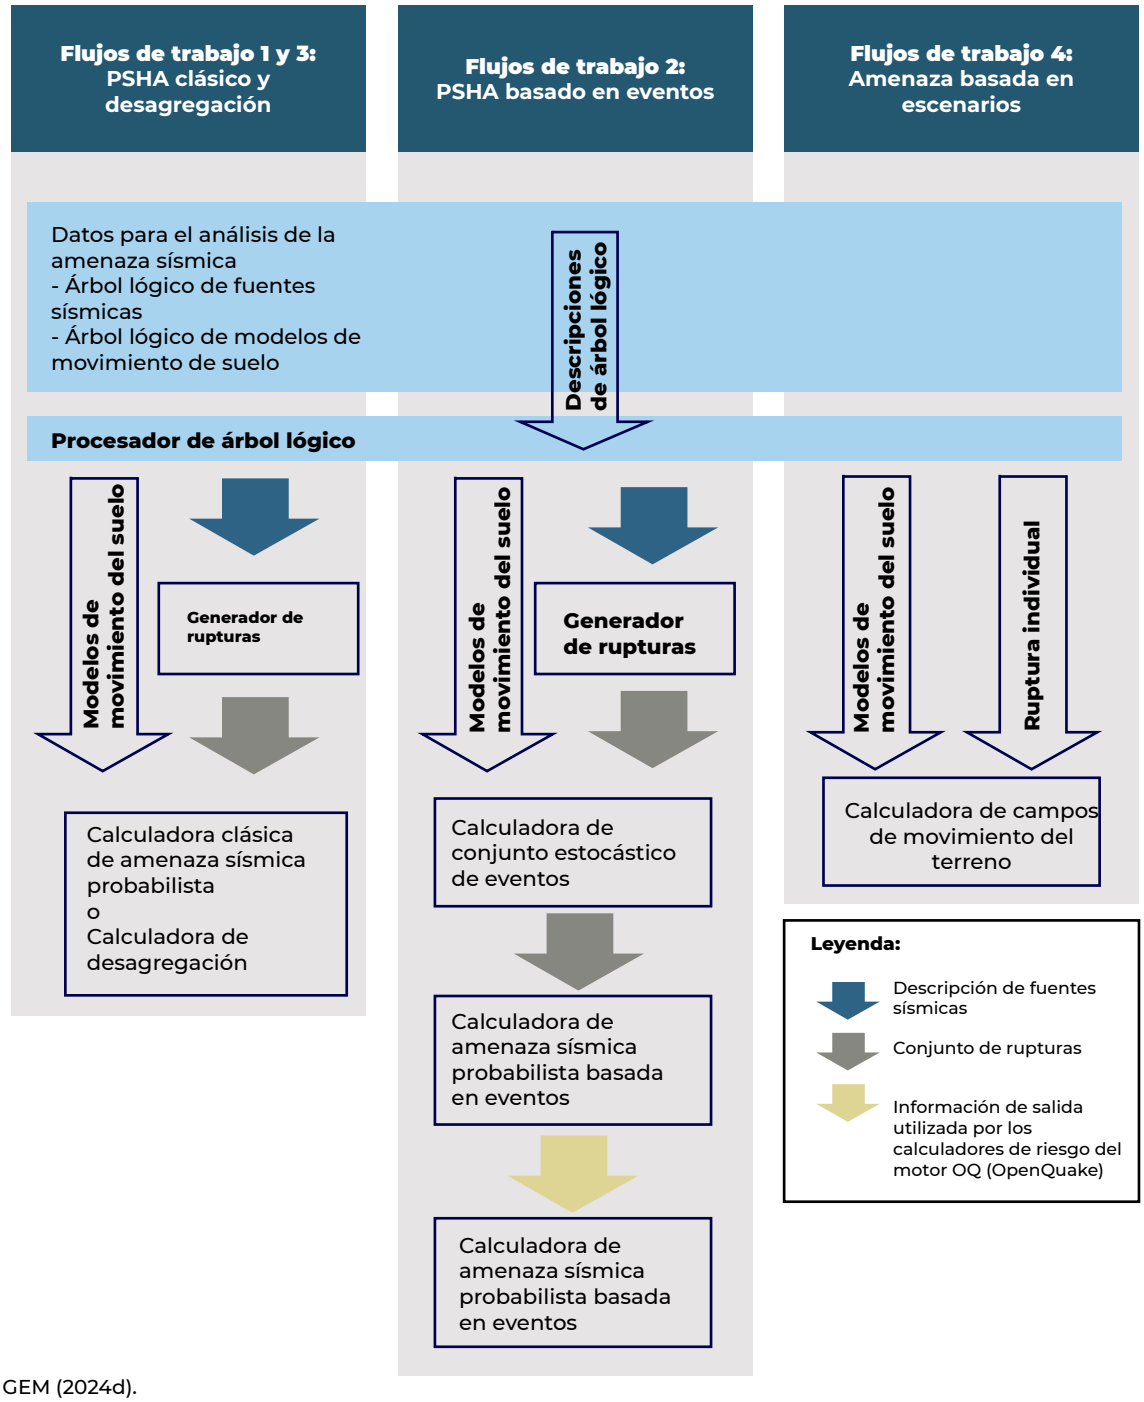
El plugin ha sido ampliado significativamente respecto a sus propósitos originales para funcionar de manera fluida con el OpenQuake Engine. Esto permite un flujo de trabajo completo en el que los cálculos de amenaza y riesgo se pueden ejecutar directamente en el entorno de QGIS, y los resultados se cargan como capas vectoriales de QGIS. Los mapas generados, como los mapas de amenaza, se estilizan automáticamente según los campos seleccionados por el usuario. Además, las curvas de riesgo se pueden generar en una ventana de Visualización de Datos, diseñada para este propósito (GEM 2024a).

A.14.2. Métodos aplicados

OpenQuake utiliza una variedad de métodos para el cálculo de riesgos sísmicos, incluyendo el Análisis Probabilístico de Amenaza Sísmica (PSHA) y el análisis basado en eventos. La plataforma también permite realizar simulaciones de escenarios sísmicos y evaluar las consecuencias de posibles eventos sísmicos a partir de la definición de la ruptura de una falla.

El componente de riesgo del motor OpenQuake proporciona cuatro flujos de trabajo de cálculo principales que se muestran en la **Figura 60**.

Figura 60. Esquema de los principales flujos de trabajo de cálculo del motor OpenQuake disponibles en el componente de riesgo



Fuente: GEM (2024d).

Los métodos utilizados se describen a continuación (GEM 2024d):

- **Análisis Clásico Probabilístico amenaza Sísmica (PSHA):** Calcula curvas de amenaza, mapas de amenaza y espectros de amenaza uniforme, resolviendo la integración PSHA propuesta por Field et al. (2003). Es común en evaluaciones de amenaza a escala regional/nacional y en estudios específicos. Utiliza curvas de amenaza junto con modelos de vulnerabilidad y exposición para derivar curvas de excedencia de pérdidas y mapas de pérdidas para diferentes periodos de retorno.

- **PSHA basado en eventos:** Calcula conjuntos de eventos estocásticos y campos de movimiento del suelo para cada ruptura, incluyendo la correlación espacial de residuos dentro del evento. Es un método basado en Monte Carlo para PSHA. Los catálogos sintéticos generados se comparan con catálogos reales, y de los campos de movimiento del suelo se derivan curvas de amenaza y mapas de amenaza. Estos campos son esenciales para estimaciones de pérdidas, sumando las pérdidas por activo en cada campo de movimiento para obtener una curva de excedencia de pérdidas total representativa de todos los activos.

- **Desagregación:** Con un modelo PSHA, identifica los escenarios sísmicos que más contribuyen a un nivel de amenaza específico en un sitio dado. Actualmente se realiza siguiendo la metodología clásica de PSHA, pero se añadirá al calculador basado en eventos en futuras fases de desarrollo.

- **Análisis del Riesgo Sísmico basado en escenarios (SHA):** Dado una ruptura sísmica y un modelo de movimiento del suelo, se pueden calcular conjuntos de campos de movimiento del suelo. Este método es típico para análisis de pérdidas a escala urbana, debido a que permite capturar la correlación de las pérdidas entre activos de un portafolio. Estos campos se utilizan con un modelo de fragilidad/vulnerabilidad para calcular la distribución de daños/pérdidas en una colección de activos.

Las principales fuentes de información de entrada necesarias además de la amenaza para un cálculo de riesgos con el motor OpenQuake son un modelo de exposición y un modelo de vulnerabilidad física o modelo de fragilidad (además del tipo de cálculo y la región de interés).

A.14.3. Enfoque matemático

OpenQuake ofrece tres tipos de cálculo que se describen a continuación (GEM 2024d).

Cálculo con base en escenarios

El calculador de riesgo basado en escenarios de OpenQuake calcula pérdidas y estadísticas de pérdidas a partir de un único evento para una colección de activos, utilizando un conjunto de campos de movimiento del suelo. Estos campos modelan la variabilidad aleatoria en las ecuaciones de predicción

de movimiento del suelo y pueden incluir o no la correlación espacial de los residuos del movimiento del suelo.

Los pasos para el cálculo son:

1. Los niveles de intensidad en cada sitio se combinan con una función de vulnerabilidad para cada activo, de la cual se extrae aleatoriamente una tasa de pérdida.

2. El motor toma la función de vulnerabilidad asignada a cada activo y comprueba si el coeficiente de variación es cero. Si es así, las tasas de pérdidas se derivan sobre la base de la relación de pérdidas medias para cada nivel de medida de intensidad. De lo contrario, si se define la incertidumbre, se muestrea aleatoriamente siguiendo la distribución probabilística de la *función de vulnerabilidad* respectiva, $\log LRn=\mu+\epsilon\sigma$ Donde μ y σ representan la media y la desviación estándar del logaritmo de las tasas de pérdidas, respectivamente, y ϵ es un término que tiene una distribución normal estándar con una media cero y una desviación estándar de uno. El método utilizado para muestrear épsilon depende de si se debe considerar o no la correlación entre la incertidumbre de vulnerabilidad de los activos de una taxonomía dada.

3. La tasa de pérdida media para cada activo en todas las simulaciones posibles del evento del escenario se puede calcular a través de la fórmula:

Ecuación 23

$$LR = \frac{\sum_{n=1}^{m} LR_n | \mathrm{IML}}{m}$$

Donde m representa el número de campos de movimiento del suelo simulados y IML niveles de medida de intensidad

Cálculo con base en eventos probabilísticos

El calculador de riesgo probabilístico basado en eventos utiliza conjuntos de eventos estocásticos y campos de movimiento del suelo para calcular curvas de excedencia de pérdidas para cada activo en un modelo de exposición. Este proceso combina niveles de medida de intensidad con funciones de vulnerabilidad para determinar tasas de pérdida, que pueden ser independientes o correlacionados. Las pérdidas se calculan para todos los campos de movimiento y se ordenan por tasa de pérdida. Luego, se calcula la tasa de excedencia y la probabilidad de excedencia de cada tasa de pérdida. Además, se puede realizar una desagregación de pérdidas por magnitud/distancia o coordenadas geográficas.

En este método, se estiman las pérdidas para cada activo para cada evento de la misma forma que para el cálculo con base en escenarios y luego se ordenan de mayor a menor. La tasa de excedencia de cada pérdida se calcula dividiendo el número de excedencias de esa pérdida por el número de conjuntos de eventos estocásticos multiplicado por la duración de cada conjunto de eventos. Por lo tanto, la pérdida más alta tendrá cero excedencias, la siguiente tasa de pérdida tendrá una excedencia, y así sucesivamente.

Ecuación 24

$$\lambda\,(L_n) = \frac{NE_L}{TSES}$$

Donde λ representa la tasa de excedencia del ratio de pérdida respectivo, NE_L representa el número de excedencias de la pérdida dada, y $TSES$ representa el período de tiempo de todos los conjuntos de eventos estocásticos, es decir, el número de conjuntos de eventos estocásticos multiplicado por la duración de cada uno.

Asumiendo una distribución de Poisson del modelo de ocurrencia, la probabilidad de excedencia del conjunto de pérdidas en un período de tiempo dado se puede derivar usando la siguiente fórmula:

Ecuación 25

$$PE(L_n) = 1 - exp - \lambda_n \text{ x } t$$

Donde t representa el período de tiempo utilizado para producir el conjunto de eventos estocásticos.

Para la desagregación de las pérdidas es necesario proporcionar las coordenadas de las ubicaciones donde se debe emplear este procedimiento. Luego, para las ubicaciones seleccionadas, la engine de OpenQuake calcula la suma de las pérdidas (considerando todos los activos existentes en cada uno de los sitios seleccionados) para cada evento sísmico. Además, se estima la distancia de la ruptura (Joyner-Boore) y las coordenadas del punto dentro de la proyección vertical del plano de ruptura más cercano a cada sitio.

La engine de OpenQuake calcula el rango (valores máximos y mínimos) de la lista de magnitudes, distancias, latitudes y longitudes en todos los eventos, y utilizando el incremento definido para cada parámetro, se calcula un conjunto de intervalos linealmente espaciados. Luego, las pérdidas de cada evento sísmico se agregan dependiendo en qué combinación de magnitud/distancia o latitud/longitud caen.

Las pérdidas resultantes para cada par de parámetros (magnitud/distancia y latitud/longitud) se dividen por la pérdida total en todos los eventos.

Cálculo de Riesgo Basado en PSHA Clásico

La calculadora de riesgo basada en PSHA clásica se utiliza para calcular curvas de excedencia de pérdidas para activos individuales, calculadas sitio por sitio, utilizando curvas de amenaza. Esta calculadora requiere curvas de amenaza como entrada, las cuales pueden ser calculadas por la engine de OpenQuake. Actualmente, esta calculadora solo puede calcular pérdidas directas, aunque en futuras versiones se incluirán pérdidas aseguradas.

Para utilizar esta calculadora, las curvas de amenaza primero deben convertirse en funciones de masa de probabilidad (por ejemplo, probabilidad de ocurrencia de un conjunto discreto de niveles de medida de intensidad). Para hacerlo, la engine comienza leyendo los niveles de medida de intensidad de las funciones de vulnerabilidad discretas y calcula el valor central entre niveles consecutivos. Dos valores consecutivos definen los límites del intervalo para cada nivel de medida de intensidad y, relacionando estos límites con la curva de amenaza, la engine calcula las probabilidades correspondientes de excedencia.

La probabilidad de ocurrencia (PO) de los niveles de medida de intensidad que caen dentro de cada intervalo se puede derivar restando las probabilidades de excedencia de los límites inferior y superior, como se describe en la siguiente fórmula:

Ecuación 24

$$PO = PE\,[lowerbound] - PE\,[uperbound]$$

Las funciones de vulnerabilidad discretas para cada activo se convierten en matrices de excedencia de ratios de pérdida (por ejemplo, matrices que describen la probabilidad de excedencia de cada tasa de pérdida para un conjunto discreto de niveles de medida de intensidad). Estas matrices tienen un número de columnas igual al número de niveles de medida de intensidad definidos en la función de vulnerabilidad y un número de filas que puede ir desde el número de ratios de pérdida definidos por la función discreta hasta cualquier múltiplo de este número. Para incorporar adecuadamente la distribución probabilística de las tasas de pérdida por nivel de medida de intensidad, las probabilidades de excedencia deben calcularse no solo para las tasas de pérdida definidos en la función de vulnerabilidad, sino también para muchos valores intermedios entre tasas de pérdida consecutivas. Después de varios análisis de sensibilidad, parece que cinco valores intermedios entre tasas de pérdida consecutivos es un valor razonable; sin embargo, este es un parámetro que el usuario puede ajustar.

Finalmente, cada columna de la matriz mencionada anteriormente se multiplica por la probabilidad de ocurrencia del respectivo nivel de medida de intensidad (extraído de las curvas de amenaza) para producir una matriz de excedencia de tasas de pérdida condicional. Luego, para cada tasa de pérdida, se suman las probabilidades de excedencia, llevando a una curva de excedencia de tasas de pérdida, cuyo conjunto de tasas de pérdida puede multiplicarse por el valor del activo dado por el modelo de exposición para obtener una curva de excedencia de pérdida absoluta.

A.14.4. Avances recientes e innovaciones

La versión 3.23 de OpenQuake Engine es una actualización de Soporte a Largo Plazo (LTS) que ofrece mejoras significativas en rendimiento, especialmente para modelos grandes, con una velocidad de 3 a 4 veces mayor en comparación con la versión 3.16. Introduce nuevas funcionalidades en el cálculo de riesgos y amenazas, incluyendo mejoras en el manejo de modelos de sitio, cálculos de escenarios y la incorporación de nuevos Modelos de Predicción de Movimiento del Suelo (GMPEs). Además, se ha integrado el proyecto OQ-Impact, que amplía las capacidades de evaluación de impacto, y se han corregido varios errores para mejorar la estabilidad y precisión del software (GEM 2024e) .

Además, en términos de funcionalidad, a partir de la versión 3.19 toda la documentación asociada con el uso de la plataforma se unificó y migró a una página web (https://docs.openquake.org/oq-engine/master/manual/index.html), lo cual mejora su accesibilidad y hace que la información requerida sea más sencilla de encontrar.

A.14.5. Comunidad de desarrollo

El motor OpenQuake se desarrolla mediante una estrecha y continua colaboración entre los equipos científicos y de TI de GEM. El proceso de desarrollo se lleva a cabo de forma abierta para promover la participación de expertos que trabajan en las disciplinas de análisis de riesgos y amenaza sísmica, así como de aquellos especializados en el desarrollo de software (GEM 2024d).

El código de OpenQuake se encuentra disponible en GitHub lo que garantiza un control de versiones exhaustivo y facilita el seguimiento de la implementación de funciones y la corrección de errores. También garantiza que se puedan recuperar fácilmente las versiones anteriores del software. Cuando un desarrollador envía un nuevo código al repositorio principal, se conserva el registro del cambio. Si el código tiene como objetivo resolver un error o un fallo identificado en el sistema de seguimiento de errores, o implementar una nueva función en respuesta a una solicitud, el registro de la contribución del código debe indicar el error o la función específicos que el cambio de código pretende resolver. De este modo, se mantiene un registro exhaustivo y auditable de cada problema identificado y de los cambios en el código realizados para resolverlo (GEM 2024d).

A.14.6. Limitaciones

Dada su larga trayectoria y su comunidad de desarrollo que lleva a cabo mejoras continuas a la plataforma, las limitaciones de OpenQuake son más relacionadas con su funcionalidad que con su capacidad. Al ser una herramienta capaz de manejar modelos muy complejos, puede tener una curva de aprendizaje empinada, especialmente para usuarios con poca experiencia en modelado de riesgos, lo cual se ve reflejado en que los mismos desarrolladores recomiendan que los usuarios tengan un nivel de maestría en sismología para manejar la plataforma correctamente.

Actualmente la herramienta cuenta con una página web dedicada exclusivamente a el entrenamiento en el uso de la plataforma (https://www.training.openquake.org/), donde se cuenta con varios módulos y recursos para el aprendizaje enfocado a usuarios principiantes. Sin embargo, estos recursos fueron desarrollados en el 2020 para la versión 3.9 de la plataforma, por lo que ya en su mayoría el contenido se encuentra desactualizado.

Además, es una herramienta desarrollada sólo para riesgos sísmicos, por lo que se requiere un grado de especialidad y compromiso muy alto, aunque sólo se pueda utilizar para una sola amenaza. Esto genera el requisito de tener múltiples plataformas, modelos y profesionales para evaluar riesgos en un contexto multiamenaza.

A.14.7. Casos de uso

OpenQuake ha sido utilizado en numerosos proyectos de evaluación de riesgos sísmicos a nivel mundial. Existen ejemplos de aplicación en Latinoamérica, Estados Unidos, Europa, Asia y Africa (Azizi 2024).



Imagen: Adobe Stock

Caja 15. Ejemplo de aplicación de OpenQuake

Caso de Estudio: Implementación de OpenQuake para la Evaluación del Riesgo Sísmico en India



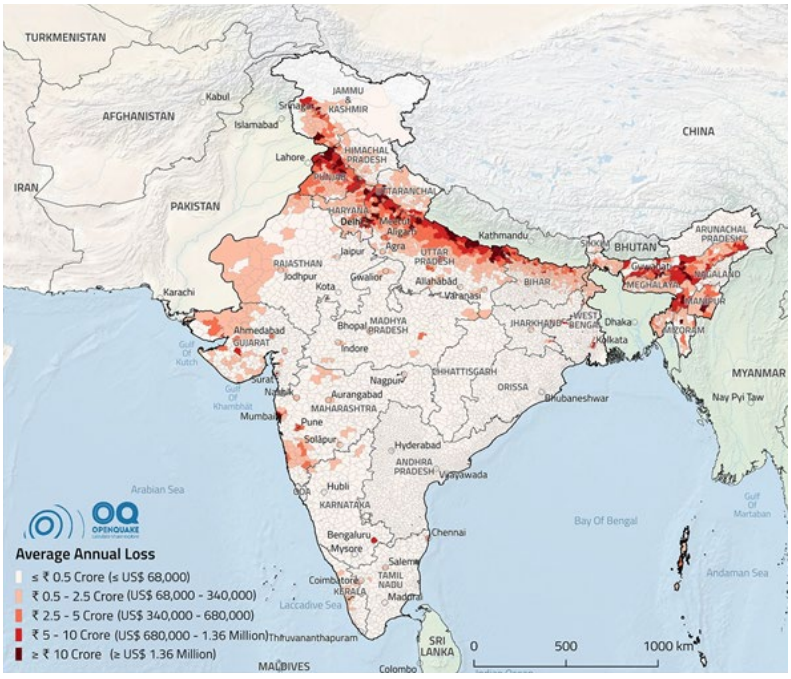
Imagen: Adobe Stock

El riesgo sísmico probabilístico para India fue estimado utilizando la plataforma OpenQuake para mejorar la comprensión de las amenazas y riesgos sísmicos en todo el país. Este modelo sirve como una herramienta crítica para evaluar la exposición, la vulnerabilidad y el riesgo, permitiendo establecer objetivos de mitigación de riesgos racionales y priorizar inversiones en la gestión de desastres.

El estudio destaca los desafíos enfrentados en el desarrollo de un modelo nacional de riesgo sísmico, particularmente la falta de información detallada sobre el inventario actual de edificios y la escasez de modelos de fragilidad y vulnerabilidad sísmica para varios tipos de edificios en India. Las evaluaciones anteriores se han centrado principalmente en análisis basados en escenarios para ciudades específicas, que, aunque valiosos, no proporcionan la resolución necesaria para el análisis de riesgo a nivel nacional.

Se empleó el motor OpenQuake para calcular métricas de amenaza sísmica, incluyendo la aceleración máxima del suelo (PGA) y la aceleración espectral, utilizando un enfoque de evaluación probabilística del peligro sísmico (PSHA). El modelo incorpora una amplia gama de tipos de edificios y prácticas de construcción, lo que permite una comprensión del riesgo en diferentes regiones. Los resultados incluyen mapas de amenaza promedio y curvas de excedencia de pérdidas, que son esenciales para las actividades de planificación y preparación.

Mapa de la pérdida promedio anual para la India obtenida con OpenQuake



Además, el estudio subraya la importancia de la mejora continua del modelo a través de evaluaciones locales y la recopilación de datos empíricos. La naturaleza abierta de los conjuntos de datos y los componentes del modelo fomenta la colaboración entre expertos y partes interesadas, promoviendo un enfoque impulsado por la comunidad para la gestión del riesgo sísmico.

En conclusión, la implementación de la plataforma OpenQuake para la evaluación del riesgo sísmico en India representa un avance significativo en el campo de la reducción del riesgo de desastres. El modelo no solo proporciona información crítica para mejorar los códigos de diseño sísmico nacionales, sino que también sirve como base para futuras investigaciones y toma de decisiones informadas sobre riesgos en áreas propensas a sismos.

Fuente: Rao et al. (2020).

ANEXO B. TIPOS DE DATOS

Los principales tipos de datos requeridos para la evaluación de amenazas, vulnerabilidad y exposición en estudios de riesgo de desastres, así como sus formatos comunes y las herramientas de software utilizadas para su procesamiento son:

- **Los datos vectoriales:** representan elementos geográficos utilizando geometrías como puntos, líneas y polígonos. Cada geometría está asociada a una tabla de atributos que contiene información descriptiva sobre ese elemento (ESRI, Esri Products, s.f.)

  Puntos: representan ubicaciones únicas, como pozos, sensores o estaciones meteorológicas.

  Líneas: representan elementos lineales como ríos, calles o redes eléctricas.

  Polígonos: representan áreas como lagos, zonas agrícolas o límites administrativos.

  Extensiones más comunes: .shp, .geojson, .dwg, .dxf, .kml

- **Nubes de puntos:** son conjuntos masivos de puntos en el espacio 3D, cada uno con coordenadas X, Y, Z y, a veces, con información adicional como intensidad o clasificación (suelo, vegetación, edificios). Se generan comúnmente mediante sensores LiDAR (Light Detection and Ranging) desde drones o aviones.

  Estas nubes de puntos permiten crear modelos 3D del terreno, edificios o vegetación, y pueden ser utilizadas para generar productos como Modelos Digitales de Elevación (MDE) o Modelos de Superficie (MDS). (Neuvition, s.f.)

  Extensiones más comunes: .las, .xyz

- **Imágenes rasterizadas y satelitales:** están compuestas por una cuadrícula regular de píxeles, donde cada píxel contiene un valor (como color, temperatura, elevación, etc.). Estas imágenes se utilizan para representar fenómenos continuos sobre la superficie terrestre. Las imágenes satelitales son un tipo de ráster capturado por sensores remotos montados en satélites. Pueden contener múltiples bandas espectrales y permiten analizar variables como vegetación (NDVI), temperatura, humedad del suelo, y más (ESRI, Esri Products, s.f.).

  Extensiones más comunes: .tiff, .geotiff, .img.

- **Los datos espacio-temporales:** contienen información georreferenciada que varía a lo largo del tiempo. Es decir, no solo tienen una dimensión espacial (latitud, longitud, altitud), sino también una dimensión temporal (hora, día, año, etc.). Este tipo de datos permite analizar cambios en el clima, patrones meteorológicos, evolución de amenazas, entre otros (NOAA, s.f.)

  Extensiones más comunes: .nc, grib

La siguiente tabla resume las principales extensiones y tipo de dato utilizados:

Tabla 1. Tipos de datos, formatos y herramientas usadas

Datos	Tipo de Datos	Formatos Comunes	Herramientas de Análisis / Software
Datos geoespaciales	Elevación, pendiente, relieve (DEM, MDT), curvas de nivel	• .tif, • .asc, • .las, • .xyz	ArcGIS, QGIS, Global Mapper, CloudCompare, LAStools
	Cobertura y uso del suelo	• .tif, • .img, • .shp, • .geojson	Google Earth Engine, ArcGIS, QGIS, SNAP
Climáticos y meteorológicos	Índices climáticos (NDVI, SPI, SPEI, FWI)	.nc, .tif, .csv	R (raster, SPEI package), Python, ArcGIS Pro, GEE
Socioeconómicos y demográficos	Infraestructura crítica y redes de servicios	• .shp, • .dwg, • .dxf	AutoCAD, ArcGIS, QGIS
Amenazas específicas	Fallas geológicas, volcanes, zonas de deslizamiento, cuencas	• .shp, • .tif, • .kml, • .geojson	ArcGIS, QGIS, SAGA GIS, GRASS GIS
Modelos climáticos	Proyecciones CMIP6, ERA5, CHIRPS, CRU	• .nc, • .zip, • .grib	Climate Data Store Toolbox, Python (xarray), Panoply, QGIS





Imagen: Flickr - BID Ciudades sostenibles / Natal Brasil


BID
Mejorando vidas