

NOTAS TÉCNICAS Nº IDB-TN-03139

# Revisão de métodos e ferramentas de software para avaliação de riscos de desastres

María Carolina Rogelis  
María Alejandra Escovar  
Andrés Abarca  
Kenneth Otálora  
Walter Cortes  
Ginés Suarez

Banco Interamericano de Desenvolvimento  
Unidade de Gestão de Riscos de Desastres

Setembro de 2025



# Revisão de métodos e ferramentas de software para avaliação de riscos de desastres

María Carolina Rogelis  
María Alejandra Escovar  
Andrés Abarca  
Kenneth Otálora  
Walter Cortes  
Ginés Suarez

Banco Interamericano de Desenvolvimento  
Unidade de Gestão de Riscos de Desastres

Setembro de 2025

<http://www.iadb.org>

Copyright © 2025 Banco Interamericano de Desenvolvimento. Esta obra está licenciada sob uma licença Creative Commons CC BY 3.0 IGO (<https://creativecommons.org/licenses/by/3.0/igo/legalcode>). Os termos e condições indicados no link URL devem ser atendidos e o respectivo reconhecimento deve ser concedido ao BID.

Além da seção 8 da licença acima, qualquer mediação relacionada a disputas decorrentes de tal licença deve ser conduzida de acordo com as Regras de Mediação da OMPI. Qualquer controvérsia relacionada ao uso das obras do BID que não possa ser resolvida amigavelmente deverá ser submetida à arbitragem de acordo com as regras da Comissão das Nações Unidas sobre Direito Comercial Internacional (UNCITRAL). O uso do nome do BID para qualquer finalidade que não seja atribuição e o uso do logotipo do BID estarão sujeitos a um contrato de licença por escrito separado entre o BID e o usuário e não está autorizado como parte desta licença.

Observe que o link da URL inclui termos e condições que são parte integrante desta licença.

As opiniões expressas nesta publicação são de responsabilidade dos autores e não refletem necessariamente a posição do Banco Interamericano de Desenvolvimento, de sua Diretoria Executiva, ou dos países que eles representam.



# REVISÃO DE MÉTODOS E FERRAMENTAS DE SOFTWARE PARA AVALIAÇÃO DE RISCOS DE DESASTRES

---

## **Autores**

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

---

# REVISÃO DE MÉTODOS E FERRAMENTAS DE SOFTWARE PARA AVALIAÇÃO DE RISCOS DE DESASTRES

---

**Autores:**

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

---






Imagem: Adobe Stock

# INTRODUÇÃO

---

A avaliação do risco de desastres é um componente fundamental do gerenciamento de riscos e do planejamento de medidas de redução de riscos e adaptação. Nos últimos anos, o desenvolvimento de ferramentas especializadas aprimorou a capacidade analítica por meio do uso de metodologias avançadas que incorporam a análise de diversos tipos de ameaças, modelos matemáticos, inteligência artificial, abordagens de governança e considerações sobre as mudanças climáticas. Este documento fornece uma análise detalhada das principais plataformas e métodos usados no cálculo de riscos, destacando suas capacidades, limitações e áreas de aplicação.

O documento está estruturado em oito seções. Na Seção 2, são apresentadas as ferramentas existentes para o cálculo de riscos, diferenciando entre aquelas que permitem a avaliação de multiameaças e aquelas especializadas em riscos específicos, como inundações e terremotos. A Seção 3 explora o uso da inteligência artificial na gestão de riscos de desastres, incluindo aplicações em mitigação, preparação e resposta. Na Seção 4, são descritos os modelos matemáticos usados para a estimativa de riscos, desde abordagens baseadas em eventos probabilísticos até métodos específicos de quantificação de incertezas implementados em diversas ferramentas. A Seção 5 analisa metodologias que incorporam a vulnerabilidade social e a governança na análise de riscos. A Seção 6 é dedicada à avaliação de riscos relacionados às mudanças climáticas, com foco especial no CLIMADA, a única plataforma revisada com métodos específicos para essa finalidade. Posteriormente, a Seção 7 descreve os produtos globais de precipitação disponíveis gratuitamente que podem ser usados na análise de ameaças hidrometeorológicas. Por fim, a Seção 8 discute as informações globais disponíveis para a avaliação da exposição e da vulnerabilidade, que são aspectos fundamentais da estimativa de riscos de desastres.

Este documento tem como objetivo fornecer uma visão geral abrangente das ferramentas e metodologias disponíveis, facilitando sua seleção e aplicação em estudos de risco em diferentes escalas e contextos.

---

<sup>1</sup> A conceituação da classificação das medidas de redução de riscos pode variar de acordo com o país e suas regulamentações. Por exemplo, na Colômbia (lei 1523 de 2012), a redução de riscos é composta pela intervenção corretiva de riscos existentes, pela intervenção prospectiva de novos riscos e pela proteção financeira.


<sup>2</sup> O termo multiameaças é o equivalente em inglês a multi-hazard que, de acordo com o Escritório das Nações Unidas para a Redução do Risco de Desastres, significa: (1) a seleção de vários ameaças importantes enfrentados pelo país e (2) os contextos específicos nos quais os eventos de perigo podem ocorrer simultaneamente, em cascata ou se acumular ao longo do tempo, levando em conta os possíveis efeitos interrelacionados.

SEÇÃO

1

## REVISÃO DAS FERRAMENTAS EXISTENTES PARA O CÁLCULO DE RISCO

Ferramentas existentes para cálculo de risco são apresentadas, distinguindo-se aquelas que permitem avaliação multirrisco daquelas especializadas em riscos específicos, como inundações e terremotos.



SEÇÃO

2

## MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NO CÁLCULO DE RISCOS

Explora o uso da inteligência artificial na gestão do risco de desastres, incluindo aplicações em mitigação, preparação e resposta.




SEÇÃO

3

## MODELOS MATEMÁTICOS NO CÁLCULO DE RISCO DE DESASTRES NAS PLATAFORMAS DE CÁLCULO DE RISCO

Analisa metodologias que incorporam vulnerabilidade social e governança nas análises de risco.



SEÇÃO

4

## MÉTODOS QUE INCORPORAM A VULNERABILIDADE SOCIAL E/OU A GOVERNANÇA NA ANÁLISE DE RISCOS

Analisa metodologias que incorporam vulnerabilidade social e governança nas análises de risco, com foco em riscos específicos, como inundações e terremotos.




SEÇÃO

5

## MUDANÇAS CLIMÁTICAS E CÁLCULOS DE RISCO

É dedicado à avaliação de risco considerando as mudanças climáticas, com ênfase particular no CLIMADA, a única plataforma revisada que inclui métodos específicos para esse fim.




SEÇÃO

6

## PRODUTOS GLOBAIS DE PRECIPITAÇÃO DISPONÍVEIS GRATUITAMENTE

Descreve produtos globais de precipitação de acesso aberto que podem ser usados em análises de perigos hidrometeorológicos.



SEÇÃO

7

## INFORMAÇÕES GLOBAIS DISPONÍVEIS GRATUITAMENTE PARA ANÁLISE DE EXPOSIÇÃO E VULNERABILIDADE

Aborda as informações globais disponíveis para avaliar exposição e vulnerabilidade, que são aspectos-chave na estimativa do risco de desastres.



# CONTEÚDO

## INTRODUÇÃO ..... 04

### **1** **REVISÃO DAS FERRAMENTAS EXISTENTES PARA O CÁLCULO DE RISCO ..... 11**

<b>1.1. INTRODUÇÃO</b> .....	<b>12</b>
<b>1.2. PLATAFORMAS MULTIAMEAÇA</b> .....	<b>13</b>
2.2.1. Introdução .....	14
2.2.2. Acessibilidade .....	16
2.2.3. Comunidade de desenvolvimento e suporte .....	18
2.2.4. Atualizações e melhoria contínua do software ..	20
2.2.5. Interface gráfica .....	22
2.2.6. Estrutura conceitual para a estimativa do risco estimation .....	23
2.2.7. Comparação de ferramentas .....	26
<b>1.3. PLATAFORMAS PARA O CÁLCULO DE RISCO DE INUNDAÇÃO</b> .....	<b>28</b>
<b>1.4. PLATAFORMAS PARA O CÁLCULO DO RISCO SÍSMICO</b> .....	<b>30</b>
2.4.1. Acessibilidade .....	30
2.4.2. Comunidade de desenvolvimento e suporte ...	31
2.4.3. Atualizações e melhoria contínua .....	31
2.4.4. Interface gráfica .....	32
2.4.5. Estrutura conceitual para a estimativa do risco .....	32
<b>1.5. CONCLUSÕES</b> .....	<b>33</b>

### **2** **MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NO CÁLCULO DE RISCOS ..... 35**

<b>2.1. INTRODUÇÃO</b> .....	<b>36</b>
<b>2.2. APLICAÇÕES DA IA NO GERENCIAMENTO DE RISCOS DE DESASTRES</b> .....	<b>40</b>
2.2.1. Mitigação e preparação para desastre .....	43
2.2.2. Resposta a desastres .....	60
<b>2.3. DESAFIOS</b> .....	<b>62</b>

### **3** **MODELOS MATEMÁTICOS NO CÁLCULO DE RISCO DE DESASTRES NAS PLATAFORMAS DE CÁLCULO DE RISCO DISPONÍVEIS ..... 67**

<b>3.1. INTRODUÇÃO</b> .....	<b>68</b>
<b>3.2. CURVAS DE VULNERABILIDADE E DE FRAGILIDADE</b> .....	<b>72</b>
<b>3.3. AVALIAÇÃO PROBABILÍSTICA COMPLETA DAS PLATAFORMAS AVALIADAS</b> .....	<b>76</b>
<b>3.4. AVALIAÇÃO PROBABILÍSTICA SIMPLIFICADA DE DE RISCO NAS PLATAFORMAS AVALIADAS</b> .....	<b>78</b>
<b>3.5. AVALIAÇÃO MISTA DETERMINÍSTICA-PROBABILÍSTICA</b> .....	<b>81</b>
<b>3.6. RESUMO</b> .....	<b>83</b>


### **4** **MÉTODOS QUE INCORPORAM A VULNERABILIDADE SOCIAL E/OU A GOVERNANÇA NA ANÁLISE DE RISCOS ..... 88**

<b>4.1. INTRODUÇÃO</b> .....	<b>89</b>
<b>4.2. MÉTODOS INCORPORADOS NO PLUG-IN DO OPENQUAKE</b> .....	<b>91</b>
<b>4.3. PLUGINS QGIS PARA ANÁLISE MULTICRITÉRIO</b> .....	<b>93</b>
4.3.1. Modelo de Avaliação de Sustentabilidade Espacial (SSAM) .....	94
4.3.2. Análise Multicritério Ponderada (WMCA) .....	94

### **5** **MUDANÇAS CLIMÁTICAS E CÁLCULOS DE RISCO ..... 96**

<b>5.1. INTRODUÇÃO</b> .....	<b>97</b>
<b>5.2. ESTIMATIVA DE RISCO AO INCORPORAR A MUDANÇA CLIMÁTICA NAS PLATAFORMAS</b> .....	<b>98</b>
<b>5.3. ABORDAGEM DE MUDANÇA CLIMÁTICA DA CLIMADA</b> .....	<b>100</b>
<b>5.4. MÉTODOS INCORPORADOS NA CLIMADA PARA MUDANÇAS CLIMÁTICAS</b> .....	<b>104</b>
<b>5.5. PONTOS-CHAVE PARA A ANÁLISE DE RISCO NO CONTEXTO DAS MUDANÇAS CLIMÁTICAS</b> .....	<b>107</b>

# 6



## PRODUTOS GLOBAIS DE PRECIPITAÇÃO DISPONÍVEIS GRATUITAMENTE ..... 110

<b>6.1. INTRODUÇÃO</b> .....	<b>111</b>
<b>6.2. PRODUTOS DE PRECIPITAÇÃO POR SATÉLITE</b> .....	<b>112</b>
<b>6.3. PRODUTOS DE REANÁLISE</b> .....	<b>117</b>

# 7



## INFORMAÇÕES GLOBAIS DISPONÍVEIS GRATUITAMENTE PARA ANÁLISE DE EXPOSIÇÃO E VULNERABILIDADE ..... 120

<b>7.1. EXPOSIÇÃO</b> .....	<b>121</b>
7.1.1. Modelos globais .....	122
7.1.2. Informações disponíveis que podem ser usadas para gerar camadas de exposição .....	128
<b>7.2. VULNERABILIDADE</b> .....	<b>139</b>

## REFERÊNCIAS ..... 141

## ANEXOS ..... 155

### ANEXO A. CARACTERÍSTICAS DAS FERRAMENTAS EXISTENTES PARA O CÁLCULO DE RISCO ..... 156

<b>A.1. CAPRA (PROBABILISTIC RISK ASSESSMENT PLATFORM)</b> .....	<b>156</b>
A.1.1 DESCRIÇÃO GERAL .....	156
A.1.2 MÉTODOS APLICADOS .....	156
A.1.3 ABORDAGEM MATEMÁTICA .....	158
A.1.4 AVANÇOS RECENTES NO CAPRA .....	159
A.1.5 COMUNIDADE DE DESENVOLVIMENTO .....	160
A.1.6 LIMITAÇÕES .....	160
A.1.7 CASOS DE USO .....	160
<b>A.2. HAZUS</b> .....	<b>163</b>
A.2.1 DESCRIÇÃO GERAL .....	163
A.2.2 MÉTODOS APLICADOS .....	163
A.2.3 ABORDAGEM MATEMÁTICA .....	173
A.2.4 AVANÇOS RECENTES E INOVAÇÕES .....	178
A.2.5 COMUNIDADE DE DESENVOLVIMENTO .....	178
A.2.6 LIMITAÇÕES .....	178
A.2.7 CASOS DE USO .....	178

### A.3. RISKScape: FERRAMENTA DE AVALIAÇÃO DE RISCO ..... 181

A.3.1 DESCRIÇÃO GERAL .....	181
A.3.2 MÉTODOS APLICADOS .....	181
A.3.3 ABORDAGEM MATEMÁTICA .....	185
A.3.4 AVANÇOS RECENTES E INOVAÇÕES .....	193
A.3.5 COMUNIDADE DE DESENVOLVIMENTO .....	193
A.3.6 LIMITAÇÕES .....	194
A.3.7 CASOS DE USO .....	194

### A.4. INASAFE ..... 199

A.4.1 DESCRIÇÃO GERAL .....	199
A.4.2 MÉTODOS APLICADOS .....	199
A.4.3 AVANÇOS RECENTES E INOVAÇÕES .....	202
A.4.4 COMUNIDADE DE DESENVOLVIMENTO .....	202
A.4.5 LIMITAÇÕES .....	202
A.4.6 CASOS DE USO .....	202

### A.5. OASIS LOSS MODELLING FRAMEWORK (OASIS LMF) ..... 205

A.5.1 DESCRIÇÃO GERAL .....	205
A.5.2 MÉTODOS APLICADOS .....	207
A.5.3 ABORDAGEM MATEMÁTICA .....	210
A.5.4 AVANÇOS RECENTES E INOVAÇÕES .....	213
A.5.5 COMUNIDADE DE DESENVOLVIMENTO .....	213
A.5.6 LIMITAÇÕES .....	213
A.5.7 CASOS DE USO .....	213

### A.6. INTERDEPENDENT NETWORKED COMMUNITY RESILIENCE MODELING ENVIRONMENT IN-CORE ..... 216

A.6.1 DESCRIÇÃO GERAL .....	216
A.6.2 MÉTODOS APLICADOS .....	218
A.6.3 ABORDAGEM MATEMÁTICA .....	233
A.6.4 AVANÇOS RECENTES E INOVAÇÕES .....	234
A.6.5 COMUNIDADE DE DESENVOLVIMENTO .....	234
A.6.6 LIMITAÇÕES .....	234
A.6.7 CASOS DE USO .....	234

### A.7. CLIMADA (CLIMATE ADAPTATION) ..... 237

A.7.1 DESCRIÇÃO GERAL .....	237
A.7.2 MÉTODOS APLICADOS .....	237
A.7.3 ABORDAGEM MATEMÁTICA .....	239
A.7.4 AVANÇOS RECENTES E INOVAÇÕES .....	243
A.7.5 COMUNIDADE DE DESENVOLVIMENTO .....	243
A.7.6 LIMITAÇÕES .....	243
A.7.7 CASOS DE USO .....	243


<b>A.8. CATSIM (CATASTROPHE SIMULATION TOOL)</b> .....	<b>247</b>	<b>A.12. DELFT-FIAT</b> .....	<b>266</b>
A.8.1 DESCRIÇÃO GERAL .....	247	A.12.1 DESCRIÇÃO GERAL .....	266
A.8.2 MÉTODOS APLICADOS .....	248	A.12.2 MÉTODOS APLICADOS .....	267
A.8.3 AVANÇOS RECENTES E INOVAÇÕES .....	250	A.12.3 AVANÇOS RECENTES E INOVAÇÕES .....	268
A.8.4 COMUNIDADE DE DESENVOLVIMENTO .....	251	A.12.4 COMUNIDADE DE DESENVOLVIMENTO .....	268
A.8.5 LIMITAÇÕES .....	251	A.12.5 LIMITAÇÕES .....	268
A.8.6 CASOS DE USO .....	251	A.12.6 CASOS DE USO .....	268
<b>A.9. RISKCHANGES</b> .....	<b>255</b>	<b>A.13. HEC-FDA</b> .....	<b>270</b>
A.9.1 DESCRIÇÃO GERAL .....	255	A.13.1 DESCRIÇÃO GERAL .....	270
A.9.2 MÉTODOS APLICADOS .....	255	A.13.2 MÉTODOS APLICADOS .....	270
A.9.3 AVANÇOS RECENTES E INOVAÇÕES .....	256	A.13.3 ABORDAGEM MATEMÁTICA .....	271
A.9.4 COMUNIDADE DE DESENVOLVIMENTO .....	256	A.13.4 AVANÇOS RECENTES E INOVAÇÕES .....	275
A.9.5 LIMITAÇÕES .....	256	A.13.5 COMUNIDADE DE DESENVOLVIMENTO .....	275
A.9.6 CASOS DE USO .....	256	A.13.6 LIMITAÇÕES .....	275
<b>A.10. FLOODRISK - QGIS PLUGIN</b> .....	<b>258</b>	A.13.7 CASOS DE USO .....	275
A.10.1 DESCRIÇÃO GERAL .....	258	<b>A.14. OPENQUAKE</b> .....	<b>279</b>
A.10.2 MÉTODOS APLICADOS .....	260	A.14.1 INTRODUÇÃO AO OPENQUAKE .....	279
A.10.3 AVANÇOS RECENTES E INOVAÇÕES .....	261	A.14.2 MÉTODOS APLICADOS .....	279
A.10.4 COMUNIDADE DE DESENVOLVIMENTO .....	261	A.14.3 ABORDAGEM MATEMÁTICA .....	281
A.10.5 LIMITAÇÕES .....	262	A.14.4 AVANÇOS RECENTES E INOVAÇÕES .....	284
A.10.6 CASOS DE USO .....	262	A.14.5 COMUNIDADE DE DESENVOLVIMENTO .....	285
<b>A.11. FLOODRISE</b> .....	<b>265</b>	A.14.6 LIMITAÇÕES .....	285
A.11.1 DESCRIÇÃO GERAL .....	265	A.14.7 CASOS DE USO .....	286
A.11.2 MÉTODOS APLICADOS .....	265	<b>ANEXO B. TIPOS DE DADOS</b> .....	<b>289</b>
A.11.3 AVANÇOS RECENTES E INOVAÇÕES .....	265		
A.11.4 COMUNIDADE DE DESENVOLVIMENTO .....	265		
A.11.5 LIMITAÇÕES .....	265		
A.11.6 CASOS DE USO .....	265		





SEÇÃO 1

# **REVISÃO DAS FERRAMENTAS EXISTENTES PARA O CÁLCULO DE RISCO**





## 1.1. INTRODUÇÃO



Imagem: Adobe Stock

A capacidade de avaliar e gerenciar riscos é uma prioridade para governos nacionais, regionais e locais, organizações e instituições financeiras. As plataformas de cálculo de riscos são ferramentas essenciais que permitem analisar, modelar e projetar os impactos de diversos cenários, facilitando a tomada de decisões embasadas. Essas plataformas passaram por um desenvolvimento acelerado nos últimos anos, incorporando métodos avançados de análise estatística, modelagem probabilística, simulação e até mesmo inteligência artificial para oferecer ferramentas que permitem o cálculo de riscos usando o conhecimento mais avançado e aproveitando os recursos computacionais.

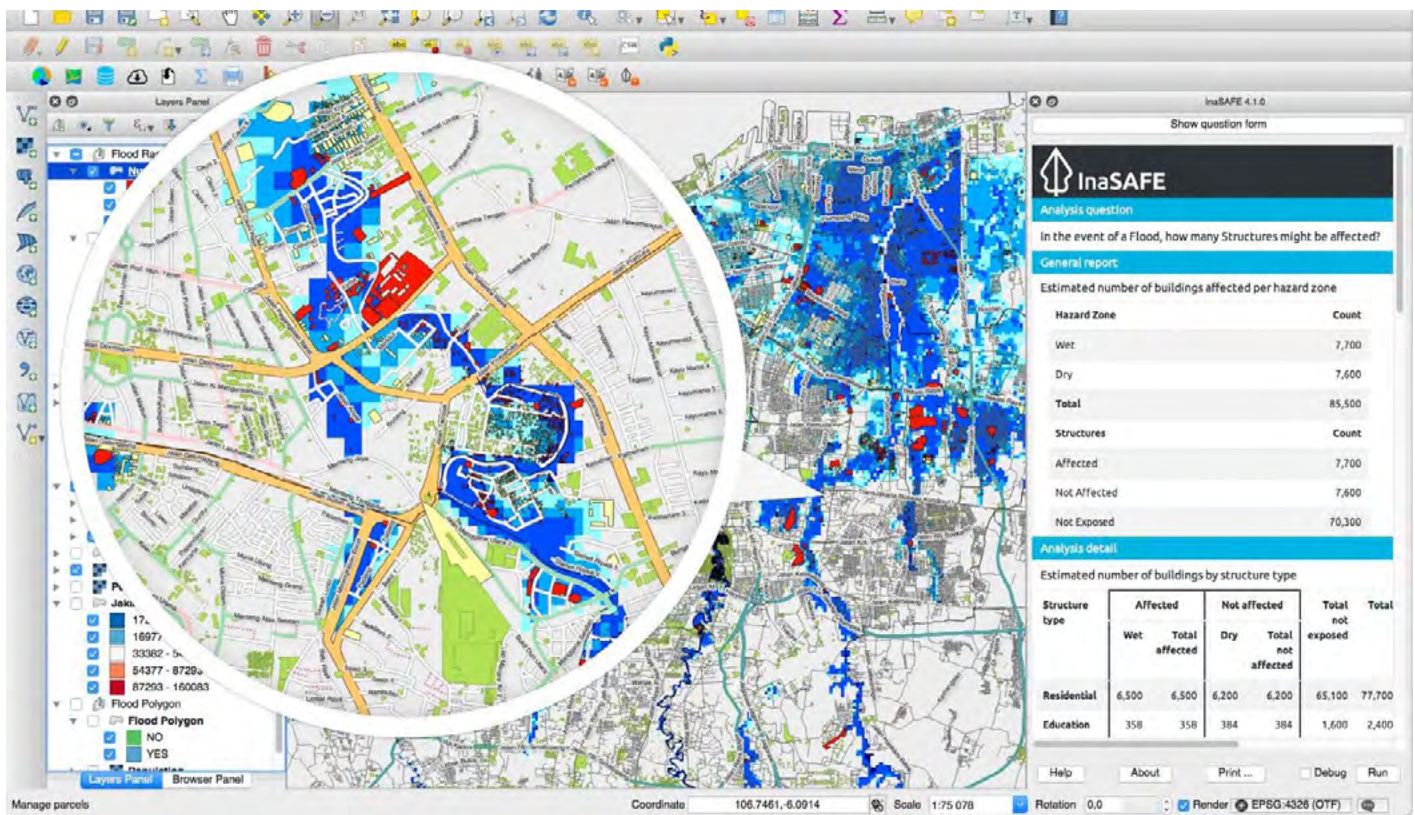
O desenvolvimento de plataformas e ferramentas de cálculo de riscos representa um avanço significativo na área. Atualmente, há um número significativo de plataformas e ferramentas disponíveis, cada uma com características exclusivas que as tornam particularmente úteis em diferentes contextos, desde a avaliação de riscos sísmicos até a modelagem dos impactos climáticos. Sua implementação não só permite a quantificação dos possíveis danos econômicos e sociais, como também promove uma melhor preparação e resiliência frente aos desastres.



Este capítulo apresenta uma análise de diversas plataformas de cálculo de riscos, destacando suas características, funcionalidades e aplicações específicas. A estrutura do capítulo é organizada como um resumo da revisão da literatura sobre as ferramentas disponíveis para o cálculo de riscos multiameaça, para o risco de inundação e o risco sísmico, avaliando diferentes critérios, como acessibilidade, comunidade de desenvolvimento e suporte, disponibilidade de software, interface gráfica e estrutura conceitual para a estimativa do risco. O Anexo A inclui detalhes adicionais sobre cada uma das plataformas, bem como exemplos de uso que expandem o conteúdo apresentado no capítulo. Por meio dessa análise, pretendemos fornecer uma visão abrangente que facilite a identificação da solução mais adequada para os tipos de análise que o Banco Interamericano de Desenvolvimento deseja oferecer aos países da América Latina e do Caribe.



## 1.2. PLATAFORMAS MULTIAMEAÇA



Fonte: <https://inasafe.org/>



## 1.2.1. Descrição

Essas plataformas são projetadas para analisar diversos tipos de ameaças e, embora algumas delas possam ser projetadas para ameaças específicas, devido à sua flexibilidade, elas podem ser usadas com outras ameaças. A seguir, uma breve descrição das plataformas avaliadas; para obter mais detalhes sobre as características das plataformas, consulte o **Anexo A**.



**A CAPRA** (Probabilistic Risk Assessment Platform) (<https://ecapra.org/>) é uma plataforma que usa uma abordagem probabilística para a avaliação de riscos de desastres. Ele permite a quantificação e a análise do risco associado a terremotos, tsunamis, vulcões, movimentos de massa, furacões, inundações, precipitação e seca (Universidad de Los Andes 2024a). Ele gera métricas como curvas de risco, distribuição espacial de danos e perda anual esperada (Banco Mundial et al. 2009).



**O HAZUS** (<https://www.fema.gov/flood-maps/products-tools/hazus>) é um software desenvolvido pela FEMA que se concentra na avaliação de riscos de desastres usando uma metodologia padronizada. Ele é usado para estimar os impactos de terremotos, furacões, enchentes e tsunamis. Seus resultados incluem estimativas de danos físicos às estruturas e perdas econômicas e sociais (FEMA 2023).



**O RiskScape** (<https://riskscape.org.nz/>) é um aplicativo que processa dados espaciais para análises de risco multiameaça. Ele combina camadas espaciais para avaliar a exposição de edifícios e outras infraestruturas, fornecendo uma análise dos riscos potenciais (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024c).



**A InaSAFE** (<https://inasafe.org/>), uma ferramenta de software livre, também é especializada na avaliação dos impactos dos desastres, principalmente terremotos, tsunamis e enchentes. Seu foco é a geração de cenários de impacto e a criação de camadas de mapas para mostrar os efeitos de diferentes ameaças, embora não realize uma análise econômica do risco, mas se concentre na exposição de elementos e no planejamento da resposta (InaSAFE 2019a).



**A OASIS** (<https://oasislmf.org/>) concentra-se na modelagem de catástrofes, fornecendo ferramentas padronizadas para a avaliação de riscos e a quantificação das perdas financeiras. Os usuários podem avaliar possíveis perdas e áreas de alto risco com modelos que integram dados de exposição e análise de cenários catastróficos (OASIS 2024a).



**A IN-CORE** (Integrated Computational Resilience) (<https://in-core.org/>) é uma plataforma desenvolvida pela Universidade Estadual do Colorado para analisar a resiliência de infraestruturas e comunidades a desastres. Ela integra modelos de simulação para avaliar os impactos físicos e socioeconômicos dos desastres, analisando a recuperação das comunidades e fornecendo ferramentas para otimizar o planejamento da resiliência e a resposta a desastres (IN-CORE 2024).



**CLIMADA** (CLIMate ADAPtation) (<https://climada.ethz.ch/>) é uma ferramenta de modelagem probabilística que avalia o risco socioeconômico de eventos climáticos, mas pode ser usada para a análise de outras ameaças, considerando tanto as projeções atuais quanto as futuras. Ela permite estudos de eventos individuais e conjuntos e avalia como as medidas de adaptação podem reduzir os impactos das mudanças climáticas (Aznar-Siguan e Bresch 2019).



**A CATSIM** (Catastrophe Simulation Tool) (<https://iiasa.ac.at/models-tools-data/catsim>), desenvolvida pelo IIASA, concentra-se em ajudar os formuladores de políticas a identificar as melhores estratégias financeiras para lidar com os riscos de desastres. A CATSIM inclui um módulo para avaliar o risco e outro para mostrar os custos e benefícios de diferentes estratégias financeiras, permitindo que os usuários ajustem os parâmetros e simulem várias condições econômicas e de risco (IIASA 2024a).



**RiskChanges** (<https://riskchanges.org/>), desenvolvida pela Universidade de Twente e pelo Instituto de Tecnologia da Ásia, Centro de Geoinformática. É uma ferramenta de código aberto projetada para analisar riscos dinâmicos multiameaça. Ela permite avaliar e gerenciar riscos associados a diferentes ameaças naturais e antropogênicas, considerando suas interações e efeitos cumulativos (PreventionWeb 2023).

Além dessas nove plataformas, foram identificados sites de outras ferramentas que, embora representem esforços valiosos, não foram incluídos na análise comparativa do Anexo A. Isso ocorre porque sua continuidade não pôde ser confirmada. Um exemplo é o PRAISys (Probabilistic Resilience Assessment for Interdependent Systems), que tem um site (Lehigh University e Florida Atlantic University 2020) e permite que o software seja baixado mediante solicitação, fornecendo um link do Google Drive para download. No entanto, não foi encontrada nenhuma documentação detalhada, e a última versão do software data de 2020, sem nenhuma evidência clara de que a iniciativa tenha sido continuada.



## 1.2.2. Acessibilidade

As plataformas multiameaça analisadas têm diferentes licenças e níveis de acesso ao seu código-fonte, o que influencia a flexibilidade de seu uso e modificação. A CAPRA não especifica publicamente sua licença e, embora tenha sido originalmente planejado como de código aberto, atualmente não está disponível para acesso público. O software foi projetado para uso em sistemas Windows com suporte aprimorado para sistemas operacionais de 64 bits e foi desenvolvido em VB.NET 2005. Ele não tem um repositório público para seu código, o que limita a possibilidade de personalização ou extensão da plataforma pelos usuários (Universidad de Los Andes 2024a). O HAZUS é gratuito, mas requer o uso do ArcGIS, que é um software pago. Embora algumas das ferramentas complementares do HAZUS sejam de código aberto e haja um projeto da FEMA para criar uma distribuição Python de código aberto (FEMA 2020), o código completo não está disponível gratuitamente para modificação.

O RiskScape está disponível sob a licença AGPLv3<sup>3</sup> e é de código aberto. Ele pode ser executado no Windows, Linux e macOS, desde que o Java versão 17 ou superior esteja instalado. A plataforma é desenvolvida em Java e Python, e seu código-fonte está disponível no site oficial do software, permitindo que os usuários pesquisem, modifiquem e contribuam com o projeto. O InaSAFE é uma ferramenta totalmente de código aberto sob a licença GPLv3, compatível com Windows, macOS e Linux. Desenvolvido em Python, o InaSAFE está disponível em seu repositório no GitHub, o que facilita a personalização e a adaptação para necessidades específicas.

Por outro lado, a OASIS é de código aberto sob a licença BSD 3<sup>4</sup>, mas o uso dos modelos que emprega não é gratuito. Ela está disponível no Windows através de contêineres Docker ou do subsistema Linux para Windows e foi desenvolvido em Python 3 e C++ 11. Seu código-fonte está disponível no GitHub. A IN-CORE também distribui seu código-fonte sob uma licença de código aberto, especificamente a licença pública para Mozilla 2.0<sup>5</sup>. Ele é compatível com Windows, macOS e Linux, e foi desenvolvido em Python e Java. Seu repositório no GitHub permite que os usuários acessem o código e contribuam para o desenvolvimento da plataforma. A CLIMADA, outra ferramenta de código aberto, está licenciada sob a

---

<sup>3</sup> A Licença Pública Geral Affero versão 3 (AGPLv3) é uma licença de software livre e de código aberto. A AGPLv3 exige que qualquer modificação do software, mesmo que seja executada em um servidor e não seja distribuída diretamente aos usuários, também deve ser liberada sob a mesma licença (<https://www.gnu.org/licenses/agpl-3.0.html>).

<sup>4</sup> A licença BSD de 3 cláusulas (BSD 3-Clause License) é uma licença de software livre e de código aberto que permite o uso, a modificação e a distribuição do software com restrições mínimas. É uma versão mais permissiva da licença BSD original, que remove a cláusula de publicidade, mas mantém três condições principais: (1) o aviso de direitos autorais e a lista de condições devem ser mantidos em todas as cópias ou distribuições do software; (2) o nome dos autores ou colaboradores não pode ser usado para endossar produtos derivados sem permissão; e (3) os desenvolvedores originais (<https://opensource.org/licenses/BSD-3-Clause>) são isentos de responsabilidade.

<sup>5</sup> A licença pública do Mozilla 2.0 (MPL-2.0) é uma licença de software livre e de código aberto que combina características de licenças permissivas e de copyleft. Ela permite que o código licenciado sob a MPL-2.0 seja usado, modificado e distribuído, mesmo em projetos proprietários, desde que os arquivos modificados sob a MPL permaneçam sob a mesma licença e sejam compartilhados com a comunidade (<https://opensource.org/licenses/MPL-2.0>).



GNU GPL3<sup>6</sup> e é compatível com Windows, macOS e Linux. Desenvolvida em Python, MATLAB e Octave, seu código também está disponível no GitHub, o que facilita o acesso e a colaboração. O RiskChanges é distribuído sob uma licença MIT de código aberto<sup>7</sup>. Essa ferramenta é compatível com os sistemas operacionais Windows, Linux e macOS e foi desenvolvida usando a linguagem de programação Python. Por fim, a CATSIM tem uma licença personalizada, o que significa que não é de código aberto, embora o acesso ao software possa ser solicitado sob determinadas condições. Seu repositório não está disponível publicamente.

A **Tabela 1** resume os critérios de acessibilidade selecionados para a comparação das plataformas, onde foi considerado de alta importância que a ferramenta seja de código aberto e que também disponibilize o código publicamente por meio do GitHub.

**Tabela 1. Critérios de acessibilidade**

Critério	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Código aberto	X	X <sup>1</sup>	✓	✓	✓	✓	✓	X	✓
GitHub	X	X <sup>2</sup>	X <sup>3</sup>	✓	✓	✓	✓	X	✓

**Notas:**

- Há um projeto da FEMA para criar uma distribuição de código aberto do HAZUS como um pacote Python. O progresso desse projeto é desconhecido, embora o pacote esteja disponível para download e instalação sob a licença pública geral GNU v3 (GPLv3+). <https://fema-ftp-snapshot.s3.amazonaws.com/Hazus/hazpy/build/html/index.html> <https://github.com/nhrap-hazus> atualizado pela última vez há 5 anos.
- O código do RiskScape não está no GitHub, mas pode ser baixado do site oficial.




<sup>6</sup> A licença pública geral GNU, versão 3 (GPL-3.0), é uma licença de software livre com uma forte abordagem de copyleft, o que significa que qualquer software derivado ou distribuído que inclua um código sob essa licença também deve ser mantido sob a GPL-3.0. Ela garante aos usuários a liberdade de executar, estudar, modificar e distribuir o software, mas impõe restrições para evitar que o código se torne proprietário (<https://www.gnu.org/licenses/gpl-3.0.html>).

<sup>7</sup> A licença MIT é uma licença permissiva de software de código aberto, o que significa que ela permite que os desenvolvedores usem, modifiquem e distribuam o software com poucas restrições. Sua única condição é que o aviso de direitos autorais e a isenção de responsabilidade originais sejam incluídos em todas as cópias ou versões modificadas (<https://opensource.org/license/mit/>).






## 1.2.3. Comunidade de desenvolvimento e suporte

### No caso da CAPRA

-  Não é especificado um canal direto de contato com os desenvolvedores.
-  Inclui ferramentas de ajuda integradas à sua interface gráfica para orientar os usuários.
-  Os manuais disponíveis datam de 2009 e não há registro de atualizações desde então, o que pode limitar o suporte atualizado.




---

### No caso do HAZUS

-  Fornece assistência técnica por meio de um endereço de e-mail específico: FEMA [HazusSupport@fema.dhs.gov](mailto:HazusSupport@fema.dhs.gov).
-  Disponibiliza manuais do usuário e manuais técnicos.
-  Inclui um menu de ajuda integrado à ferramenta, melhorando a acessibilidade.


---

### No caso do RiskScape

-  Disponibiliza manual e ferramentas de apoio.
-  Fornece documentação e tutoriais on-line.
-  Não é especificado um canal direto de contato com os desenvolvedores.


---

### No caso do InaSAFE

-  Disponibiliza manual e recursos de apoio.


---

### No caso do OASIS

-  Possui documentação extensa disponível em seu repositório.

---

### No caso do IN CORE

-  Disponibiliza exemplos de uso e documentação detalhada em seu site.
-



## No caso da CLIMADA



Destaca-se por sua documentação extensa e pelos exemplos de uso disponíveis, que facilitam a compreensão da plataforma.

## No caso da CATSIM



Não possui repositório público.



Disponibiliza contato direto com o responsável pelo projeto para fins de suporte.



Inclui um manual do usuário e diretrizes práticas para o uso do software.

## No caso do RiskChanges



O site fornece informações de contato dos desenvolvedores.



Inclui ferramentas de ajuda.



A documentação é bastante básica e focada no uso operacional, sem detalhamento dos procedimentos de cálculo do software, sem fornecer detalhes sobre os procedimentos de cálculo.

A **Tabela 2** apresenta os critérios de comparação entre as ferramentas em relação à comunidade de desenvolvimento e suporte. A disponibilidade de alguma forma de contato com os desenvolvedores, bem como a existência de manuais e ferramentas de ajuda, foi considerada essencial. No entanto, a qualidade do último não foi incluída como um critério de avaliação.

**Tabela 2. Critérios comunitários de desenvolvimento e suporte**

Critério	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Contato com desenvolvedores	✗	✓	✓	✓	✓	✓	✓	✓	✓
Manuais e ajuda	✓	✓	✓	✓	✓	✓	✓	✓	✓



## 1.2.4. Atualizações e melhoria contínua do software

A frequência com que as atualizações de software são disponibilizadas ao público foi considerada um critério chave de avaliação, pois reflete o compromisso dos desenvolvedores com a manutenção, a incorporação de melhorias, a correção de erros e a adaptação a novas necessidades ou métodos.

### CAPRA GIS (motor de cálculo de risco da CAPRA)



O desenvolvimento teve início em 2008.



A última atualização foi lançada em 2018, com a versão 2.4.



O fato de sua última atualização ter ocorrido há sete anos pode indicar uma possível interrupção em sua evolução.

---

### HAZUS



Teve início em 1997.



Manteve um ciclo de atualizações mais ativo.



A versão mais recente (7.0) foi lançada em novembro de 2024.

---

### RiskScape



Teve início no início dos anos 2000.



A versão estável mais recente, v1.6.0, foi lançada em abril de 2024.



Mantém um ciclo de atualização relativamente consistente.

---

### InaSAFE



Teve início em outubro de 2012.



A última atualização foi lançada em novembro de 2018, com a versão 5.0.0.



Apresenta uma frequência de atualização menor em comparação com outras plataformas.

---



## OASIS



Teve início em 2012.



Encontra-se atualmente em desenvolvimento ativo, com a versão 2.4.0 lançada em fevereiro de 2025.

---

## IN-CORE



Teve início em 2015.



É atualizada de forma ativa.



A versão 5.5.1 foi lançada em novembro de 2024.

---

## CLIMADA



Teve início em 2018.



É atualizada regularmente.



A versão mais recente (v5.0.0) foi lançada em julho de 2024.

---

## CATSIM



Não há data específica de início disponível.



Encontra-se em processo de expansão para uma versão web interativa.



A última atualização do manual do usuário ocorreu em agosto de 2021, indicando que o desenvolvimento continua ativo.

---

## RiskChanges



A data de início do desenvolvimento não pôde ser identificada.



A última modificação do código no GitHub ocorreu em junho de 2022.



Não há informações disponíveis sobre atualizações posteriores.



A **Tabela 3** apresenta o critério selecionado para avaliar as atualizações e a melhoria contínua do software, que estabelece que pelo menos uma atualização deve ter sido realizada nos últimos dois anos.

**Tabela 3. Critérios para atualizações e melhoria contínua do software**

Critério	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Atualização nos últimos dois anos	X	✓	✓	X	✓	✓	✓	X	X

## 1.2.5. Interface gráfica

As plataformas multiameaça variam em termos de interface de usuário e de integração com outros softwares. A CAPRA tem uma interface gráfica em espanhol e é apresentada como um software autônomo, o que significa que pode ser usada de forma independente, sem depender de outros aplicativos. Por outro lado, o HAZUS, que tem uma interface gráfica em inglês, requer o ArcGIS para seu funcionamento, o que o torna um software não autônomo e requer que o usuário adquira a licença do ArcGIS.

O RiskScape e o OASIS são plataformas com interfaces gráficas em inglês que funcionam como um software autônomo e não dependem de outros aplicativos, como o QGIS ou o ArcGIS, embora o RiskScape não tenha uma interface gráfica e a interação com o usuário seja feita por meio da linha de comando. O InaSAFE, por outro lado, é integrado como um plug-in do QGIS e tem uma interface gráfica em inglês e indonésio, o que o torna uma ferramenta fácil de usar no ambiente do QGIS.

As plataformas IN-CORE e CLIMADA não têm suas próprias interfaces gráficas. A IN-CORE é usada no ambiente Python/Jupyter, o que significa que os usuários interagem com um código, em vez de interfaces visuais. Da mesma forma, a CLIMADA também é um pacote Python que é usado por meio do Python/Jupyter, sem uma interface gráfica dedicada. A CLIMADA também tem uma versão no MATLAB que data de 2016, mas que já não tem mais suporte no momento<sup>8</sup>.

No caso do RiskChanges, essa ferramenta tem uma interface de usuário sob sua operação como ferramenta web e, além disso, pode ser usada como uma biblioteca Python, permitindo a interação do usuário com código (RiskChanges 2021).

<sup>8</sup> <https://github.com/davidnbresch/climada>



Por fim, a CATSIM tem uma interface gráfica em inglês e é um aplicativo autônomo, embora uma versão web interativa esteja em processo de lançamento.

A **Tabela 4** mostra os critérios selecionados, que são o fato de o software não depender de outro software que exija uma licença paga e ter ou não sua própria interface de usuário.

**Tabela 4. Critérios de interface gráfica**

Critério	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Independência de outro software com licença paga	✓	✗ <sup>1</sup>	✓	✓ <sup>2</sup>	✓	✓	✓	✓	✓
Interface de usuário	✓	✓	✗ <sup>3</sup>	✓	✓	✗ <sup>4</sup>	✗ <sup>4</sup>	✓	✓

**Notas:**

1. uso do HAZUS requer o ArcGis, mas as funções que foram desenvolvidas em Python não requerem esse software.
2. InaSAFE é um plug-in QGIS que não requer licença.
3. RiskScape funciona a partir da linha de comando
4. Tanto a IN-CORE quanto a CLIMADA são executadas no ambiente Python/Jupyter, portanto, não têm interface própria e as funções e a visualização são feitas por meio do código Python gerado pelo usuário.

## 1.2.6. Estrutura conceitual para a estimativa do risco

As plataformas multiameaça são estruturadas em módulos que abordam diferentes aspectos da análise de risco. A CAPRA, por exemplo, inclui módulos para avaliar ameaças específicas, como enchentes, movimentos de massa, furacões e terremotos, bem como um módulo de vulnerabilidade e o CAPRA-GIS, uma ferramenta especializada para o cálculo probabilístico de riscos. No caso do HAZUS, os módulos correspondem às ameaças: terremotos, furacões, inundações e tsunamis.

Por outro lado, ferramentas como o RiskScape e o OASIS são projetadas com módulos que integram a análise de ameaças, exposição e vulnerabilidade. A OASIS adiciona um módulo financeiro para avaliar o impacto econômico dos desastres. A IN-CORE amplia essa funcionalidade ao incluir módulos com foco nos impactos sociais, recuperação e otimização, enquanto a CATSIM se concentra exclusivamente na avaliação do risco macroeconômico e na análise de estratégias financeiras. Embora a CLIMADA não apresente módulos no sentido tradicional, ela organiza suas funcionalidades em pacotes que abrangem entidades<sup>9</sup>, ameaças e utilidades específicas. Por fim, o RiskChanges divide suas ferramentas entre

<sup>9</sup>A classe entity ou entidade é uma classe de contêiner que armazena as exposições e as funções de impacto (curvas de vulnerabilidade) necessárias para um cálculo de risco, bem como as taxas de desconto e as medidas de adaptação para uma análise de custo-benefício de adaptação. Assim como os objetos Hazard ou ameaça, as Entities podem ser lidas a partir de arquivos ou criadas por código.



modelagem de exposição (seção da ferramenta web na qual você seleciona as camadas dos elementos expostos e a ameaça para a análise da exposição), perda (seção da ferramenta web chamada loss, na qual você escolhe o tipo de perda a ser calculada entre população, quantificação de objetos, custos ou geometria, que pode ser área, comprimento ou número e um evento caracterizado por um período de retorno) e risco (seção da ferramenta web na qual você pode configurar uma análise de risco completa por cenários, para uma ameaça ou multiameaça). O Riskchanges também contém um banco de dados de curvas de vulnerabilidade que permite aos usuários compartilhar curvas.

Em termos de resultados e métricas calculados, as plataformas podem gerar curvas de risco, que permitem o cálculo da perda anual esperada (PAE) para as perdas físicas e humanas, dependendo de como os elementos expostos e a vulnerabilidade são inseridos. A exceção é a InaSAFE, que se limita a cálculos de exposição e, portanto, não gera estimativas de risco.

No caso da OASIS e da CATSIM, não foi identificada nenhuma documentação indicando que essas ferramentas calculam métricas sociais. A CATSIM, em particular, se restringe a uma abordagem puramente macroeconômica.

## Ferramentas como a CAPRA, a OASIS, o RiskScape, a IN-CORE e a CLIMADA se destacam por seu design flexível e robusto

- ➔ **A CAPRA e a OASIS**, em particular, foram projetadas principalmente para realizar análises probabilísticas que abrangem centenas ou milhares de eventos.
- ➔ **RiskScape, a IN-CORE e a CLIMADA** têm uma abordagem que abrange tanto a análise de um número limitado de eventos quanto a execução de cálculos com um número ilimitado, graças à sua integração em ambientes Python
- ➔ **HAZUS e o RiskChanges** foram projetados para a análise de grupos de eventos limitados, especialmente para inundações e terremotos no caso do HAZUS, e para todas as ameaças no caso do RiskChanges
- As versões iniciais do HAZUS inclusive restringiam o número de eventos a serem analisados (5 para inundações e 8 para terremotos), embora na versão 7 essa limitação pareça ter sido superada, exigindo uma configuração manual no ArcGIS
- No caso do RiskChanges, na sua versão como ferramenta web, ele também exige a configuração manual das análises, embora sua integração com o Python possa permitir a flexibilidade de executar análises com um grande número de eventos com um código desenvolvido pelo usuário.



A quantificação da incerteza nas ferramentas avaliadas concentra-se na ameaça, com três exceções importantes: A CAPRA, que inclui a incerteza nas curvas de vulnerabilidade; a IN-CORE, que emprega métodos avançados na quantificação da incerteza da vulnerabilidade, como a Probabilidade de Estado Limite de Monte Carlo; e a CLIMADA, que usa seu módulo Unsequa para realizar a análise global da incerteza, incluindo ameaça, exposição e função de impacto (Kropf et al. 2022).

Em geral, as ferramentas não têm restrições quanto ao uso de arquivos para a análise. Normalmente, as ameaças são modeladas com arquivos raster de formatos padrão, a exposição com arquivos shapefile e as curvas de vulnerabilidade são inseridas com arquivos de texto ou diretamente na interface. A única exceção é a CAPRA, que requer arquivos específicos no formato \*.ame para descrever as ameaças. Todas as plataformas permitem a visualização espacial dos resultados, exceto a CATSIM, cujo foco é limitado à análise macroeconômica.

**Tabela 5. Critérios da estrutura conceitual**

Critério	CAPRA	HAZUS	RiskScope	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Curva de risco e PAE	✓	✓	✓	✗	✓	✓	✓	✓	✓
Algum tipo de métrica de risco social	✓	✓	✓	✓ <sup>3</sup>	✗	✓	✓	✗	✓
Projetada para análise probabilística <sup>4</sup>	✓	✗ <sup>1</sup>	✓	✗	✓	✓	✓	✗	✗
Sem restrições quanto ao uso de alguns formatos de arquivo	✗	✓	✓	✓	✓	✓	✓	✓	✓
Métodos de análise da incerteza no componente de vulnerabilidade	✓	✗ <sup>1</sup>	✗ <sup>2</sup>	✗	✓	✓	✓	✗	✗
Visualização espacial dos resultados	✓	✓	✓	✓	✓	✓	✓	✗	✓

**Notas:**

- Embora as ferramentas não tenham sido projetadas para realizar análises totalmente probabilísticas no caso das enchentes, terremotos e tsunamis, a exceção são os furacões, em que o Hazus considera eventos gerados durante um longo período e leva em consideração a incerteza do impacto.
- Embora os métodos não estejam disponíveis na ferramenta, eles podem ser desenvolvidos com Python e integrados ao fluxo de trabalho do RiskScope.
- O InaSAFE pode produzir valores de exposição da população, embora não propriamente de risco; no entanto, isso será considerado suficiente do ponto de vista da análise de risco humano.
- Neste documento, a análise probabilística implica que centenas ou milhares de cenários precisam ser analisados.



## 1.2.7. Comparação de ferramentas












A consolidação dos aspectos avaliados é mostrada na **Tabela 6**. As três ferramentas com o maior número de critérios atendidos são a CLIMADA, a IN-CORE e a OASIS, com 12 critérios atendidos.

**Tabela 6. Critérios consolidados preenchidos por cada ferramenta avaliada**

Critério	CAPRA	HAZUS	RiskScape	InaSAFE	OASIS	IN-CORE	CLIMADA	CATSIM	RiskChanges
Código aberto	X	X	✓	✓	✓	✓	✓	X	✓
GitHub	X	X	X	✓	✓	✓	✓	X	✓
Contato com desenvolvedores	X	✓	✓	✓	✓	✓	✓	✓	✓
Manuais e ajuda	✓	✓	✓	✓	✓	✓	✓	✓	✓
Atualização nos últimos dois anos	X	✓	✓	X	✓	✓	✓	X	X
Independência de outro software com licença paga	✓	X	✓	✓	✓	✓	✓	✓	✓
Interface de usuário própria	✓	✓	X	✓	✓	X	X	✓	✓
Curva de risco e PAE	✓	✓	✓	X	✓	✓	✓	✓	✓
Algum tipo de métrica de risco social	✓	✓	✓	✓	X	✓	✓	X	✓
Projetada para análise probabilística	✓	X	✓	X	✓	✓	✓	X	X
Sem restrições quanto ao uso de alguns formatos de arquivo	X	✓	✓	✓	✓	✓	✓	✓	✓
Métodos de análise da incerteza no componente de vulnerabilidade	✓	X	X	X	✓	✓	✓	X	X
Visualização espacial dos resultados	✓	✓	✓	✓	✓	✓	✓	X	✓
<b>Total de critérios atendidos</b>	<b>8</b>	<b>8</b>	<b>10</b>	<b>9</b>	<b>12</b>	<b>12</b>	<b>12</b>	<b>6</b>	<b>10</b>

Embora todas as ferramentas avaliadas tenham aspectos valiosos que podem contribuir para o cálculo do risco, a IN-CORE e a CLIMADA se destacam por serem significativamente mais avançadas do que as outras. Além dos critérios avaliados e consolidados na **Tabela 6**, uma exploração mais profunda dessas duas ferramentas, incluindo a revisão de manuais e o desenvolvimento de tutoriais, permitiu identificar as vantagens apresentadas na **Tabela 7**.

**Tabela 7. Vantagens da IN-CORE e da CLIMADA**

IN-CORE	CLIMADA
 <ul style="list-style-type: none"> <li>• Contém funções específicas para a análise de risco da infraestrutura, como estradas, sistemas elétricos e de água potável.</li> </ul>	 <ul style="list-style-type: none"> <li>• Fornece funções para acesso direto a modelos de mudanças climáticas e tem uma API (interface de programação de aplicativos) que permite o acesso a dados de exposição e ameaças.</li> </ul>
 <ul style="list-style-type: none"> <li>• Contém funções para estimar os impactos sobre a população, por exemplo, o deslocamento da população após um desastre.</li> </ul>	 <ul style="list-style-type: none"> <li>• Fornece métodos para gerar as camadas de exposição a partir de informações globais.</li> </ul>
 <ul style="list-style-type: none"> <li>• Contém funções para a análise dos impactos socioeconômicos dos desastres.</li> </ul>	 <ul style="list-style-type: none"> <li>• Pode usar o Google Earth Engine.</li> </ul>
 <ul style="list-style-type: none"> <li>• Contém funções para analisar a recuperação.</li> </ul>	 <ul style="list-style-type: none"> <li>• A CLIMADA pode ser executada no cluster Euler da Universidade ETH Zurich, embora a documentação não especifique claramente se nem sob quais condições pessoas de fora da universidade podem usar o cluster.</li> </ul>
 <ul style="list-style-type: none"> <li>• Conta com ferramentas web e, por meio do laboratório In-CORE, é possível desenvolver e executar o código no sistema de nuvem do NCSA (National Center for Supercomputing Applications).</li> </ul>	 <ul style="list-style-type: none"> <li>• Tem um foco especial na avaliação de custo-benefício das medidas de adaptação.</li> </ul>
 <ul style="list-style-type: none"> <li>• O módulo <i>unsequa</i> permite a análise de incerteza e sensibilidade para os parâmetros de ameaça, exposição, função de vulnerabilidade e medidas de adaptação.</li> </ul>	
<ul style="list-style-type: none"> <li>✓ Gratuito e de código aberto.</li> <li>✓ Flexível e adaptável às necessidades do usuário.</li> <li>✓ Funciona no ambiente Python, portanto, pode ser combinado com qualquer outra biblioteca.</li> <li>✓ Os métodos desenvolvidos são apoiados por publicações revisadas por pares.</li> </ul>	

Tanto a IN-CORE quanto a CLIMADA foram desenvolvidas para a análise probabilística de risco, implementando diversos métodos de quantificação de incerteza que foram desenvolvidos e publicados pelo Centro de Excelência para o Planejamento da Resiliência Comunitária Baseada no Risco, localizado na Universidade do Estado do Colorado, no caso da IN-CORE, e pela ETH de Zurich, no caso da CLIMADA. As vantagens apresentadas na Tabela 7 não são compartilhadas pelas outras ferramentas avaliadas, o que faz com que elas se destaquem das demais. No entanto, ambas têm desvantagens. Ambas as ferramentas têm sua documentação desenvolvida em inglês, o que poderia limitar seu acesso na América Latina, exigindo o desenvolvimento do material em espanhol. Além disso, ambas requerem experiência do usuário em Python, o que torna o perfil do usuário específico; além de ser um especialista em análise de ameaças e cálculo de riscos, é necessária a capacidade de desenvolver código em Python. No caso da IN-CORE, algumas das funções são baseadas em informações disponíveis nos Estados Unidos, portanto, seriam necessárias adaptações para outros contextos.



## 1.3. PLATAFORMAS PARA O CÁLCULO DE RISCO DE INUNDAÇÃO



Imagem: Adobe Stock

Dentro da revisão da literatura foram encontradas plataformas desenvolvidas em princípio para analisar o risco de inundação. Essas plataformas não apresentam o grau de desenvolvimento e sofisticação dos métodos encontrados nas plataformas IN-CORE e CLIMADA discutidas na seção 1.2 e, portanto, não serão comparadas em detalhes nesta seção, embora todas as suas características, juntamente com as outras plataformas, possam ser encontrados no Anexo A.

As ferramentas que foram revisadas são:

- ➔ **FloodRisk:** é um plug-in gratuito e de código aberto para QGIS que fornece uma avaliação das consequências das inundações, incluindo a perda de vidas humanas e danos econômicos diretos. O plug-in permite que os usuários realizem uma avaliação de risco simples, considerando eventos fixos em que a probabilidade de cada evento é estimada separadamente e as consequências são calculadas de forma determinística.
- ➔ **O FloodRISE (Flood Resilience, Insurance, and Spatial Equity)** é um projeto liderado pela Universidade da Califórnia, em Irvine (EUA), que tem como foco melhorar a resiliência a inundações por meio do desenvolvimento de simulações de ameaça de inundação de alta resolução. O projeto tem como objetivo fornecer visualizações de risco de inundação que sejam úteis para a tomada de decisões locais, envolvendo as comunidades no processo



de desenvolvimento de mapas de ameaça de inundação. O FloodRISE usa simulações de ameaça de inundação em escala métrica para avaliar os riscos em diferentes tipos de inundações (costeiras, fluviais, pluviais). A abordagem inclui a participação iterativa das partes interessadas por meio de reuniões, pesquisas e sessões de capacitação para desenvolver

→ mapas de ameaça de inundação personalizados para cada comunidade.

→ **A Delft-FIAT (Flood Impact Assessment Tool)** é uma ferramenta desenvolvida pelo instituto de pesquisa Deltares que é usada para avaliar rapidamente os impactos econômicos diretos das inundações na infraestrutura, nos edifícios e nas estradas. Essa ferramenta de código aberto, baseada em Python, é particularmente útil no planejamento da adaptação climática, já que permite a modelagem rápida dos impactos de diferentes cenários de inundação e das medidas de mitigação correspondentes. A Delft-FIAT se destaca por sua capacidade de automação e flexibilidade, o que a torna uma solução adaptável para diferentes necessidades de análise.

**A HEC-FDA (Hydrologic Engineering Center - Flood Damage Reduction Analysis)** é uma ferramenta desenvolvida pelo Corpo de Engenheiros do Exército dos Estados Unidos (USACE). Seu principal objetivo é avaliar e quantificar os danos econômicos associados a eventos de inundação, auxiliando na tomada de decisões em projetos de redução de riscos de inundação. A HEC-FDA emprega métodos probabilísticos para analisar a relação entre a frequência das inundações e os possíveis danos, permitindo a estimativa de benefícios e custos associados a diferentes medidas de mitigação de riscos.

Dessas quatro ferramentas avaliadas, destacam-se a Delft-FIAT e a HEC-FDA. A primeira se destaca por ser um script que pode ser usado de forma simples e eficaz para calcular danos em cenários que variam de poucos a centenas. Além disso, por ser um script Python, ele pode ser integrado a códigos mais complexos de acordo com as necessidades da análise. No caso da HEC-FDA, uma de suas principais contribuições é que ela integra a avaliação do desempenho das medidas de proteção, como uma barragem, à análise de risco, avaliando a capacidade dos sistemas de proteção e a probabilidade de falha. A ferramenta usa simulações de Monte Carlo para avaliar a incerteza das funções que descrevem a frequência do fluxo, o nível da água, os danos causados pela inundação etc. e o funcionamento do sistema de proteção, gerando uma avaliação de risco probabilística. A Delft-FIAT não foi identificada como tendo uma vantagem sobre a IN-CORE ou a CLIMADA, além de sua maior simplicidade, especialmente a possibilidade de usar essa ferramenta por meio do Excel. No caso da HEC-FDA, o método implementado para integrar os sistemas de proteção à avaliação de risco é uma vantagem frente à IN-CORE ou à CLIMADA. No entanto, na América Latina, poucas análises de risco consideram esses sistemas, de modo que essa ferramenta seria particularmente útil apenas em situações em que é necessário avaliar a incerteza associada ao funcionamento dos sistemas de proteção ou implementar uma metodologia para quantificar a incerteza das curvas de amostragem (para obter mais detalhes sobre o método, consulte o Anexo A).



## 1.4. PLATAFORMAS PARA O CÁLCULO DO RISCO SÍSMICO



Imagem: Adobe Stock

Em termos de plataformas exclusivas para o cálculo do risco sísmico, a única ferramenta que se destacou na revisão da literatura foi o OpenQuake Engine (<https://www.globalquakemodel.org/product/openquake-engine>), desenvolvido pela Global Earthquake Model (GEM) Foundation. Outras ferramentas populares usadas no campo da análise sísmica, como o R-CRISIS (<http://www.r-crisis.com/>), foram excluídas desta análise porque se concentram no componente da ameaça e não incorporam a exposição e a vulnerabilidade para realizar estimativas do risco sísmico.

A análise do OpenQuake foi realizada considerando os mesmos critérios pelos quais as plataformas de risco multiameaça foram avaliadas.

### 1.4.1. Acessibilidade

O OpenQuake é um desenvolvimento de código aberto que está disponível em um repositório público no GitHub (<https://github.com/gem/oq-engine>) sob uma licença AGPL v3.0 aberta. Seu desenvolvimento é quase totalmente realizado na linguagem Python e, para cada lançamento de novas versões, estão disponíveis os executáveis compilados para executar a plataforma em sistemas Windows, Mac e Linux.



## 1.4.2. Comunidade de desenvolvimento e suporte

### No caso do OpenQuake



A versão inicial do OpenQuake foi lançada em 2013, portanto, demonstrou estabilidade e sustentabilidade no desenvolvimento durante um longo período.



A plataforma recebe manutenção constante da Fundação GEM, que está em operação desde 2009. A GEM recebe financiamento de vários patrocinadores, o que garante o apoio contínuo ao projeto.



O OpenQuake construiu com sucesso uma comunidade forte e ativa de usuários e desenvolvedores.



A comunidade ativa que interage através de um fórum público online (<https://groups.google.com/g/openquake-users>), no qual os usuários podem fazer perguntas sobre seu funcionamento, que são respondidas diretamente pela equipe de desenvolvedores do GEM, bem como pelo público em geral.

## 1.4.3. Atualizações e melhoria contínua

### OpenQuake



O OpenQuake está em constante atualização, o que garante melhorias contínuas e novas funcionalidades. A plataforma possui um ciclo de desenvolvimento estruturado, incluindo versões com suporte de longo prazo (LTS – *Long-Term Support*). As versões LTS permanecem estáveis por vários anos, facilitando seu uso em projetos de longo prazo sem a necessidade de atualizações frequentes.



Em paralelo, são desenvolvidas versões experimentais que incorporam as inovações técnicas mais recentes. Essa abordagem permite que os usuários optem entre estabilidade ou funcionalidades avançadas, de acordo com suas necessidades específicas.



A última versão estável disponível no momento da elaboração do relatório é a 3.23 (“Bellamy”), lançada em fevereiro de 2025. Esse lançamento reflete o compromisso contínuo da equipe de desenvolvimento com a evolução e a manutenção do OpenQuake.



## 1.4.4. Interface gráfica (GUI)

O OpenQuake Engine não tem uma interface gráfica independente, mas existe a possibilidade de instalar um plug-in QGIS (<https://plugins.qgis.org/plugins/svir/>) com o qual você pode executar as análises da plataforma, quando ambos estiverem instalados no mesmo sistema. O plug-in não tem toda as funcionalidades do OpenQuake Engine, mas concentra-se nas funções mais comuns para usuários iniciantes e intermediários. Ao mesmo tempo, o esquema de desenvolvimento do plug-in é diferente do da plataforma e não tem o mesmo ciclo de atualização. No entanto, a existência do plug-in representa uma grande vantagem, pois permite que os usuários se familiarizem com o uso da plataforma de forma gráfica, usando o QGIS, que é um sistema muito popular e de livre acesso.

## 1.4.5. Estrutura conceitual para a estimativa do risco

O OpenQuake Engine possui um conjunto de módulos de cálculo para realizar análises probabilísticas, que podem considerar apenas estimativas de ameaça ou incorporar informações de exposição e vulnerabilidade para calcular métricas de risco sísmico. Em relação à ameaça, a plataforma pode realizar a avaliação de eventos individuais ou a estimativa do potencial da ameaça sísmica considerando várias fontes (falhas sísmicas e funções de recorrência de magnitude), seja por meio da integração das fontes (identificada como método clássico na documentação) ou por meio da simulação de um conjunto de eventos. A plataforma usa sua própria definição de arquivos de entrada para definição da ameaça (arquivos XML para representar falhas e árvores lógicas), exposição (arquivos CSV) e vulnerabilidade (arquivos XML). Exemplos para gerar esses arquivos no formato correto são apresentados na documentação, e a Fundação GEM disponibiliza arquivos compatíveis sob licenças abertas, que representam suas interpretações de cada componente para as principais partes do mundo. Por fim, a plataforma conta com comandos para obter facilmente produtos e métricas de risco, como curvas de superação de perdas econômicas, estimativas de fatalidades médias anuais, populações deslocadas e outras métricas humanitárias.



Imagem: Adobe Stock



## 1.5. CONCLUSÕES



Imagem: Adobe Stock

As plataformas multiameaças IN-CORE e CLIMADA se destacaram na avaliação, pois atendem a vários critérios importantes, como acessibilidade, suporte da comunidade de desenvolvimento, disponibilidade do software, interface gráfica e uma estrutura conceitual sólida para a estimativa de riscos. Elas superaram as demais plataformas avaliadas nesses aspectos e têm vantagens que as colocam na vanguarda da avaliação de risco para plataformas multiameaça.


Em termos de cálculo de risco de inundação, duas ferramentas foram identificadas como tendo vantagens significativas: A Delft-FIAT, por sua simplicidade e flexibilidade, mas sem exceder os recursos da IN-CORE ou da CLIMADA, e a HEC-FDA, que é particularmente útil nos casos em que se deseja incluir o desempenho dos sistemas de proteção na análise de risco.

Com relação ao cálculo do risco sísmico, a plataforma OpenQuake é a única encontrada disponível na literatura que atende aos requisitos de código aberto necessários para esta análise. No entanto, a plataforma se destacou por atender a uma série de critérios importantes e representa uma excelente opção para uso na estimativa de métricas de risco sísmico.



SEÇÃO  
2

# MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NO CÁLCULO DE RISCOS



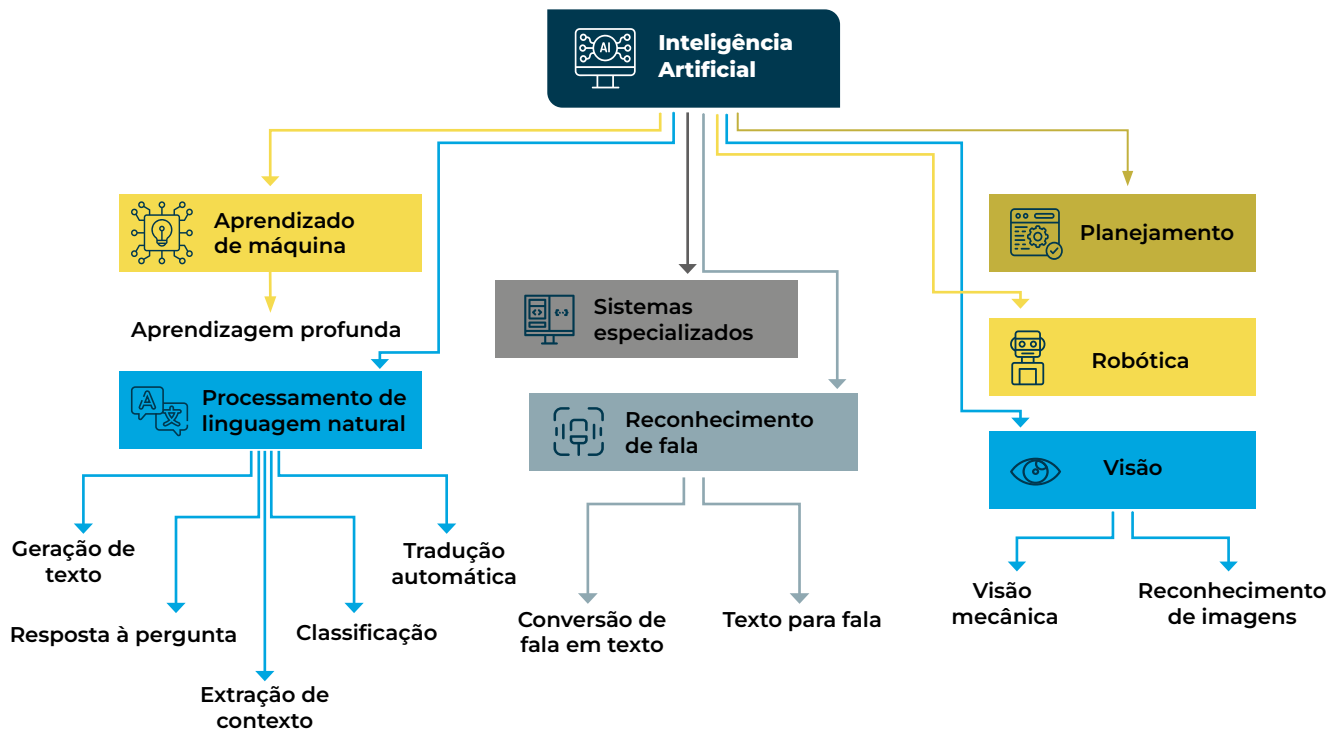


## 2.1. INTRODUÇÃO



A inteligência artificial (IA) engloba atividades relacionadas a computadores que buscam desenvolver máquinas inteligentes capazes de executar tarefas que tradicionalmente exigem intervenção humana (Abid et al. 2021). De acordo com McCarthy (2007), IA é “a ciência e a engenharia da criação de máquinas inteligentes, especialmente programas de computador inteligentes”.

Existem várias classificações da inteligência artificial (IA), e uma delas é mostrada na Figura 1, proposta por Ivić, (2019). Nessa figura, os ramos da IA incluem aprendizado de máquina (Machine Learning ou ML), aprendizado profundo (Deep Learning ou DL), processamento de linguagem natural (Natural Language Processing ou NLP), sistemas especializados (Expert Systems ou ES), bem como robótica, visão computacional e reconhecimento de fala.


**Figura 1. Ramos da inteligência artificial**


Fonte: Ivić (2019).

O ML está presente na maioria dos aplicativos de IA. Um ramo da IA que permite que os sistemas aprendam e melhorem a partir da experiência sem serem explicitamente programados (expert.ai 2024). Existem três tipos principais de ML: supervisionado, não supervisionado e aprendizado profundo (DL). Os algoritmos de aprendizado de máquina que são treinados por humanos com base em dados pré-existentes são chamados de supervisionados, enquanto os que aprendem somente a partir de dados sem intervenção humana são conhecidos como não supervisionados (GFDRR 2018). O aprendizado profundo usa redes neurais artificiais inspiradas no cérebro humano para processar dados em várias camadas de abstração (GFDRR 2018; Ivić 2019).

O aprendizado supervisionado é dividido em problemas de classificação e regressão. Na classificação, o resultado esperado é um rótulo ou classe semântica. Os problemas de regressão, por outro lado, buscam prever uma variável contínua. Há diferentes tipos de algoritmos de aprendizado supervisionado, com arquiteturas às vezes completamente diferentes. O algoritmo mais comum para a classificação é a regressão logística, enquanto o mais usado para regressão é a regressão linear. Entre os algoritmos de classificação mais conhecidos estão as florestas aleatórias, o gradient boosting, as máquinas de suporte vetorial (SVMs), os modelos bayesianos ingênuos e as redes bayesianas de gradient boosting (GFDRR 2018).



Uma das aplicações mais comuns do ML não supervisionado é o agrupamento, em que as amostras são agrupadas conforme sua similaridade. Outras aplicações incluem a redução da dimensionalidade e a detecção de anomalias para reduzir a variação em um conjunto de dados e filtrar as exceções. Os métodos não supervisionados se baseiam exclusivamente nos padrões de dados, que dependem das características estatísticas das amostras de entrada. Muitas vezes, os resultados dos algoritmos de aprendizado não supervisionado são inseridos em algoritmos de aprendizado supervisionado, nos quais a intervenção humana pode ajudar a obter uma maior precisão no conjunto de dados mais rapidamente. Há três tipos de aprendizado de máquina não supervisionado: o agrupamento K-means, a análise de componentes principais (PCA) e o t-SNE (GFDRR 2018).

A **Tabela 8** mostra a classificação dos métodos de IA propostos por Sun et al. (2020) incluindo não apenas modelos supervisionados, não supervisionados e de DL, mas também aprendizado por reforço, aprendizado profundo por reforço e otimização. O aprendizado por reforço é um tipo de aprendizado automático inspirado na psicologia comportamental. Em termos simples, o conjunto de dados de treinamento e as regras em um algoritmo de aprendizado de máquina não são decisões binárias (sim ou não), mas buscam atingir um equilíbrio entre a exploração dos dados e a precisão. Em outras palavras, permite-se que o modelo cometa erros e explore os dados dentro de determinados parâmetros. (GFDRR 2018).

**Tabela 8. Classificação dos métodos de IA**

Nome do método	Descrição	Usos
<b>Modelos supervisionados</b>	Algoritmos treinados com dados rotulados, em que tanto as entradas quanto as saídas são conhecidas. Eles usam métodos de regressão e classificação para prever os resultados.	Reconhecimento de objetos na visão computacional, extração de informações, reconhecimento de padrões e de fala.
<b>Modelos não supervisionados</b>	Eles usam métodos estatísticos para encontrar estruturas ocultas nos dados não rotulados, com base nas características inerentes dos dados.	Agrupamento de dados (clustering), redução da dimensionalidade, detecção de anomalias, agregação de dados.
<b>Aprendizado profundo (deep learning)</b>	Algoritmos que usam várias camadas para extrair recursos de dados de forma progressiva. Adequado para problemas complexos que exigem uma alta capacidade de processamento.	Detecção de movimento, processamento de linguagem natural (NLP), reconhecimento facial, previsão de transporte, etc.
<b>Aprendizado por reforço</b>	Algoritmos que aprendem com reforço (punições e recompensas) a tomar decisões em uma sequência de ações. Eles são baseados nos processos de decisão de Markov.	Robótica, controle de tráfego, gerenciamento de recursos em ambientes complexos e mutáveis.
<b>Aprendizado profundo por reforço</b>	Ele combina o aprendizado por reforço com redes neurais profundas para resolver tarefas sequenciais complexas, otimizando as decisões de longo prazo.	Visão computacional, robótica, finanças, gerenciamento de rede inteligente.
<b>Otimização</b>	Técnicas usadas na maioria dos métodos de IA para melhorar o desempenho dos modelos, avaliando seu desempenho mediante uma função objetiva.	Otimização de modelos para o gerenciamento de desastres, aprimoramento de algoritmos de IA em vários domínios, como planejamento e logística.

Fonte: Sun et al. (2020)



As metodologias de aprendizado de máquina (ML) estão sendo cada vez mais aplicadas em todos os campos, inclusive no gerenciamento de riscos de desastres (DRM). Esses aplicativos têm como objetivo melhorar a modelagem de riscos e a priorização de recursos durante a resposta e a reconstrução. A análise de imagens de satélite e as abordagens de visão computacional têm sido usadas para entender melhor a exposição física e socioeconômica, bem como para identificar vulnerabilidades. Além disso, a inteligência artificial está aprimorando a modelagem de ameaças por meio do uso de dados de sensores físicos e remotos, além de ter avançado na previsão de danos. Também foram desenvolvidos aplicativos para priorizar recursos durante as fases de resposta e recuperação, incluindo a priorização de inspeções, a mineração de redes sociais e o monitoramento da reconstrução por meio da visão computacional (GFDRR 2018).


Jones et al. (2023) agruparam os métodos de IA em 3 categorias em relação à sua aplicação na avaliação de risco de inundação, conforme mostrado na **Tabela 9**, destacando que eles podem melhorar a eficiência computacional dos modelos, permitindo a quantificação da incerteza ao aproveitar os novos conjuntos de dados geoespaciais. Isso não apenas otimiza o desempenho dos modelos, mas também aumenta a precisão das previsões e análises, fornecendo melhores ferramentas para a tomada de decisões e o planejamento em vários contextos.

**Tabela 9. Grupos de métodos de inteligência artificial**

Nome do método	Descrição	Vantagens	Desvantagens
<b>Modelagem baseada em dados</b>	Se refere ao uso de técnicas de aprendizado de máquina (ML) para criar modelos empíricos com base apenas nos dados observados. Esses modelos podem abordar a falta de conhecimento científico ou a complexidade do sistema. São úteis para prever eventos específicos em nível local ao ajustar os modelos físicos existentes. Os exemplos incluem a previsão de riscos de incêndio e padrões de inundação.	Reduz os custos com computação e é ideal para se adaptar às condições locais.	Dificuldade de interpretação dos resultados (“caixa preta”) e necessidade de dados locais precisos.
<b>Modelagem substituta</b>	Consiste em treinar um modelo de ML usando dados simulados, a fim de substituir as simulações originais por versões mais eficientes e de execução mais rápida. Essa abordagem é eficiente para testes de calibração e análise de sensibilidade, especialmente em situações em que as simulações são caras.	Reduz o tempo de simulação e o custo computacional. Ela pode ser aplicada em calibrações de modelos climáticos e previsões de impacto.	A precisão pode diminuir se o modelo substituto não capturar todas as complexidades do original.
<b>Exploração de big data geoespacial</b>	Usa técnicas de IA e ML para analisar grandes quantidades de dados geoespaciais, como imagens de satélite ou dados de sensores. Esses métodos são particularmente úteis na detecção automática de eventos climáticos extremos, como enchentes ou incêndios florestais.	Ela acelera a análise de grandes volumes de dados e melhora a precisão do mapeamento de riscos climáticos.	Isso requer uma infraestrutura computacional avançada para lidar com grandes volumes de dados, e a complexidade dos dados pode ser um grande desafio.

Fonte: Jones et al., (2023).

As seções a seguir apresentam uma análise da literatura sobre as principais aplicações da IA nos processos de gerenciamento de riscos.



## 2.2. APLICAÇÕES DA IA NO GERENCIAMENTO DE RISCOS DE DESASTRES



Para ilustrar como vários métodos de IA foram aplicados na gestão de desastres, Sun et al. (2020) identificaram um total de 26 métodos de inteligência artificial e 17 áreas de aplicação representativas. Para essa análise, os nomes dos métodos e as áreas de aplicação foram usados como palavras-chave em pesquisas em sites acadêmicos, como o Google Scholar e o Web of Science. Os resultados são apresentados na **Figura 2**, que mostra as aplicações dos métodos de IA nas quatro fases do gerenciamento de desastres e suas subáreas. Cada linha sólida na figura indica a presença de aplicações em uma determinada área. As fases de mitigação e resposta se destacam por terem mais linhas sólidas conectadas às áreas de aplicação, o que sugere um número maior de estudos que aplicam métodos de IA nessas fases.



Os métodos de inteligência artificial, como a regressão (linear, não linear e logística), são usados para avaliar ameaças e riscos, bem como para avaliar o possível impacto dos desastres. As máquinas de vetores de suporte também fornecem previsões e avaliações de risco. Redes neurais, agrupamento hierárquico, k-means, agrupamento difuso e análise de componentes principais foram usados para desenvolver e comparar estratégias de mitigação, sistemas de treinamento e procedimentos de evacuação em casos de desastres. No entanto, as técnicas de aprendizagem profunda (DL), como as redes neurais convolucionais, as redes neurais profundas e o perceptron multicamadas, são usadas principalmente para o mapeamento de riscos. Além disso, técnicas mais recentes, como as redes Deep Q e os algoritmos genéticos, têm sido usadas para avaliar os custos de perda e reparo (Abid et al. 2021).

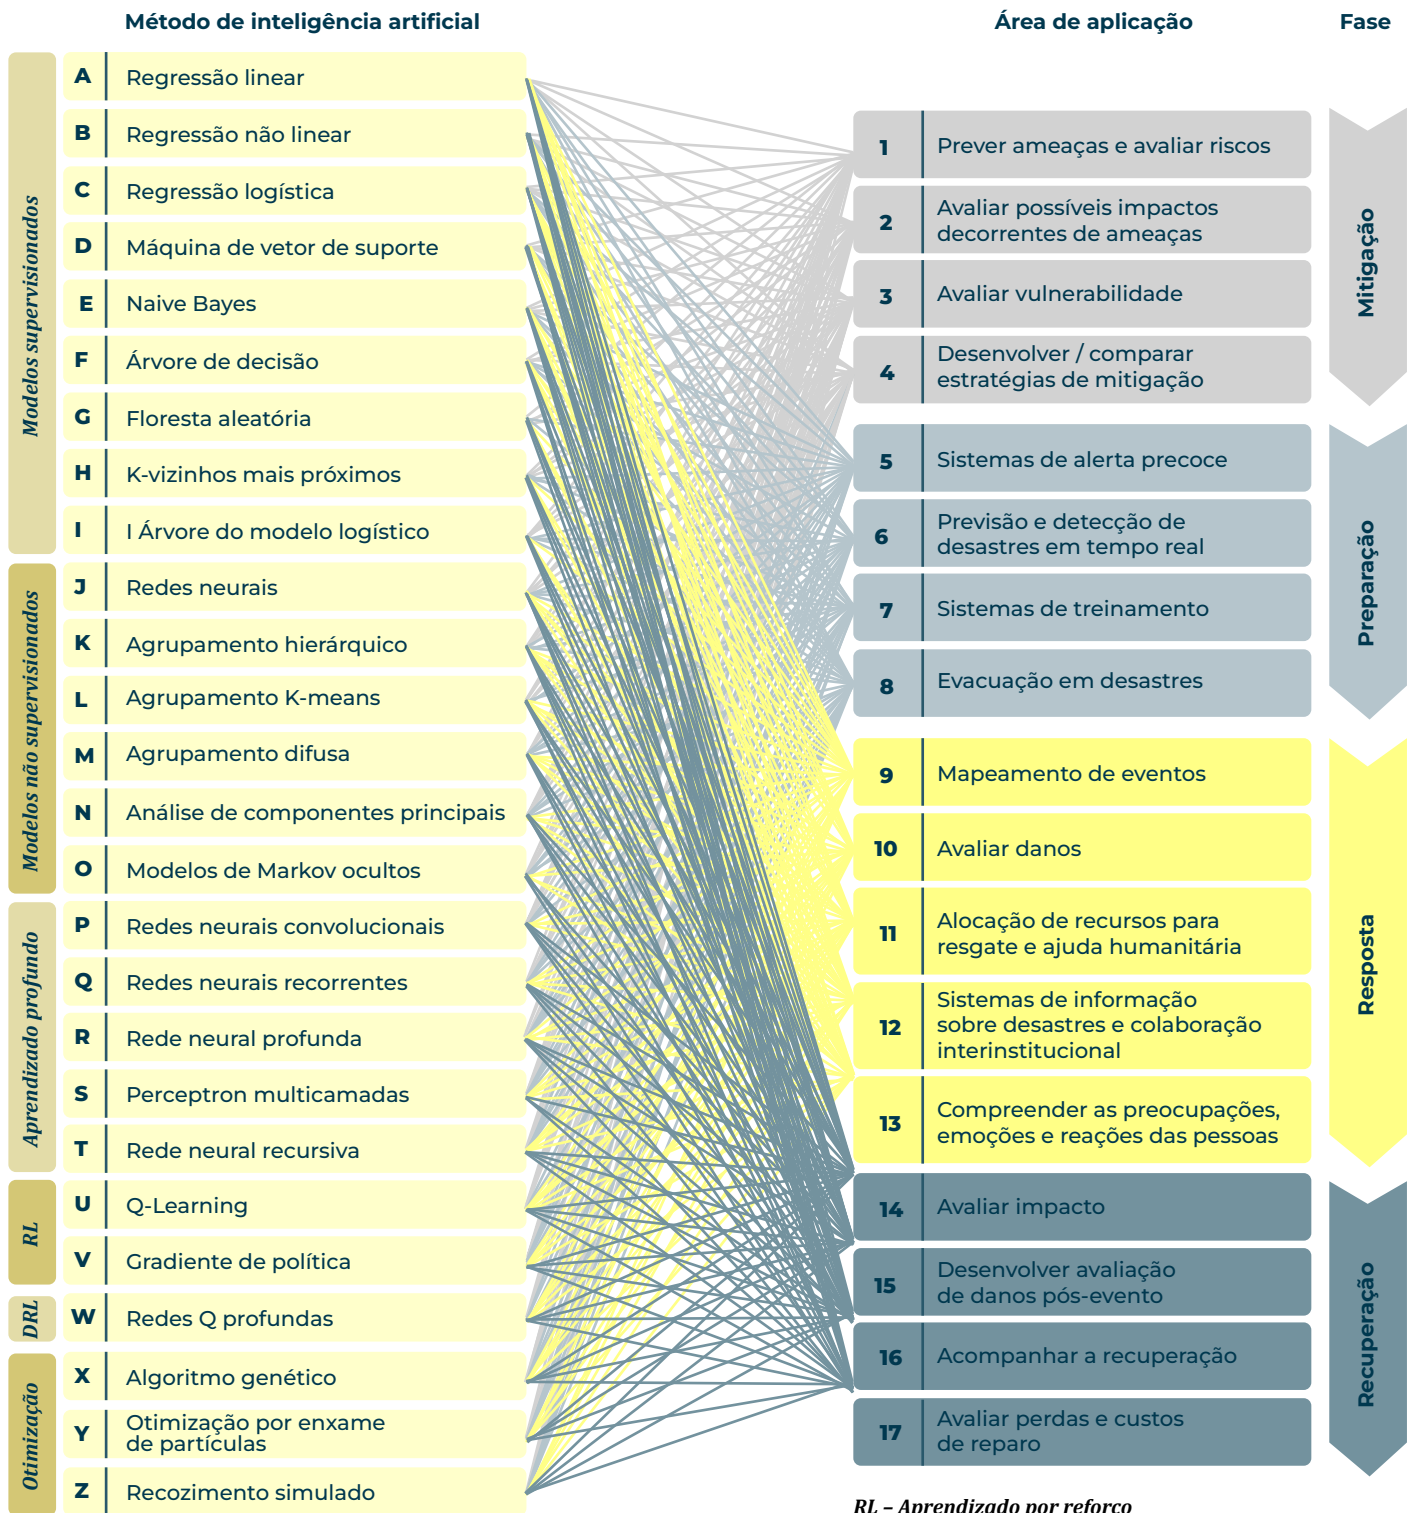
Outro campo em que a IA começou a desempenhar um papel fundamental na modelagem de risco de desastres, especialmente no domínio hidrológico e hidráulico, é a codificação assistida. Ferramentas como o ChatGPT e ambientes de codificação assistidos por IA estão revolucionando a maneira como engenheiros e cientistas de dados abordam a simulação e a análise de modelos de risco. Essas ferramentas permitem a manipulação eficiente de arquivos de modelos, a extração de dados relevantes e a automação de tarefas complexas, resultando em um fluxo de trabalho mais ágil e eficiente (Australian Water School 2024).



Imagem: Adobe Stock



**Figura 2. Métodos de inteligência artificial e áreas de aplicação no gerenciamento de riscos de desastres**



*RL - Aprendizado por reforço*  
*DRL - Aprendizado profundo por re-forço*

Fonte: Sun et al. (2020)



## 2.2.1. Mitigação e preparação para desastres

Os métodos de IA têm sido amplamente utilizados na avaliação de ameaças e riscos. Entre eles, os modelos supervisionados e não supervisionados são os mais comuns, enquanto o aprendizado por reforço e o DL são métodos mais recentes e emergentes. As técnicas tradicionais de identificação de riscos podem consumir muito tempo e ter altas taxas de falsos positivos, o que torna as técnicas de IA particularmente úteis para analisar grandes volumes de dados com mais rapidez e eficiência (Sun et al. 2020). A avaliação de ameaças é o estágio mais estudado pelos acadêmicos e emprega métodos como sistemas evolutivos (ES), redes neurais artificiais (ANN), lógica difusa (FL), máquinas de suporte vetorial (SVM) e sistemas adaptativos neuro-difusos (ANFIS). A pesquisa se concentra na avaliação de riscos de desastres, monitoramento e alerta precoce, abrangendo inundações, terremotos, movimentos de massa e outras ameaças (Tan et al. 2020).

Estudos demonstraram que a IA pode avaliar ameaças por meio da análise de dados. Por exemplo, métodos de árvore de decisão, visão computacional, aprendizagem profunda e aprendizagem automática têm sido usados para analisar enchentes, movimentos de massa e incêndios florestais. Essas técnicas se mostraram eficazes no mapeamento de ameaças e na previsão de eventos.

As técnicas de IA também são aplicadas para estimar os possíveis impactos, avaliar a vulnerabilidade e prever danos estruturais usando curvas de fragilidade. Embora haja menos aplicações de IA na estimativa de impacto e na avaliação de vulnerabilidade em comparação com a avaliação de ameaças, essas ferramentas são promissoras para o desenvolvimento de estratégias de atenuação mais eficazes. Além disso, as técnicas de IA podem ajudar a identificar as prioridades de gerenciamento e otimizar os planos de resposta. Por outro lado, as pesquisas sobre o uso de IA para comparar estratégias de mitigação ainda são limitadas (Sun et al. 2020).



Imagem: Adobe Stock



Um dos principais benefícios da IA é sua capacidade de analisar grandes volumes de dados com rapidez e precisão. Isso a torna uma ferramenta valiosa para identificar as áreas mais vulneráveis aos efeitos da mudança climática, como áreas propensas a inundações, movimentos de massa ou secas. Ao analisar dados como modelos climáticos, imagens de satélite e padrões meteorológicos, os governos e as comunidades podem desenvolver planos de adaptação específicos para cada risco. A IA facilita o acesso às informações, o que permite elaborar estratégias de adaptação às mudanças climáticas (Jain et al. 2023).

Do ponto de vista do gerenciamento de **inundações**, os estudos se concentram em quatro aspectos principais: avaliação do risco de inundação, previsão de nível e vazão, modelagem de chuva e escoamento e análise de frequência de inundação (Tan et al. 2020). Para a previsão de nível e vazão, foram usados métodos simples e híbridos, sendo que os métodos híbridos combinam diferentes abordagens para melhorar a precisão e o escopo das avaliações. Além disso, na modelagem do processo de chuva e escoamento, várias metodologias foram usadas para simular fluxos em bacias hidrográficas, incluindo estudos que integram algoritmos de otimização. Embora a análise de frequência de inundação ainda esteja em desenvolvimento limitado, algumas pesquisas começaram a abordar essa questão usando redes neurais e regressões de suporte vetorial para estimar os quantis de inundação em áreas específicas (Tan et al. 2020).

Na revisão da literatura realizada por Bentivoglio et al. (2022) foi descoberto que os métodos de perceptron multicamada (MLP) e as redes neurais convolucionais (CNN) eram os tipos mais comuns de modelos de aprendizagem profunda no mapeamento de inundações, enquanto as redes neurais recorrentes (RNN) eram usadas com menos frequência. Para superar sua falta de tendências indutivas e obter uma boa precisão, os MLPs são frequentemente combinados com outras técnicas estatísticas. Por outro lado, graças às suas tendências indutivas espaciais e temporais, descobriu-se que as CNNs e RNNs superam regularmente outros modelos. Independentemente da aplicação, os resultados mostram que as soluções de aprendizagem profunda superam as abordagens tradicionais e outras técnicas de aprendizagem automática. Os modelos de aprendizagem profunda usados para modelagem substituta oferecem um aumento de velocidade significativo (até 3 ordens de magnitude), mantendo a precisão suficiente (Bentivoglio et al. 2022). Um exemplo da aplicação de modelos de aprendizagem profunda na avaliação de ameaças de inundação é o trabalho de McSpadden et al. (2023) que comparou modelos de inundação de chuva substitutos, mostrando as vantagens da aprendizagem profunda (DL) para a quantificação de incertezas, mantendo altos níveis de precisão e mostrando seu alto potencial no gerenciamento de riscos de desastres.

**A modelagem e as projeções climáticas** com suporte de IA referem-se ao uso de técnicas para melhorar a precisão e a confiabilidade desses modelos. A modelagem climática usa simulações para entender como fatores como as emissões de gases de efeito estufa afetam o clima da Terra ao longo do tempo. A partir desses modelos, são feitas projeções para prever futuras mudanças climáticas. A IA pode analisar grandes volumes de dados de diversas fontes, como imagens de satélite e padrões



climáticos, para identificar tendências e padrões não evidentes com métodos tradicionais, o que ajuda a reduzir as incertezas nas simulações e previsões climáticas. Existem várias técnicas de IA que podem ser aplicadas, como algoritmos de aprendizagem de máquina e redes neurais. Os benefícios da modelagem climática apoiada por IA incluem maior precisão, uma análise mais rápida e eficiente dos dados climáticos e uma melhor compreensão dos possíveis impactos das mudanças climáticas em diferentes regiões e ecossistemas. Essas informações são fundamentais para embasar as decisões políticas e orientar os esforços de adaptação e mitigação frente às mudanças climáticas. Exemplos de sistemas de modelagem e projeção climática com suporte de IA incluem o Google Earth Engine, Climate.ai, IBM Watson e Microsoft Azure, conforme mostrado na **Tabela 10** (Jain et al. 2023).

**Tabela 10. Sistemas de modelagem e projeção climática com suporte de IA**

Sistema de IA	Função	Referência
<b>Climate.ai</b>	Usa IA para analisar dados climáticos e gerar cenários probabilísticos de mudanças climáticas para modelagem e projeções futuras.	Dewitte et al. (2021)
<b>DeepMind</b>	Usa IA para melhorar a precisão da modelagem climática, reduzindo as incertezas nas simulações e previsões climáticas.	Subramaniam et al. (2022)
<b>Google Earth Engine</b>	Usa IA para analisar dados de satélite e gerar modelos climáticos e projeções de alta resolução.	Yang et al. (2022)
<b>Engine IBM Watson</b>	Usa IA para gerar projeções climáticas e avaliar os riscos dos impactos climáticos na infraestrutura e nas cadeias de suprimentos.	Yigitcanlar et al. (2020)
<b>Microsoft Azure</b>	Usa IA para criar modelos climáticos e projeções de alta resolução usando dados de satélite e algoritmos de aprendizagem automática.	Khan et al. (2023)

Fonte: H. Jain et al. (2023)

Além disso, os modelos climáticos baseados em IA permitem que os formuladores de políticas prevejam os impactos e criem estratégias. Por exemplo, sensores e drones com tecnologia de IA permitem o monitoramento e a análise em tempo real dos impactos de eventos climáticos extremos, melhorando a resposta e o gerenciamento de seus efeitos. Da mesma forma, os algoritmos de aprendizagem automática ajudam a criar modelos preditivos sobre as mudanças climáticas, permitindo que os tomadores de decisão planejem e tomem medidas proativas para proteger comunidades e empresas (Jain et al. 2023).



A **Tabela 11** apresenta vários projetos e modelos que usam técnicas de IA para abordar diferentes aspectos relacionados à análise de **inundações e ao impacto das mudanças climáticas** na infraestrutura costeira. Cada projeto é caracterizado pela tecnologia que utiliza, seu objetivo principal e os tipos de dados que analisa. Por exemplo, o CoastalDEM (Kulp e Strauss 2018) concentra-se na criação de modelos digitais de elevação para identificar áreas expostas a inundações costeiras. Além disso, projetos como o CoastalAI e o Deltares (Jain et al. 2023) usam IA para simular o impacto do aumento do nível do mar na infraestrutura, permitindo o desenvolvimento de estratégias de adaptação que protegem as comunidades e a infraestrutura em risco. Em geral, essas iniciativas mostram como a IA pode ser uma ferramenta poderosa para melhorar a resiliência aos desafios climáticos.

**Tabela 11. Exemplos de projetos que usam IA na análise de inundações e mudanças climáticas**

Projeto/Modelo	Tecnologia utilizada	Objetivo	Dados analisados	Resultados esperados
<b>CoastalDEM</b>	Redes neurais.	Criar mapas de elevação de alta resolução.	Imagens de satélite, dados de elevação.	para identificar áreas de risco.
<b>DeepSD</b>	Aprendizagem profunda.	Previsão de mudanças nos padrões climáticos.	Dados dos modelos climáticos.	Previsões sobre temperatura e precipitação em escala regional.
<b>Climate Informatics Toolbox</b>	Aprendizagem automática.	Fornecimento de ferramentas para analisar dados climáticos.	Dados dos modelos climáticos.	Identificação de padrões e tendências em dados climáticos.
<b>CoastalAI</b>	Aprendizagem automática.	Simulação do impacto do aumento do nível do mar na infraestrutura.	Dados climáticos e da infraestrutura.	Estratégias de adaptação para proteger comunidades vulneráveis.
<b>Deltares</b>	Aprendizagem automática.	Simulação do impacto do aumento do nível do mar na infraestrutura.	Dados climáticos e da infraestrutura.	Estratégias de adaptação para proteger comunidades vulneráveis.

Fonte: H. Jain et al. (2023)

A IA pode ser usada para desenvolver **sistemas de alerta antecipado para eventos climáticos**, como furacões e inundações, permitindo que as comunidades se preparem e evacuem antes da ocorrência de um desastre. A aprendizagem automática, em particular, possibilita a previsão de enchentes por meio da análise de dados históricos e da detecção de padrões que indicam a possibilidade de enchentes (consulte **Tabela 13** e **Caixa 1** para ver exemplos de aplicação em sistemas de alerta antecipado). Ao analisar variáveis como padrões climáticos, níveis de água e outras variáveis relevantes, os algoritmos podem estimar a probabilidade de inundação e emitir alertas antecipados para as pessoas em risco, facilitando uma resposta rápida e efetiva (Jain et al. 2023). Em particular, a IA provou ser essencial para melhorar



a precisão e a cobertura das previsões de enchentes. Por exemplo, os modelos baseados em redes neurais, como o LSTM (Long Short-Term Memory), estão sendo usados para prever enchentes em tempo real, mesmo em bacias hidrográficas não monitoradas, onde a falta de dados tradicionalmente torna as previsões menos precisas. Esses modelos podem integrar várias fontes de dados e gerar simulações confiáveis de eventos extremos, o que é fundamental para o gerenciamento de riscos de desastres (Nevo et al. 2022; Gegenleithner et al. 2024; Zhu et al. 2023).

Um exemplo do uso de IA em sistemas de alerta precoce de inundações em nível operacional é o sistema do Google, que provou sua eficácia em ajudar as comunidades vulneráveis a se prepararem e responderem às inundações. O sistema do Google foi desenvolvido para fornecer alertas em tempo real sobre inundações em grandes rios monitorados (consulte **Caixa 1** para obter mais informações sobre esse sistema). Em operação desde 2018, ele expandiu sua cobertura geográfica e atualmente consiste em quatro subsistemas: validação de dados, previsão de níveis, modelagem de inundações e disseminação de alertas. A inteligência artificial é usada na previsão do nível e na modelagem de inundações, usando redes LSTM e modelos lineares para prever os níveis e calcular a extensão e a profundidade das inundações. Durante as monções de 2021, o sistema operou na Índia e em Bangladesh, cobrindo uma região de 470.000 km<sup>2</sup> e enviando mais de 100 milhões de alertas à população afetada e às autoridades competentes (Nevo et al. 2022).

No campo dos **movimentos de massa**, a IA está sendo usada em três áreas principais: detecção, avaliação da suscetibilidade e ameaça e previsão do deslocamento de movimentos de massa com resultados muito promissores. Por exemplo, Akosah et al. (2024) concluíram que os algoritmos de aprendizagem automática e profunda e as tecnologias de sensoriamento remoto avaliam razoavelmente o mapeamento da suscetibilidade a movimentos de massa, com uma precisão de previsão que varia de 56% a quase 100%. He et al. (2024) condensaram suas descobertas sobre as técnicas de IA mais comumente usadas nas áreas de desenvolvimento mencionadas no diagrama mostrado na **Figura 3**.





A detecção de movimentos de massa consiste em identificar e mapear eventos que já ocorreram em uma região, fornecendo informações importantes, como local, tipo, volume e data. Tradicionalmente, isso era feito por meio da interpretação visual de imagens de sensoriamento remoto e fotografias aéreas, o que era caro, demorado e sujeito a viés de interpretação. A IA facilitou a automação desse processo, usando uma tecnologia de reconhecimento de imagem que pode identificar movimentos de massa com mais precisão e eficiência, reduzindo a dependência da interpretação humana e melhorando a objetividade e a reprodutibilidade (He et al. 2024).

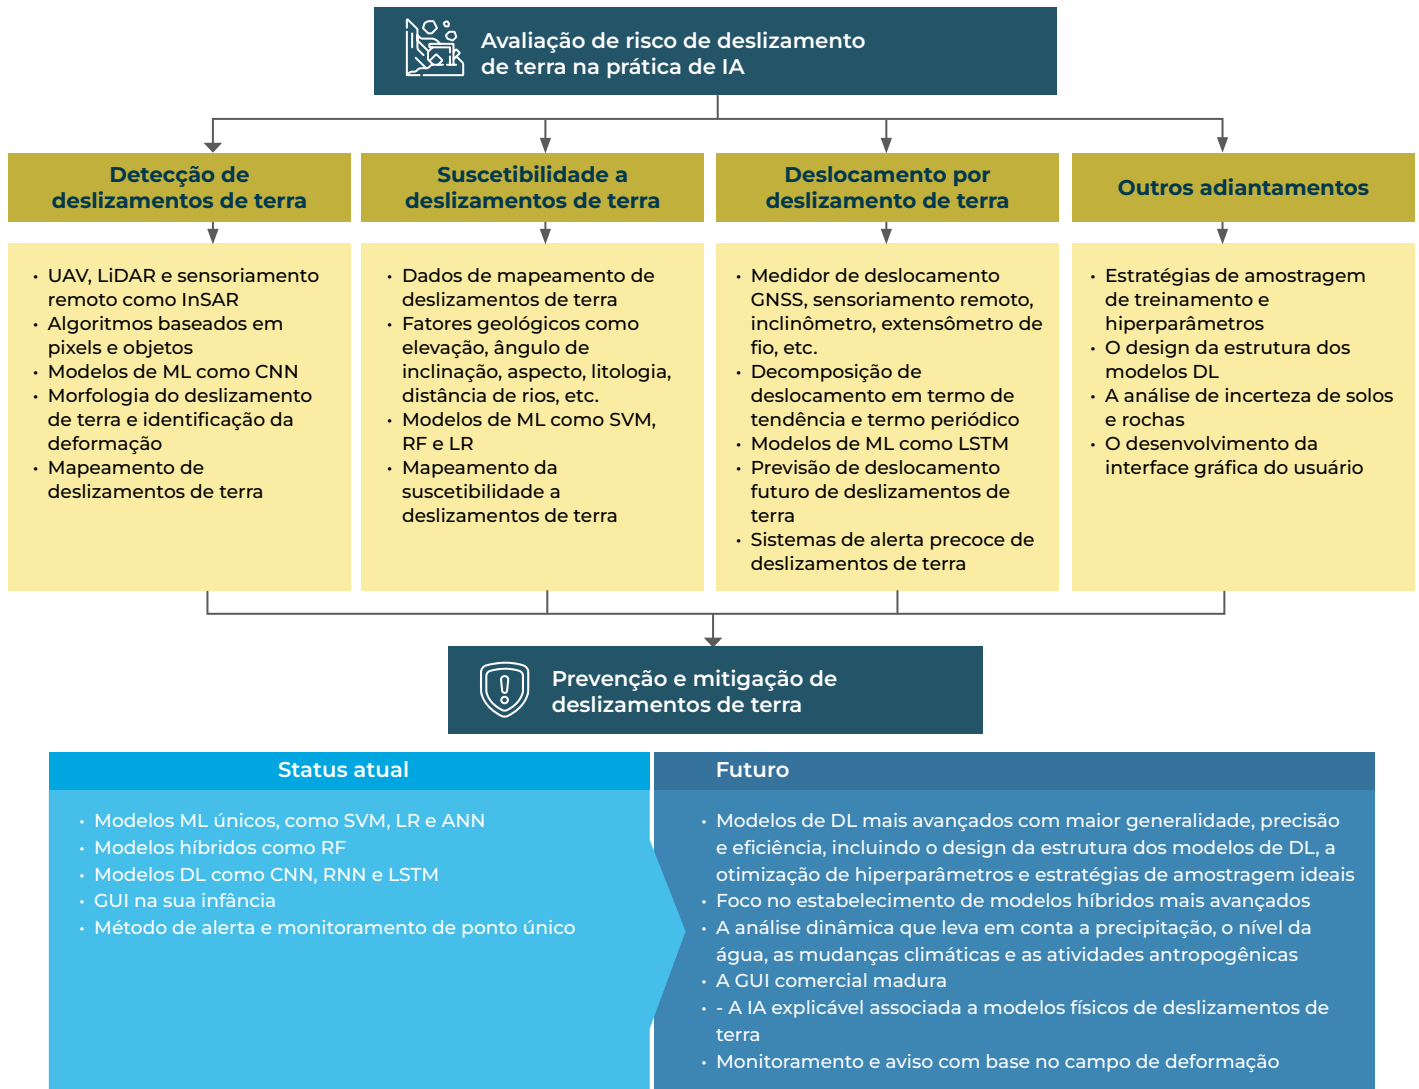
Na avaliação da suscetibilidade e da ameaça de movimentos em massa, a IA ajuda a determinar a probabilidade de ocorrência em uma região específica. Essa avaliação se baseia em fatores como altitude, inclinação, tipo de solo, distância de rios e estradas, entre outros. Tradicionalmente, eram usados métodos estatísticos e conhecimento especializado, que dependiam da experiência prática. Com a IA, os modelos de aprendizagem automática (ML) são usados para mapear a suscetibilidade de forma mais objetiva e eficiente, eliminando fatores de influência altamente correlacionados e mantendo aqueles que são menos correlacionados (He et al. 2024). No caso dos métodos únicos, foram realizadas análises de gatilho, classificadores estatísticos (regressão logística e modelo aditivo generalizado) juntamente com técnicas de aprendizagem automática, como RF e SVM (Tan et al. 2020). Os métodos híbridos, por outro lado, integram diferentes abordagens para fornecer uma avaliação mais abrangente. Dentro dessas abordagens, redes neuro-difusas e modelos de aprendizagem automática, como entropia máxima, SVM e ANN, foram usados para realizar simulações espaciais (Tan et al. 2020).

Um exemplo da aplicação da visão computacional na avaliação de risco de movimentos de massa é o projeto Landslide Reporter (NASA 2024), que usa a coleta de dados por meio da participação pública e da aprendizagem automática para identificar áreas com risco de movimentos de massa com imagens de satélite. Esse projeto foi bem-sucedido na identificação de eventos de movimento de massa e pode ajudar as comunidades a tomar medidas proativas para atenuar os possíveis impactos (Prakash et al. 2021; Shameem Ansar et al. 2022; Jain et al. 2023).





**Figura 3. Práticas atuais e o futuro da aplicação de IA na avaliação de suscetibilidade e risco de movimentos de massa**



Fonte: He et al. (2024).

Em termos de previsão do deslocamento de movimentos de massa, a IA, em especial a aprendizagem profunda (DL), está sendo usada para prever o movimento futuro de movimentos de massa existentes. Os modelos de redes neurais, como as redes convolucionais (CNNs) e as redes neurais recorrentes (RNNs), provaram ser úteis nesse aspecto. Embora a aprendizagem profunda ainda esteja em desenvolvimento nessa área, já foi demonstrado que ela fornece resultados de maior precisão do que os métodos convencionais de aprendizagem automática (He et al. 2024).



A **Tabela 12** resume os métodos identificados por He et al. (2024) como o de melhor desempenho no campo dos movimentos de massa.

**Tabela 12. Modelos com o melhor desempenho para cada aplicação em movimentos de massa**

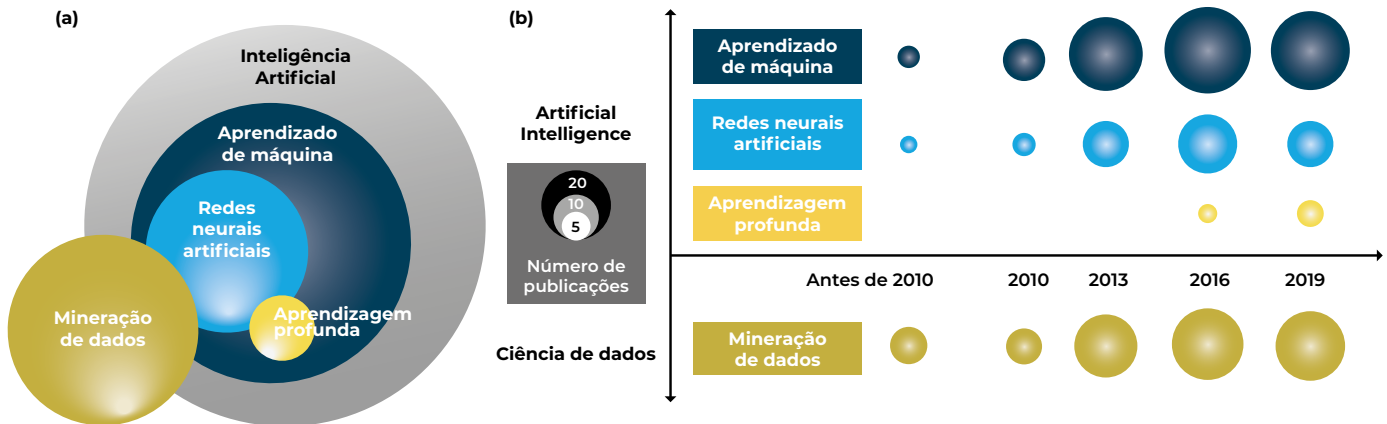
Campo	Modelos com melhor
<b>Deteção de movimentos de massa</b>	Máquina de vetor de suporte, rede neural convolucional, rede neural recorrente e modelos híbridos relacionados.
<b>Mapeamento da suscetibilidade e da ameaça a movimentos de massa</b>	Máquina de vetor de suporte, regressão logística, floresta aleatória, rede neural convolucional, rede neural recorrente e modelos híbridos relacionados.
<b>Previsão de deslocamento de movimentos de massa</b>	Memória de curto e longo prazo, transformador e modelos híbridos.

Fonte: He et al. (2024).

Na área de **gerenciamento de riscos sísmicos**, a IA está revolucionando o mapeamento de riscos ao permitir análises mais precisas e dinâmicas. Ao processar grandes volumes de dados e reconhecer padrões, a IA pode refinar os modelos de ameaças, fornecendo mapas que são atualizados em tempo real à medida que surgem novos dados (Plevris 2024). Foram usados métodos simples e híbridos. No caso dos métodos individuais, os sistemas evolucionários foram usados para prever o nível de risco potencial dos edifícios devido a riscos sísmicos, redes neurais e tecnologias de aprendizagem profunda. Os métodos híbridos, por outro lado, combinam diferentes abordagens para fornecer avaliações mais robustas. Por exemplo, sistemas de inferência baseados em SVM evolutivo foram gerados para integrar modelos de IA (Tan et al. 2020). A **Figura 4** (a) mostra uma ilustração da inter-relação entre as técnicas de IA e a ciência de dados em sismologia. Os algoritmos de aprendizagem automática, como as redes neurais artificiais (ANN), programação genética (GP), mapas auto-organizáveis (SOM), máquinas de vetor de suporte (SVM) e árvores de decisão (DT), são usados para treinar e encontrar determinações implícitas para eventos sísmicos. A aprendizagem profunda, um dos algoritmos mais avançados no campo da aprendizagem automática, usa o conceito de redes neurais artificiais (ANN) para aprender representações generalizadas de conjuntos de dados em diferentes domínios e definir relações não lineares complexas entre variáveis. Os excelentes recursos da aprendizagem automática em conjuntos de dados sequenciais a tornam a escolha ideal para o problema da associação de fases em sismologia, adequada para a análise em tempo real de redes sísmicas. (Jiao e Alavi 2020). A **Figura 4** (b) resume os estudos baseados em IA publicados em sismologia entre 1999 e 2019, mostrando que as ANN são os métodos de aprendizagem automática mais amplamente usados no campo, com um interesse crescente no uso de técnicas de aprendizagem profunda (Jiao e Alavi, 2020).




**Figura 4. Estudos existentes sobre IA e ciência de dados em sismologia. (a) Ilustração da inter-relação entre as técnicas de IA e a ciência de dados em sismologia. (b) Resumo dos estudos baseados em IA publicados em sismologia entre 1999 e 2019**



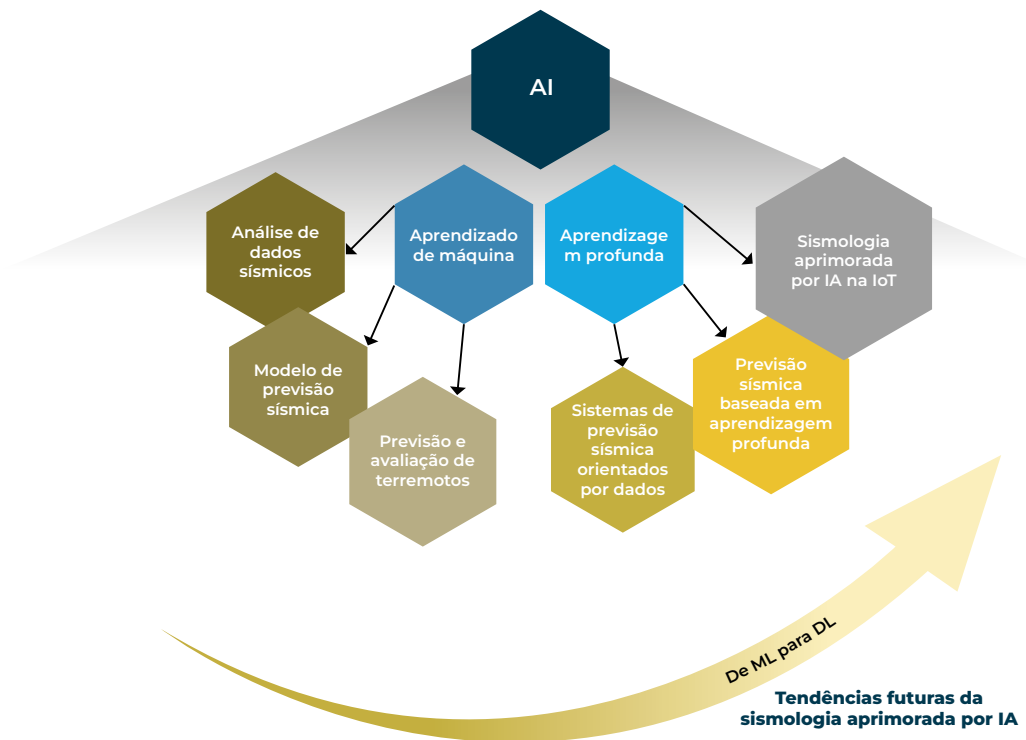
Fonte: Jiao e Alavi (2020).

As abordagens de aprendizagem supervisionada e não supervisionada têm atraído bastante atenção na pesquisa sobre algoritmos de IA aplicados à sismologia. Embora a pesquisa sísmica baseada em aprendizagem automática (ML) tenha se concentrado principalmente no uso de métodos de aprendizagem supervisionada, os métodos de aprendizagem não supervisionada provavelmente desempenharão um papel crucial na sismologia em um futuro próximo (Jiao e Alavi 2020). A **Figura 5** mostra a perspectiva da análise sísmica baseada em IA e destaca a aprendizagem profunda (DL) como uma das tendências futuras para os modelos de previsão sísmica. De acordo com Jiao e Alavi (2020), embora os sistemas sísmicos desenvolvidos com métodos de DL ainda estejam no início, é provável que o maior avanço na sismologia aprimorada por IA seja obtido pela combinação de DL com raciocínio complexo.





**Figura 5. Perspectiva e tendências futuras em sismologia aprimorada por IA, da aprendizagem automática (ML) à aprendizagem profunda (DL).**



Fonte: Jiao e Alavi (2020).

Na área dos sistemas de alerta precoce de terremotos, a integração da IA promete revolucionar esses sistemas com o potencial de melhorar sua precisão e velocidade. Um exemplo de sistema de alerta antecipado de terremotos baseado em IA é o DeepShake, desenvolvido por pesquisadores da Universidade de Stanford (Datta et al. 2022). Esse sistema usa redes neurais espaço-temporais profundas para melhorar a detecção de terremotos. Durante o terremoto de magnitude 7,1 que atingiu Ridgecrest em 5 de julho de 2019, o DeepShake emitiu alertas específicos para todas as estações em sua rede 5 segundos antes da chegada de ondas sísmicas com uma intensidade superior a MMI IV (Plevris 2024). Outro exemplo é o sistema EarthX, no qual os pesquisadores usaram a tecnologia de IA para desenvolver um sistema de monitoramento de terremotos em tempo real capaz de processar simultaneamente os dados de mais de 100 estações sísmicas nas regiões de Sichuan e Yunnan no Centro Experimental de Terremotos da China. Esse sistema conta com detecção e coleta automáticas de fases sísmicas (Zhang et al. 2020).

O projeto resistente a terremotos enfrenta limitações devido à crescente complexidade das estruturas modernas e à variabilidade das condições sísmicas. É nesse ponto que a IA desempenha um papel crucial, oferecendo ferramentas avançadas para processar grandes volumes de dados e otimizar sistemas complexos com mais eficiência. Isso resulta em soluções de projeto inovadoras que equilibram



segurança, custo e sustentabilidade. A IA está revolucionando o campo por meio de simulações que melhoram a dissipação de energia em diferentes cenários sísmicos e otimizam materiais e formas estruturais, alcançando reduções de custo de 18 a 26% com o uso de grandes conjuntos de dados (Plevris 2024). Além disso, a IA facilita o desenvolvimento de projetos generativos, que oferecem várias opções para os engenheiros explorarem alternativas inovadoras que otimizam o desempenho sísmico e, ao mesmo tempo, reduzem o uso de materiais e os custos de construção. No futuro, a integração da IA no projeto resistente a terremotos promete transformar a construção e a manutenção de estruturas em regiões sísmicamente ativas, fornecendo soluções personalizadas que consideram fatores locais e contextuais (Datta et al. 2022).

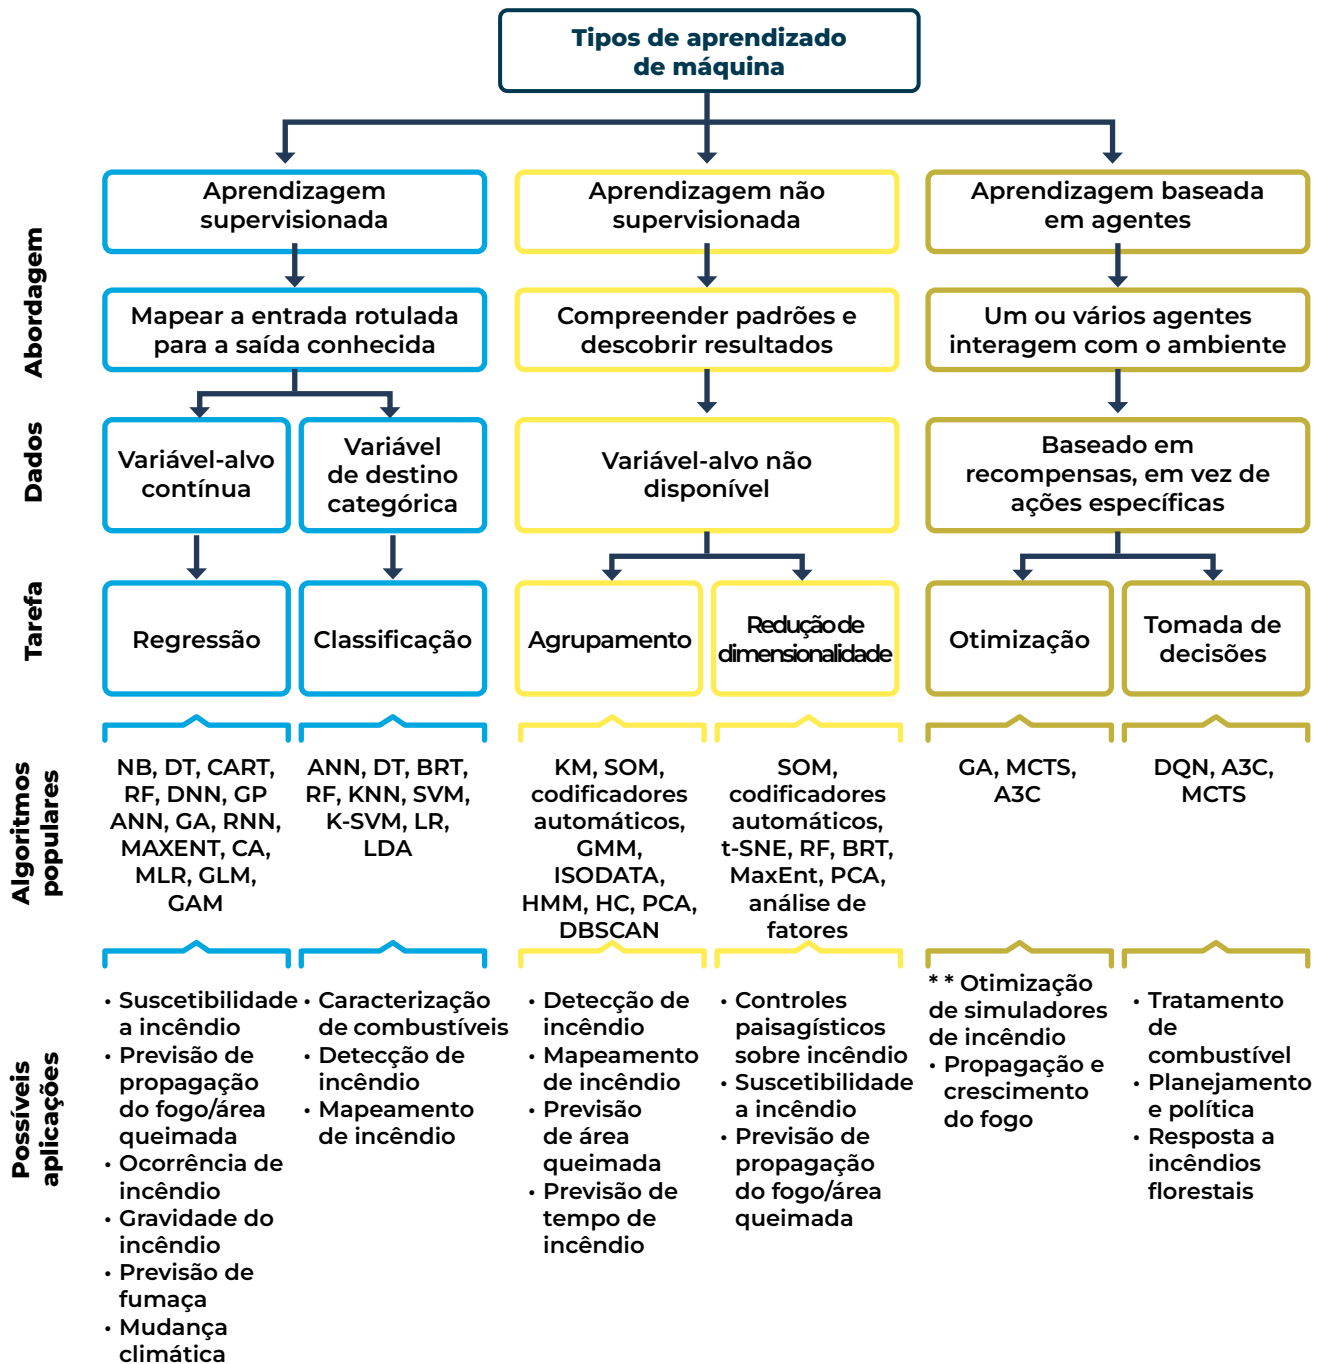
No caso dos incêndios, P. Jain et al., (2020) propõem a classificação dos métodos de ML mostrados na **Figura 6**, constatando que a aplicação de métodos de aprendizagem automática (ML) na ciência e no gerenciamento de incêndios florestais tem crescido desde a década de 1990, usando principalmente métodos tradicionais como florestas aleatórias (RF), máquinas de suporte vetorial (SVM) e redes neurais (ANNs). No entanto, áreas importantes, como a análise preditiva e prescritiva, têm recebido menos atenção, o que abre oportunidades para aplicar o ML na otimização do gerenciamento de incêndios. Além disso, o aumento dos dados espaço-temporais, como o sensoriamento remoto, favorece o uso da aprendizagem profunda (DL) e da aprendizagem baseada em agentes para melhorar a eficiência e a precisão do gerenciamento de incêndios. O uso de DL tem mostrado grandes capacidades, conforme demonstrado por Bjânes et al. (2021) em uma aplicação desenvolvida em duas áreas no Chile, descobrindo que esse método pode gerar mapas de suscetibilidade aos incêndios com métricas de desempenho muito altas em comparação com outros métodos.



Imagem: Adobe Stock



**Figura 6. Diagrama que mostra os principais tipos de aprendizagem automática (ML), tipos de dados e tarefas de modelagem em relação a algoritmos populares e possíveis aplicações na ciência e no gerenciamento de incêndios florestais. Deve-se observar que os algoritmos mostrados em negrito são métodos fundamentais de ML, enquanto os algoritmos que não estão em negrito geralmente não são considerados métodos de ML.**



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



A **Tabela 13** apresenta uma coleção de casos em que os métodos de IA foram aplicados para avaliar a ameaça, vulnerabilidade e risco em diversos contextos. Os exemplos vão desde a detecção de vulnerabilidade sísmica em edifícios usando imagens de satélite e algoritmos de aprendizagem profunda até o monitoramento do crescimento urbano com redes neurais convolucionais. Cada caso inclui detalhes como o objetivo do projeto, os dados de entrada, a unidade de análise, os algoritmos usados e um resumo dos resultados obtidos. Essa diversidade de aplicações destaca o potencial da IA para melhorar a precisão e a eficiência na avaliação de riscos, abordando questões complexas como inundações, pobreza, furacões e movimentos de massa, além de fornecer informações essenciais para o gerenciamento de desastres e o planejamento urbano.

**Tabela 13. Casos de aplicação de métodos de IA na avaliação de ameaças, vulnerabilidades e riscos**

Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Vulnerabilidade sísmica de edifícios na Cidade da Guatemala (GFDRR 2018)</b>	Detecção da vulnerabilidade sísmica de edifícios em áreas urbanas da Cidade da Guatemala, com imagens de satélite, drones e vistas de 360° das ruas para identificar casas com alto risco de desabamento durante um terremoto.	Identificar rapidamente as residências com	Imagens de drones (eBee, RGB, 4 cm), dados de elevação da nuvem de pontos Imagens de vistas de ruas (Trimble MX, 30 megapixels), camada de estradas do OpenStreetMap	Pixel/objeto (edifício)		O método possibilitou examinar 5.000 residências e identificar cerca de 500 que exigem uma inspeção adicional e possível reforço. Ele capturou 85% dos edifícios com “andar macio” identificados pelos engenheiros.
<b>Vulnerabilidade dos edifícios em Sta. Lúcia em face dos furacões (GFDRR 2018)</b>	Avaliação da vulnerabilidade de estruturas individuais em Sta. Lúcia frente a um furacão de Categoria 5, usando as características físicas dos edifícios, como o material do telhado, a forma e o tamanho.	Estimativa da vulnerabilidade dos telhados ante furacões em pequenos estados insulares do Caribe.	Imagens de drone (eBee, RGB, 4 cm), dados de elevação de nuvem de pontos, imagens do nível da rua (Trimble MX, 30 megapixels), dados de referência: contornos de edifícios do OpenStreetMap baixados do geonodo Charim	Edifício/pixel	Modelo de campo aleatório condicional combinado com o MpGlue	A destruição de cada estrutura foi estimada em Sta. Lúcia usando as variáveis que melhor previram os danos na Dominica. O volume, a forma e o tipo de telhado foram variáveis influentes: telhados grandes e de inclinação acentuada com chapas metálicas revestidas com PVF2 apresentaram melhores resultados. O algoritmo previu com mais facilidade o formato do telhado (quadril vs. empena) em comparação com o material, devido à câmera de três bandas do drone.



Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Monitoramento do crescimento urbano por meio do índice de espaço no andar (GFDRR 2018)</b>	Imagens de satélite regulares e sem nuvens, combinadas com algoritmos de aprendizagem automática, são usadas para monitorar o crescimento urbano horizontal e vertical. Este estudo usa dados de altura e de pegadas de edifícios obtidos com colaboração comunitária para treinar um modelo de aprendizagem automática para monitoramento urbano em Dar es Salaam.	Monitorar o crescimento urbano, com foco na área construída e na altura dos prédios	Imagens de satélite (RGB, 3,7 m), Modelo de superfície digital (DSM) extraído de imagens de satélite estereoscópicas (0,8 m)	Pixel	Redes neurais convolucionais de aprendizagem profunda	As informações de referência do OSM foram combinadas com métodos de aprendizagem automática. As pegadas dos edifícios foram extraídas com 77% de precisão; o número correto de andares foi previsto para 23% dos edifícios. Foram encontradas dificuldades em áreas densamente construídas (informais).
<b>Mapeamento de assentamentos informais (GFDRR 2018)</b>	Estudo que investiga a adequação de características derivadas de imagens de satélite de alta resolução para estimar a pobreza em nível local no Sri Lanka.	Estimativa dos níveis de pobreza	Imagens de satélite (RGB, < 0,5 m); características baseadas em objetos: Número de edifícios, Número de veículos, Fração de estradas pavimentadas, Pixels de sombreamento (altura dos edifícios), Tipo/ extensão das culturas, Tipo de telhado. Características baseadas em pixels: Índice de vegetação; PanTex (densidade de assentamentos), Textura	Pixel/objeto (unidade administrativa)	Aprendizagem profunda (redes neurais convolucionais) - Máquinas de vetor de suporte e identificação visual	<ul style="list-style-type: none"> <li>A análise pode explicar de 60% a 61% da variação em uma pequena área (em comparação com 15% quando se usa a análise de luz noturna).</li> <li>A densidade dos edifícios, a área construída e o sombreamento estavam entre as características mais influentes que descreviam as variações na pobreza.</li> <li>Taxas de erro padronizadas de 0,25 a 0,5 das taxas de pobreza ao aplicar o modelo a áreas geograficamente adjacentes.</li> </ul>
<b>Mapeamento de assentamentos informais (GFDRR 2018)</b>	Esse estudo, realizado por Graesser et al. em 2012, mapeou assentamentos informais em quatro grandes cidades usando um algoritmo de ML automatizado para classificar imagens de satélite.	Identificação de assentamentos informais	Imagens de satélite (RGB, < 0,5 m), características baseadas em pixels (índices de vegetação, GLCM PanTex, texturas).	Pixel	Árvores de decisão	As características de textura em imagens de satélite submétricas são adequados para distinguir áreas formais de informais. A precisão do algoritmo de ML foi de 85% a 92% para as quatro cidades estudadas.



Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Estudo sobre a pobreza de Stanford (GFDRR 2018)</b>	Este estudo usa imagens de satélite para prever a porcentagem de famílias acima da linha de pobreza em Uganda, já que o mapeamento da pobreza é caro e difícil de atualizar.	Mapeamento da pobreza	<ul style="list-style-type: none"> <li>Modelo de aprendizagem profunda treinado no ImageNet</li> <li>Imagens de luzes noturnas da NOAA</li> <li>Imagens do Google Maps</li> </ul>	Pixel (grade de 1 km x 1 km), objeto (distritos)	Rede neural convolucional totalmente conectada e classificador de regressão logística	O método proposto pode prever os níveis de pobreza com 72% de precisão, comparável aos resultados da regressão logística usando características baseadas em pesquisas.
<b>Catani, (2021) Jain et al. (2023)</b>	Analisar imagens de satélite para detectar mudanças no uso do solo e na vegetação		Imagens de satélite, dados climáticos, mapas de uso da terra		Aprendizagem profunda	Identificação de mudanças nos padrões de uso da terra e cobertura vegetal para monitoramento do desmatamento e planejamento do uso do solo
<b>Risco</b>						
Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Previsão de danos causados por enchentes (GFDRR 2018)</b>	Este projeto investiga como a inclusão de variáveis adicionais pode melhorar a capacidade de transferência dos modelos de previsão de danos causados por inundações.	Avaliação de danos causados por enchentes	Profundidade da água, tipo de edifício, área da pegada do edifício, área do andar, idade do edifício, porão, tamanho da residência, velocidade do fluxo, duração da inundação, período de retorno, experiência de inundação, medidas de precaução	Tabular (dados de pesquisa)	Redes bayesianas e florestas aleatórias (regressão)	Os modelos treinados com dados heterogêneos (ou seja, eventos de inundação com diversas características) apresentaram melhor desempenho. Enfatiza-se a importância de adquirir um conjunto de treinamento heterogêneo para modelos de danos causados por inundações.
<b>Resiliência sísmica potencializada por aprendizado de máquina para São Francisco (GFDRR 2018)</b>	Modela o dano estrutural causado por terremotos usando um algoritmo proprietário que prevê o dano estrutural. Esse modelo usa várias fontes de dados para estimar o impacto dos terremotos na cidade de São Francisco.	Modelar o dano estrutural causado por terremotos	Características do solo, parâmetros de risco sísmico, características dos edifícios (material, número de andares, área, etc.)	Tabular (dados de pesquisa)	Algoritmo proprietário da OneConcern	As previsões de danos foram feitas em nível de bloco de recenseamento, fornecendo informações situacionais em tempo real antes, durante e depois de um evento sísmico. Isso permite a visualização de dados localizados detalhados e, ao mesmo tempo, mantém o anonimato dos blocos.



Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Avaliação de danos causados por ciclones (GFDRR 2018)</b>	O Banco Mundial e a UAViators coletaram imagens de UAV depois que o ciclone Pam atingiu Vanuatu em 2015. Foram usadas imagens de UAVs em vez de satélites. Os voluntários do Humanitarian Open Street Map (HOT) e da Digital Humanitarian Network registraram os danos nas imagens.	Avaliação de danos	Imagens ópticas de UAV	Pixel	Aprendizagem profunda	Um pipeline foi desenvolvido combinando a anotação de danos por crowdsourcing e a aprendizagem profunda com 63% de precisão.
<b>Tounsi e Temimi, (2023) Jain et al. (2023)</b>	Análise de dados de redes sociais para avaliar a percepção pública das mudanças climáticas		Dados de redes sociais (por exemplo, tweets, postagens e mensagens relacionadas às mudanças climáticas)		Processamento de linguagem natural	Análise do sentimento e da opinião do público sobre as mudanças climáticas para envolver o público em ações e na defesa do clima.
<b>Oh et al. (2020) Jain et al. (2023)</b>	Mapeamento e monitoramento das mudanças no uso da terra no desenvolvimento urbano		Imagens de satélite, mapas de uso da terra, dados de planejamento urbano		Visão computacional	Identificação de mudanças no uso da terra e no desenvolvimento urbano para planejamento e gerenciamento do uso da terra, orientando o desenvolvimento urbano.

### Ameaça

Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Mapeamento global de perigos de movimentos de massa (GFDRR 2018)</b>	Foi treinado um algoritmo que vincula fatores de suscetibilidade a movimentos de massa (declive, geologia, redes de estradas, zonas de falhas e perda de florestas) a eventos históricos de movimentos de massa. Esse modelo é aplicado aos dados de precipitação da missão de Medição Global de Precipitação (GPM) em intervalos de três horas. Se uma região for classificada como altamente suscetível, será emitido um aviso "nowcast".	Mapeamento de perigo de movimentos de massa	Elevação, falhas e regiões geológicas, redes rodoviárias, cobertura florestal, precipitação	0.1°	Árvore de decisão	O modelo teria gerado um "nowcast" para eventos históricos de movimentação em massa com uma taxa de falsos positivos de menos de 3% e uma taxa de verdadeiros positivos de até 60%.



Nome e fonte do projeto	Descrição	Objetivo	Dados de entrada	Unidade de análise	Algoritmo usado	Resumo dos resultados
<b>Mapeamento de extensão de inundação (GFDRR 2018)</b>	Projeto desenvolvido pela Orbital Insight em 2017 que utilizou o Radar de Abertura Sintética (SAR) como entrada para um algoritmo de classificação de imagens.	Mapeamento da extensão de inundações	Imagens ópticas de satélite, imagens SAR (com nuvens), modelos de elevação digital (DEMs), imagens geolocalizadas de fontes de dados de crowdsourcing	Pixel	Aprendizagem profunda	A combinação de diversos tipos de dados espaciais em grande escala ajudou a estimar a extensão das inundações. As imagens de crowdsourcing geolocalizadas podem ajudar a verificar a precisão do mapeamento de inundações.
<b>Linardos et al. (2022) Jain et al. (2023)</b>		Previsão de mudanças e padrões climáticos futuros	Modelos climáticos, dados climáticos históricos, imagens de satélite		Aprendizagem automática	Projeções de temperatura, precipitação e outras variáveis climáticas para informar a política climática e orientar as estratégias de adaptação
<b>Lawal et al. (2021) Jain et al. (2023)</b>		Previsão de inundações	Dados de sensores (precipitação, nível do rio)		Aprendizagem automática	Mapas e alertas de risco de inundação para sistemas de previsão e alerta de inundação.
<b>Park et al. (2020) Jain et al. (2023)</b>		Previsão de incêndios florestais	Dados meteorológicos e de satélite		Aprendizagem profunda	Mapas de ameaça de incêndio e alertas para sistemas de previsão e alerta de incêndios florestais
<b>Wang et al. (2021) Jain et al. (2023)</b>		Identificação de áreas com risco de movimentos de massa	Dados meteorológicos e de satélitedata		Visão computacional	Mapas de ameaça de movimentos de massa e alertas para sistemas de previsão e alerta de movimentos de massa
<b>Mosavi et al. (2018) Jain et al. (2023)</b>		Previsão de inundações	Dados de sensores (precipitação, nível do rio)		Aprendizagem automática	Mapas de ameaças de inundação e alertas para sistemas de previsão e alerta de inundação
<b>Tengtrairat et al. (2021) Jain et al. (2023)</b>		Identificação de áreas com risco de movimentos de massa	Dados meteorológicos e de satélite		Visão computacional	Mapas de risco de movimentação de massa e alertas para sistemas de previsão e alerta de movimentação de massa



## 2.2.2. Resposta a desastres

Na fase de resposta ao desastre, as principais abordagens de pesquisa incluem a análise do ambiente do desastre, o resgate de emergência e a evacuação de pessoas. Os métodos aplicados incluem robótica, redes neurais artificiais (ANN), lógica difusa (FL) e máquinas de suporte vetorial (SVM), entre outros. Essa fase envolve o gerenciamento de vários tipos de desastres, como enchentes, terremotos, movimentos de massa e eventos de precipitação. A pesquisa se concentra na otimização das respostas a situações de crise e na melhoria da eficácia das operações de resgate e evacuação. Por exemplo, no caso das enchentes, veículos aéreos não tripulados foram usados para obter dados de alta resolução que permitem a detecção de áreas inundadas em paisagens urbanas complexas usando algoritmos de inteligência artificial (Tan et al. 2020).

Métodos como o DL foram usados para identificar as áreas mais afetadas por um desastre e fornecer informações para a coordenação de ações de resposta (Ivić 2019). Algoritmos como redes neurais multicamadas feedforward, redes neurais de função de base radial (RBFNN) e florestas aleatórias (Random Forests) têm sido usados para tratar de problemas complexos de previsão e classificação em várias áreas com base no dano detectado da análise de imagens de satélite, aproveitando os recursos de cada algoritmo para identificar padrões e realizar análises avançadas a partir de grandes volumes de dados (Ivić 2019).





Em termos de avaliação de danos, os modelos de inteligência artificial são usados principalmente para determinar a gravidade dos desastres e produzir mapas de danos. Por exemplo, Rodriguez et al. (2011) desenvolveram um sistema de apoio à decisão baseado em regras difusas e o compararam com outros métodos, como a regressão linear múltipla e SVM, para avaliar a gravidade dos desastres. Kou et al. (2014) propuseram um sistema de avaliação de desastres que integra lógica difusa, pesquisa e métodos de tomada de decisão multicritério, mostrando alta precisão e adaptabilidade (Tan et al. 2020).

Outra área inovadora na resposta a desastres é o monitoramento de redes sociais por meio do uso do processamento de linguagem natural (PLN), um subcampo da IA que permite a interação entre computadores e a linguagem humana. O PLN analisa grandes volumes de dados não estruturados, como publicações em redes sociais (por exemplo, Twitter/X), para identificar informações relevantes sobre desastres em andamento. Essa tecnologia ajuda as equipes de resposta a localizar as áreas afetadas, monitorar o sentimento das pessoas e entender suas necessidades em tempo real, facilitando a alocação eficiente dos recursos. Por exemplo, durante o furacão Harvey em 2017, a Guarda Costeira dos EUA usou o PLN para localizar pessoas que precisavam de ajuda, melhorando assim sua capacidade de resposta. De modo geral, o PLN desempenha um papel crucial no fornecimento de informações em tempo real e na ajuda às equipes para que tomem decisões mais embasadas e eficazes (Jain et al. 2023). A **Tabela 14** mostra exemplos do uso dessa tecnologia durante a fase de resposta.

**Tabela 14. Aplicações do processamento de linguagem natural (PLN) na fase de resposta**

Implementação do PLN	Descrição	Exemplo
<b>Análise de sentimento</b>	Avalia o sentimento das postagens nas redes sociais relacionadas a desastres como positivo ou negativo para informar os esforços de resposta.	Análise de tweets durante o furacão Harvey para identificar as áreas com o sentimento mais negativo e direcionar os esforços de resposta conforme necessário (Tounsi e Temimi 2023).
<b>Reconhecimento de entidades nomeadas</b>	Identifica pessoas, locais e organizações específicas mencionadas nas publicações nas redes sociais relacionadas aos desastres.	Identificação dos nomes de abrigos e centros de evacuação mencionados nas publicações nas redes sociais durante um incêndio florestal (Sufi 2022).
<b>Modelagem de temas</b>	Identifica temas ou tópicos comuns discutidos nas publicações nas redes sociais relacionadas aos desastres.	Identificação de questões frequentemente mencionadas, como “fechamento de estradas” ou “ordens de evacuação” durante um furacão (Anthopoulos e Kazantzi 2022).
<b>Information extraction</b>	Extraí informações específicas de publicações nas redes sociais relacionadas a desastres, como solicitações de assistência ou relatórios de danos.	Identificação de solicitações de assistência ou relatos de pessoas desaparecidas em publicações nas redes sociais durante uma enchente (Sufi e Khalil 2024).

Fonte: H. Jain et al. (2023)



## 2.3. Desafios



Imagem: Adobe Stock

Embora os novos conceitos, tecnologias e aplicações relacionados à IA tenham trazido inúmeros benefícios e estejam avançando rapidamente com um grande potencial no gerenciamento de riscos de desastres, eles também enfrentam desafios. Alguns desses desafios, como os mencionados por Xu e Xue (2024) e H. Jain et al. (2023) são apresentados a seguir:

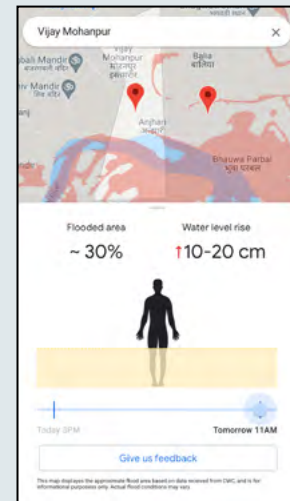
- A introdução de novas tecnologias e aplicações requer que a **equipe** relevante receba treinamento para aprimorar suas habilidades e competências. No entanto, o processo de treinamento pode demandar tempo e recursos, e a contradição entre a oferta e a demanda de talentos deve ser resolvida.
- Algumas dessas novas tecnologias requerem um backup de dados considerável, mas o compartilhamento de dados e a **proteção da privacidade** continuam sendo um desafio. Para garantir a segurança e a legalidade dos dados e, ao mesmo tempo, facilitar seu uso e acesso, é necessária a cooperação entre o governo e as instituições de pesquisa científica. Os sistemas de IA dependem de grandes volumes de dados, incluindo dados pessoais e confidenciais. O uso ético dos dados é essencial para proteger a privacidade e evitar o uso indevido de informações pessoais.



- A tecnologia de IA é cada vez mais crucial na previsão de desastres e no alerta precoce. No entanto, devido às suas características de “caixa preta”, sua **incerteza** pode levar a erros de julgamento, que exigem mais pesquisas e soluções.
- Algumas novas tecnologias e aplicações são **caras** e exigem investimentos consideráveis. Para regiões com menos recursos ou países em desenvolvimento, esses custos podem ser difíceis de assumir, levando a uma aplicação desigual da tecnologia.
- É importante garantir que os novos conceitos, tecnologias e aplicações sejam **devidamente compreendidos e utilizados** pelo público.
- A necessidade de **dados de alta qualidade, o potencial de viés e erro** nos modelos de inteligência artificial e a importância do monitoramento. Os sistemas de IA dependem de grandes volumes de dados para fazer previsões e recomendações. No entanto, se os dados usados para treinar os modelos de IA forem tendenciosos, isso pode levar a resultados tendenciosos. Por exemplo, se os dados usados para treinar um sistema de IA incluírem apenas dados históricos de determinadas regiões ou populações, eles podem não refletir as experiências de outros territórios ou grupos. Isso poderia resultar em previsões e recomendações imprecisas que poderiam afetar desproporcionalmente as populações vulneráveis.
- Esses modelos podem ser altamente **complexos**, o que torna difícil para os formuladores de políticas e as partes interessadas entenderem como eles funcionam e como interpretar seus resultados.
- A **falta de transparência** nos algoritmos usados para desenvolver e treinar modelos de IA também pode complicar a identificação de possíveis fontes de viés.
- As estratégias de redução de risco orientadas por IA podem ter **consequências não intencionais** que poderiam afetar negativamente as comunidades ou os ecossistemas. Por exemplo, se um sistema de IA recomendar a construção de um muro para proteger contra o aumento do nível do mar, isso poderá ter consequências indesejadas para os ecossistemas marinhos.

## Caixa 1. Sistema de alerta antecipado de enchentes do Google

O Google Research desenvolveu um sistema avançado de alerta antecipado de enchentes usando modelos de inteligência artificial (IA) que processam dados públicos de várias fontes. Esse sistema permite que os avisos sejam emitidos com até sete dias de antecedência, fornecendo informações críticas e acessíveis sobre inundações por meio do Flood Hub do Google. Essa plataforma foi projetada para atender às necessidades de governos, organizações de ajuda local e pessoas diretamente em risco, consolidando informações e fornecendo dados locais relevantes de forma gratuita e publicamente disponível. Os alertas também são publicados no Google Search, no Google Maps e nas notificações do Android, tornando-os acessíveis a um público mais amplo (Google 2024a).



Fonte: <https://blog.google/technology/ai/expanding-our-ml-based-flood-forecasting/>

O sistema de previsão baseia-se em dois componentes principais: o Modelo Hidrológico, que prevê possíveis transbordamentos de rios por meio do processamento de dados como precipitação e outras informações meteorológicas e de captação; e o Modelo de Inundação, que simula o comportamento da água nas planícies de inundação. Ambos os modelos são integrados com uma abordagem de IA que fornece previsões finais (Google, 2024). A arquitetura desse sistema é baseada em um modelo de codificador-decodificador LSTM (Long Short-Term Memory), em que um codificador LSTM processa dados meteorológicos e geofísicos históricos e um decodificador LSTM projeta a previsão para os próximos sete dias (Nearing et al. 2024).






Imagem: Adobe Stock

O primeiro piloto do sistema de previsão foi realizado na região de Patna, na Índia, no estado de Bihar, um dos estados mais propensos a inundações do país. Trabalhando com autoridades locais e usando dados em tempo real, um sistema de previsão de inundações foi desenvolvido e incorporado ao Google Public Alerts em 2018, permitindo que a população local seja avisada sobre os riscos iminentes. Em 2019, a cobertura da previsão foi ampliada nacionalmente e estendida a Bangladesh, abrangendo um total de 360 milhões de pessoas. Durante esse período, o sistema forneceu previsões com até 48 horas de antecedência, mas dependia da disponibilidade dos dados locais, o que limitou sua expansão para outros países (Google 2024b).


Diante dessas limitações, o Google mudou seu foco para um modelo global baseado em IA para superar a dependência dos dados locais. Essa nova abordagem exigiu fontes de dados globais para treinar o modelo usando redes LSTM, com o objetivo de prever inundações em regiões sem medições de fluxo locais. Assim, em 2022, o Google lançou a plataforma Flood Hub, que fornecia acesso a previsões em 20 países, incluindo 15 na África, onde a capacidade de previsão era restrita anteriormente (Google 2024b).

Em 2023, a plataforma do Flood Hub se expandiu ainda mais, adicionando cobertura em 60 novos países na África, na região da Ásia-Pacífico, na Europa e nas Américas do Sul e Central. Essa expansão possibilitou a cobertura de 460 milhões de pessoas em todo o mundo, fornecendo previsões gratuitas e em tempo real para muitas comunidades vulneráveis em países em desenvolvimento. Graças aos avanços na modelagem global baseada em IA, o acesso equitativo à previsão de enchentes já está disponível, comparável em regiões da África e da Europa (Google 2024b).



SEÇÃO  
**3**

**MODELOS  
MATEMÁTICOS  
NO CÁLCULO  
DE RISCO DE  
DESASTRES NAS  
PLATAFORMAS  
DE CÁLCULO  
DE RISCO  
DISPONÍVEIS**





## 3.1. INTRODUÇÃO



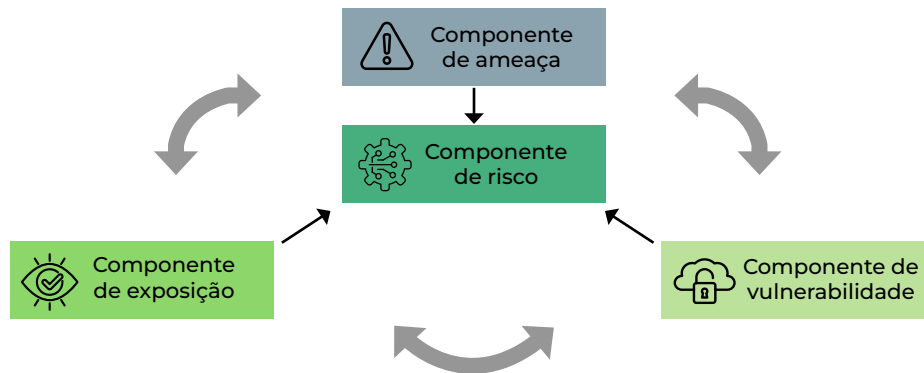
O risco se refere ao resultado final da combinação da magnitude de uma consequência com sua frequência de ocorrência, enquanto os impactos se concentram apenas nas consequências, sem considerar a frequência. O principal objetivo da quantificação de riscos é calcular as perdas econômicas e/ou humanas (BID 2019). A seguir, apresentamos a estrutura conceitual usada na metodologia do Banco Interamericano de Desenvolvimento (BID 2019) que será usada para analisar os recursos de cálculo das plataformas de cálculo de risco que foram avaliadas neste documento.



Um modelo de risco deve incluir os seguintes componentes, mostrados na **Figura 7**:



**Figura 7. Componentes da avaliação de risco**



Fonte: BID (2019).



Cada um desses módulos opera individualmente, com metodologias e critérios específicos. Entretanto, um modelo de risco eficaz deve garantir a interconexão entre os módulos, assegurando a compatibilidade dos formatos de dados e a consistência dos métodos utilizados.

Por exemplo, o módulo de exposição deve contar com uma representação espacial que permita a interação com o módulo de ameaça, identificando quais ativos ou população estão em risco. Também deve incluir características dos ativos expostos que sejam relevantes para o módulo de vulnerabilidade, permitindo uma avaliação do dano potencial. Da mesma forma, o módulo de vulnerabilidade deve ser expresso em termos de intensidade da ameaça e ser consistente com os atributos representados no módulo de exposição.

O módulo de risco atua como o centro de integração do modelo, combinando matematicamente os três módulos para calcular as métricas de risco. Essas métricas podem incluir perdas econômicas (em valores absolutos ou percentuais) e perdas sociais (vidas perdidas, pessoas feridas ou afetadas). Dependendo da abordagem metodológica, essas métricas podem ter diferentes interpretações e se estender a outros indicadores (BID 2019).

A avaliação da incerteza desempenha um papel fundamental na análise de risco. Em termos gerais, a incerteza é classificada em dois tipos principais:

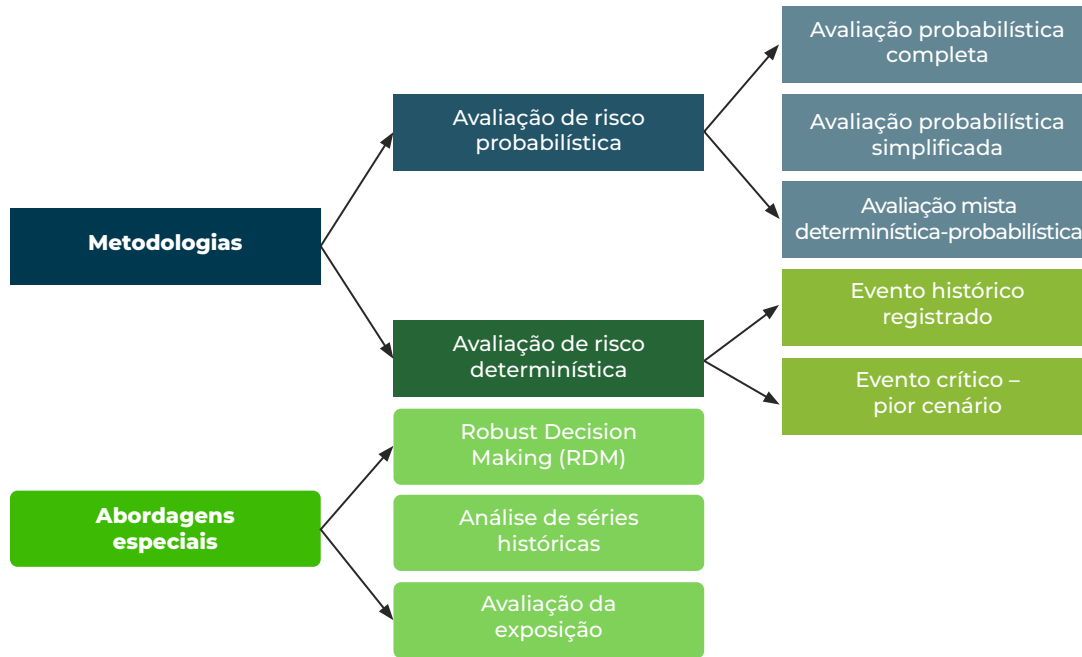
**1**

**Incerteza natural ou aleatória:** Derivada da variabilidade inerente aos processos naturais.

**2**

**Incerteza epistêmica:** Resultado da falta de conhecimento ou de informações sobre o sistema em estudo.

A abordagem mais comum na análise de risco aborda esses tipos de incerteza separadamente utilizando a análise probabilística. Esse método permite derivar uma distribuição de probabilidade dos resultados do risco considerando as variações da incerteza epistêmica. A **Figura 8** apresenta a classificação dos métodos de avaliação de risco propostos pelo BID (2019). As metodologias determinísticas baseiam-se na análise de um único evento, seja ele histórico ou crítico, enquanto as metodologias probabilísticas são divididas em três subcategorias de acordo com a forma como lidam com a incerteza na análise. A **Tabela 25** resume cada metodologia e, para uma descrição detalhada, o leitor deve consultar o documento metodológico do BID (2019). Neste capítulo, serão analisadas as metodologias probabilísticas e determinísticas, excluindo as abordagens especiais, pois o objetivo do artigo é avaliar as plataformas de cálculo de risco com abordagens quantitativas, principalmente probabilísticas.


**Figura 8. Métodos de avaliação de risco segundo o BID (2019)**


Fonte: BID (2019).

As plataformas de cálculo de risco analisadas neste documento empregam diferentes abordagens matemáticas para a estimativa de risco, que podem ser classificadas dentro dos métodos apresentados na **Figura 8**. Algumas dessas plataformas incorporam métodos específicos para quantificar a incerteza, enquanto outras não. Além disso, algumas usam curvas de vulnerabilidade, enquanto outras usam curvas de fragilidade.

Este capítulo examina as abordagens matemáticas usadas nas plataformas para o cálculo do risco probabilístico. A primeira seção apresenta as diferenças conceituais entre as curvas de vulnerabilidade e de fragilidade e discute sua aplicação nas plataformas estudadas. As três seções a seguir apresentam as principais abordagens probabilísticas para a avaliação do risco e descrevem os recursos das plataformas avaliadas com base nessas metodologias. Por fim, a quinta seção resume em tabelas os métodos de avaliação probabilística disponíveis em cada plataforma, bem como as técnicas de quantificação da incerteza que oferecem. O Anexo A complementa esta seção detalhando os métodos usados por cada plataforma.



## 3.2. CURVAS DE VULNERABILIDADE E DE FRAGILIDADE




Imagem: Flickr - IDB Sustainable Cities / Tegucigalpa Honduras

Para avaliar o dano físico que um elemento estrutural pode sofrer devido ao contato direto com uma ameaça, são usadas duas abordagens principais (consulte **Figura 9**): **curvas de vulnerabilidade e curvas de fragilidade** (Nirandjan et al. 2024). Essas curvas permitem modelar a relação entre a intensidade de uma ameaça e o dano potencial dos ativos expostos. Há também outros métodos, como as matrizes e índices (Papathoma-Köhle et al. 2022); no entanto, eles não serão abordados neste documento, pois não são comumente usados nas plataformas de cálculo de risco probabilístico.



**Figura 9. Exemplo de uma curva de fragilidade (painel esquerdo) Exemplo de uma curva de vulnerabilidade (painel direito)**



Fonte: The World Bank (2019).

As curvas de vulnerabilidade vinculam níveis específicos de intensidade de uma ameaça (por exemplo, profundidade da inundação, velocidade do vento) ao possível impacto físico de um ativo. Os danos são expressos em termos absolutos, como custos monetários de reparo, ou em termos relativos pela taxa média de danos (MDR), definida como a razão entre o custo esperado de reparo e o custo total de substituição da estrutura (The World Bank 2019). Por outro lado, as curvas de fragilidade descrevem a probabilidade de um ativo atingir ou exceder um determinado estado de dano em um determinado nível de intensidade da ameaça. Os estados de dano podem ser qualitativos e descritivos, como “leve”, “moderado” ou “extenso”, e são usados com mais frequência em estudos sísmicos, enquanto as curvas de vulnerabilidade são mais comumente usadas na análise de inundações (Papathoma-Köhle et al. 2022; Nirandjan et al. 2024).

Um aspecto crucial da modelagem de riscos é a conversão das curvas de fragilidade em curvas de vulnerabilidade, o que permite a quantificação dos danos econômicos. A transformação se baseia na distribuição cumulativa do custo esperado dado um estado de dano  $E(C | dsi)$  e a probabilidade de um ativo atingir um determinado estado de dano  $P(dsi | im)$  dado um determinado nível de intensidade da ameaça. A função que define a vulnerabilidade é expressa conforme mostrado na **Equação 1**.

**Equação 1**

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



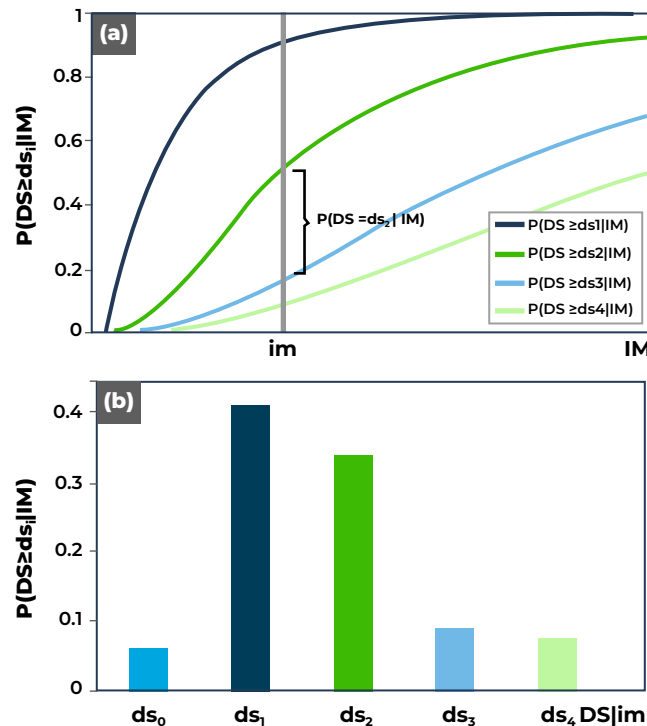
Onde  $n$  corresponde ao número de estados de dano e o estado de dano “nenhum” não é considerado na soma dos estados de dano. Se um intervalo de valores para  $E(C | ds_i)$  estiver disponível, ele será usado para definir os limites superior e inferior da curva de vulnerabilidade; caso contrário, a variação da vulnerabilidade será calculada usando **Equação 2**.

**Equação 2**

$$\text{var}(C | im) = \sum_{i=1}^n (E(C | ds_i) - E(C | im))^2 \cdot P(ds_i | im)$$

A probabilidade de um edifício atingir um estado de dano específico é calculada usando curvas de fragilidade, em que cada barra na distribuição de probabilidade de dano é definida como a diferença entre duas curvas de fragilidade sucessivas para um determinado nível de intensidade (The World Bank 2019). Ao repetir esse processo para diferentes níveis de intensidade, a curva de vulnerabilidade correspondente pode ser construída.

**Figura 10. Cálculo das probabilidades de danos a partir das curvas de fragilidade para um nível específico de medição de intensidade,  $im$ . a) Curvas de fragilidade correspondentes a  $n = 4$  estados-limite de danos. b) Coluna de probabilidades de danos para diferentes estados de danos, considerando um nível de intensidade (adaptado de D’Ayala et al. 2015)**



Fonte: The World Bank (2019).

**Notas:** Estados de dano:  $ds_0$  = Nenhum dano,  $ds_1$  = Dano leve,  $ds_2$  = Dano moderado,  $ds_3$  = Dano extenso,  $ds_4$  = Colapso



As funções de vulnerabilidade e fragilidade são derivadas da análise estatística dos valores de perda ou dano, que podem ser registrados, simulados ou estimados para diferentes níveis de gravidade da ameaça. Na prática, as estatísticas de perdas ou danos podem ser derivadas da observação de eventos passados (abordagens empíricas), estudos analíticos ou numéricos, julgamentos de especialistas ou uma combinação desses métodos (abordagem híbrida). As abordagens empíricas, baseadas em pesquisas pós-evento para avaliar o desempenho de diferentes classes de ativos, geralmente são consideradas a fonte mais confiável de dados sobre perdas e danos, pois se baseiam em observações reais (Pregnotato et al. 2015).

A **Tabela 15** resume os tipos de representação da vulnerabilidade empregados pelas plataformas de cálculo de risco analisadas neste documento. Observa-se que a maioria usa curvas de vulnerabilidade, embora alguns tenham a capacidade de aplicar ambas as abordagens no cálculo.

**Tabela 15. Tipo de representação da vulnerabilidade usado pelas plataformas de cálculo de risco**

Tipo de representação da vulnerabilidade usado	CAPRA	HAZUS	RiskScape	OASIS LMF	IN-CORE	CLIMADA	CATSIM	RiskChanges	FloodRisk	Delft-FIAT	HEC-FDA	OpenQuake
Curva de vulnerabilidade	✓	✓ <sup>1</sup>	✓	✓	✗	✓	✓	✓	✓	✓	✓	✓
Curva de fragilidade	✓	✓ <sup>2</sup>	✓	✗	✓	✗	✗	✗	✗	✗	✗	✓

**Nota:**

1. Abordagem usada pelo HAZUS para inundações.
2. Abordagem usada pelo HAZUS para tsunami, terremoto e furacões.



## 3.3. AVALIAÇÃO PROBABILÍSTICA COMPLETA DAS PLATAFORMAS AVALIADAS

A avaliação probabilística completa do risco fornece informações detalhadas sobre as possíveis perdas e suas probabilidades de ocorrência. Na maioria dos casos, as abordagens totalmente probabilísticas modelam a ameaça e a vulnerabilidade de forma probabilística, mas também há avanços na quantificação da incerteza no componente de exposição. (Mistry e Lombardi 2023).

As fases do processo de análise estão resumidas abaixo. Para informações detalhadas sobre a metodologia, consulte IDB (2019).





O método se baseia na teoria da probabilidade e usa equações matemáticas (como o Teorema da Probabilidade Total) para calcular a probabilidade de perda em função de diferentes cenários de risco e a curva de excedência de perda é obtida, o que permite estimar a frequência de perdas extremas.

Esse tipo de abordagem é usado pelo Hazus Hurricanes, em que as consequências de um furacão em uma cidade ou região são estimadas usando um conjunto probabilístico de eventos, cuja extensão varia de acordo com a geografia. O modelo de simulação da trajetória da tempestade é iniciado por meio da amostragem aleatória de uma posição inicial, data, hora, direção e velocidade de translação de uma das tempestades tropicais registradas no banco de dados HURDAT. O número de tempestades a serem simuladas em qualquer ano é obtido por amostragem de uma distribuição binomial negativa com um valor médio de 8,4 tempestades por ano e um desvio padrão de 3,56 tempestades por ano. (FEMA 2022a). O modelo de perdas é um modelo físico que calcula as perdas econômicas diretas usando uma combinação de técnicas de cálculo de custos explícitas e implícitas (FEMA 2022a).

O modelo de vento do **Hazus Hurricane** segue uma abordagem probabilística baseada na metodologia de perigo-carga-resistência-dano-perda, desenvolvida a partir de uma estrutura de risco individual. O desempenho das edificações diante de ventos extremos é formulado de maneira probabilística usando conceitos de confiabilidade estrutural. A probabilidade de falha de elementos individuais (como janelas ou portas) é estimada pela comparação da carga de vento com a resistência do elemento. Por meio de simulações em diferentes tipos de edificações, as probabilidades de danos são calculadas e as relações entre a intensidade do vento e os danos físicos são estabelecidas (FEMA). A perda média anual com furacões considera todas as perdas futuras causadas pelo perigo de furacões resultantes de possíveis eventos de risco com diferentes magnitudes e períodos de retorno em média por ano (FEMA 2022a).

Uma abordagem totalmente probabilística pode ser aplicada em plataformas como **CAPRA, RiskScape, OASIS FML, CLIMADA, IN-CORE, OpenQuake e Delft-FIAT**. Em teoria, também poderia ser implementada no RiskChanges e no FloodRisk, já que são de código aberto e podem ser adaptados em Python. No entanto, essas ferramentas não serão consideradas totalmente probabilísticas porque não foram originalmente projetadas para realizar esse tipo de cálculo com centenas ou milhares de simulações.

CAPRA, RiskScape, OASIS FML, CLIMADA, IN-CORE, OpenQuake e Delft-FIAT têm a capacidade de realizar cálculos de impacto ou dano usando um grande número de eventos de risco com uma probabilidade atribuída, o que permite o processamento posterior dos dados de dano para construir a curva de excedência de perda. CAPRA, OASIS FML, CLIMADA, IN-CORE e OpenQuake têm seus próprios métodos de quantificação de incerteza, que podem ser encontrados no Anexo A. Esses métodos envolvem execuções repetidas do modelo com parâmetros de entrada variáveis.

---

<sup>10</sup> [https://www.aoml.noaa.gov/hrd/hurdat/Data\\_Storm.html](https://www.aoml.noaa.gov/hrd/hurdat/Data_Storm.html)



## 4.3. AVALIAÇÃO PROBABILÍSTICA SIMPLIFICADA DE RISCO NAS PLATAFORMAS AVALIADAS



Em um cálculo de risco probabilístico simplificado, as perdas são calculadas discretamente para valores específicos de intensidade de perigo com um período de retorno associado. Essas perdas são informadas individualmente e permitem a determinação direta da perda anual esperada (PAE). No entanto, a curva de excedência de perda só pode ser estimada por extrapolação, ao contrário de um cálculo totalmente probabilístico, que fornece uma distribuição de perda completa. Em geral, as abordagens simplificadas não incorporam a incerteza no módulo de vulnerabilidade e usam estimativas de danos médios. O cálculo da PAE baseia-se na curva de perigo, que contém as taxas de excedência (o inverso do período de retorno) para diferentes intensidades de perigo, combinadas com as perdas esperadas para cada intensidade (BID 2019). Para obter informações detalhadas sobre a metodologia, consulte o BID (2019).

As ferramentas descritas na seção 2 podem calcular os danos usando uma abordagem probabilística simplificada para um determinado número de períodos de retorno e curvas de vulnerabilidade ou fragilidade (consulte **Tabela 15** para obter informações sobre o tipo de representação de vulnerabilidade de cada plataforma de cálculo), com exceção da **InaSAFE<sup>11</sup>** e da **FloodRise**, que não realizam cálculos de risco econômico e, portanto, não serão consideradas neste capítulo.

<sup>11</sup> Alguns métodos simplificados para calcular os danos usando as ferramentas QGIS disponíveis estão descritos na documentação da InaSAFE (InaSAFE, 2023), mas, para os fins deste documento, esses métodos não serão considerados.



A equação usada nessa metodologia corresponde a uma discretização que converte as probabilidades de excedência em probabilidades de ocorrência e calcula as perdas médias entre períodos de retorno consecutivos. Por fim, essas perdas são multiplicadas para obter a PAE (BID 2019). A documentação do **FloodRisk** fornece uma explicação detalhada do método (Albano et al., 2017). São usadas funções de dano relativo que expressam os danos como uma proporção do valor total dos ativos (0 = nenhum dano a 1 = destruição total). Essas funções de dano podem ser representadas como curvas de intensidade-dano que combinam o tipo de uso da terra ou o elemento exposto e a intensidade. O parâmetro de intensidade depende do perigo analisado, por exemplo, a FloodRisk usa a profundidade do fluxo (Albano et al. 2017c).

Depois que o dano é calculado para eventos com vários períodos de retorno, aplicando a curva de vulnerabilidade aos elementos expostos, a PAE é determinada da seguinte forma (Albano et al. 2017c):

### Equação 3

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

onde:

$\Delta P_i$  é o aumento da probabilidade de excedência.

$D_i$  é o dano médio de dois eventos com probabilidades de excedência  $P_i$  e  $P_{(i+1)}$ . Para eventos com períodos de retorno  $i$  de 1 a  $n$  períodos de retorno.

Esse método é usado pelo **RiskChanges**<sup>12</sup> (Van Westen e Bakker 2015), **CATSIM** (IIASA 2024a) e **Delf-FIAT**, embora no caso do último a documentação não seja clara sobre se o software calcula a PAE ou apenas o impacto dos eventos, embora a documentação esclareça que ele pode ser usado em conjunto com o Excel e o Python para pós-processamento de resultados e até mesmo ser usado em análises probabilísticas complexas em um ambiente Python (Deltares 2024a). No caso do **OpenQuake** essa abordagem também pode ser aplicada ao cálculo de risco baseado em eventos com um período de retorno associado, com a opção de considerar ou não a incerteza dos parâmetros (veja detalhes no **Anexo A**).

Embora a **CAPRA** e a **CLIMADA** tenham sido projetadas para uma análise de risco probabilística usando métodos de quantificação de incerteza e a simulação de centenas ou milhares de eventos, eles podem fazer cálculos por evento ou grupos de eventos com uma probabilidade atribuída. No caso do RiskScape, a ferramenta distingue três abordagens para o cálculo do risco, que são explicadas em detalhes no Anexo

<sup>12</sup> Deve-se observar que a documentação da ferramenta web em seu site não apresenta informações sobre os algoritmos utilizados para os cálculos; a documentação consultada para identificar o método corresponde a um relatório de progresso do projeto desenvolvido por Van Westen & Bakker (2015) Van Westen & Bakker (2015).



A, sendo uma delas baseada em eventos com uma probabilidade de excedência atribuída. No que diz respeito à **OASIS LMF**, a ferramenta foi projetada para o cálculo de risco totalmente probabilístico, portanto, caso seja necessária uma análise com a aplicação da Equação 3 para um conjunto limitado de cenários, pode ser preferível usar ferramentas mais simples, mesmo que a ferramenta possa realizar o cálculo. Algo semelhante acontece com a **HEC-FDA**, uma ferramenta projetada para a análise de risco de inundação que integra a avaliação de sistemas de proteção e a incerteza associada. Embora possa analisar um determinado número de eventos com uma probabilidade associada, seu principal objetivo não é esse, mas a quantificação da incerteza nos componentes hidrológicos, hidráulicos e de vulnerabilidade da análise de risco de inundação usando métodos de Monte Carlo.

A aplicação da Equação 3 é a abordagem usada pelo **Hazus** para inundações, que esclarece em sua documentação que não aborda a incerteza, embora reconheça sua importância (FEMA 2022b) e avise que os resultados do modelo não devem ser considerados como números exatos e devem ser usados conforme necessário. No entanto, o Comitê de Inundações da FEMA acredita que as decisões de planejamento tomadas com o benefício dos resultados dos modelos serão melhores do que as decisões tomadas sem qualquer consideração da ciência (FEMA 2022b). No caso de tsunamis e terremotos, o Hazus usa curvas de fragilidade na análise. A **IN-CORE** também usa curvas de fragilidade para realizar os cálculos de dano. Primeiro, obtém-se a fragilidade com base no tipo de perigo e nos atributos do edifício (ou de qualquer outro elemento exposto). Com base na fragilidade, calcula-se a intensidade da ameaça na localização do edifício. Com essas informações, é calculada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de perigo sísmico, as informações do solo podem ser usadas para modificar as probabilidades de dano e incluir os efeitos da liquefação (IN-CORE 2024).



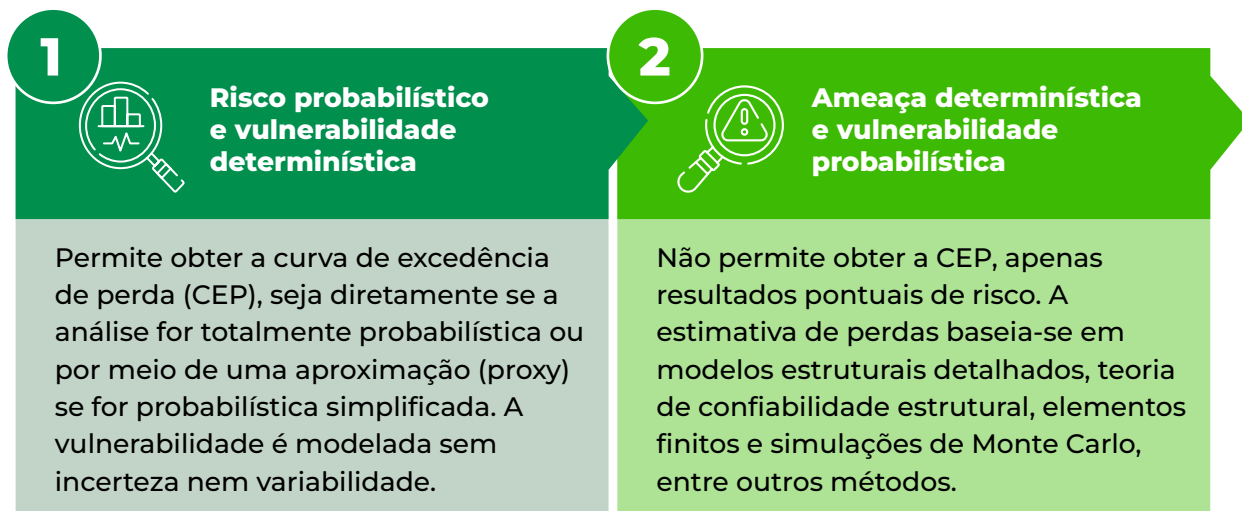
Imagem: Adobe Stock



## 3.5. AVALIAÇÃO MISTA DETERMINÍSTICA-PROBABILÍSTICA

Para a implementação dessa abordagem, é necessário definir quais componentes do modelo de risco serão tratados de forma probabilística (totalmente ou de forma simplificada) e quais componentes serão tratados de forma determinística.

Há dois casos principais:



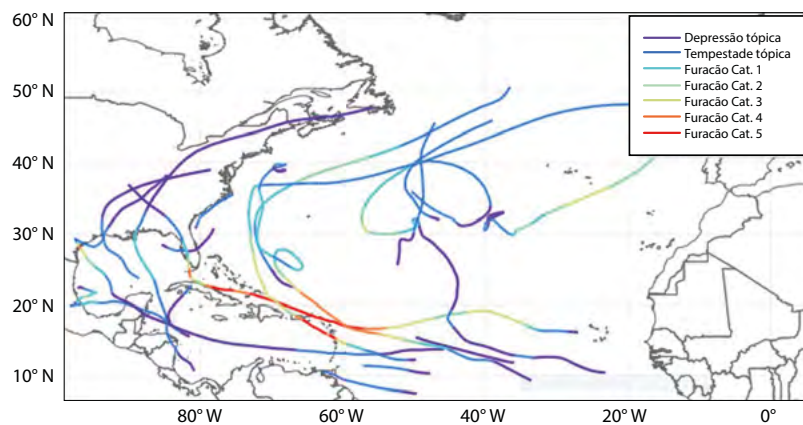
As métricas de risco dependem da abordagem adotada. Se a CEP for obtida, as métricas padrão da análise probabilística serão aplicadas. Na sua ausência, podem ser estimadas as probabilidades de danos, a probabilidade de falha e outros indicadores específicos do setor e do perigo avaliado. Para obter informações detalhadas sobre a metodologia, consulte o BID (2019).

As ferramentas que têm a capacidade de fazer uma avaliação probabilística completa, como a **Hazus Hurricanes, CAPRA, OASIS FML, CLIMADA, IN-CORE e OpenQuake**, podem ser implementadas para realizar avaliações mistas determinísticas-probabilísticas e probabilísticas simplificadas. Ferramentas como o **RiskScape** e a **Delft-FIAT**, embora seus casos de uso e manuais se refiram principalmente a aplicações probabilísticas simplificadas, podem ser usadas para análises mistas, pois podem levar em consideração a incerteza do componente de vulnerabilidade com código adicional (Python).



Em sua documentação online, o CLIMADA apresenta um exemplo de seu uso em uma implementação mista determinística-probabilística, considerando a ameaça probabilística e a vulnerabilidade determinística. Vale mencionar que a CLIMADA conta com o módulo Unsequa para considerar a incerteza de qualquer componente do modelo de risco, mas é uma ferramenta que pode ser usada de diferentes formas e complexidades para quantificar a incerteza. No exemplo, as funções da CLIMADA são usadas para analisar ciclones tropicais usando dados históricos e simulações sintéticas para avaliar o risco desses eventos extremos (ETH Zurich 2017a). Seu módulo TCTracks tem acesso a dados de ciclones tropicais do banco de dados IBTrACS, que compila registros históricos desde a década de 1950 (consulte **Figura 11**).

**Figura 11. Exemplo de tempestades históricas baixadas pela CLIMADA**



Fonte: ETH Zurich (2017a).

No entanto, como os registros históricos são limitados e apenas uma pequena fração dos ciclones atinge a terra a cada ano, essas informações são insuficientes para avaliar com precisão o risco de eventos raros. Para superar essa limitação, a CLIMADA gera ciclones sintéticos com base em registros históricos usando processos de Wiener (um tipo de passeio aleatório direcionado). Isso permite a criação de grandes conjuntos de dados que ajudam a estimar a probabilidade de ciclones extremos raros. Com a CLIMADA, os usuários podem:

1



Carregar dados históricos de ciclones do IBTrACS usando a função `from_ibtracs_netcdf()`, que baixa e armazena os dados para análise.

2



Gerar conjuntos de dados probabilísticos com base nesses registros históricos.

3




Simular trajetórias sintéticas a partir das trajetórias existentes, usando o método `calc_perturbed_trajectories()`, que cria várias versões de uma mesma trajetória com pequenas variações em seu percurso.



O tutorial da CLIMADA sobre a análise de ciclones tropicais em Porto Rico (ETH Zurich 2017a) mostra o uso desse tipo de informação na análise de risco (embora com um número pequeno de eventos para agilizar o cálculo no tutorial), que, após ser usado com uma base de exposição criada a partir do LitPop<sup>13</sup> e funções de vulnerabilidade contidas na CLIMADA, permite obter a curva de excedência de impacto e o PAE (relatado pela CLIMADA como dano anual esperado), conforme mostrado na **Figura 12**.

**Figura 12. Curva de excedência de dano**



Fonte: ETH Zurich (2017a).



## 3.6. RESUMO

A **Tabela 16** resume os métodos de avaliação probabilística que podem ser usados por cada ferramenta e a **Tabela 17** resume os métodos de quantificação de incerteza disponíveis nas ferramentas que podem ser usadas para uma avaliação totalmente probabilística. Para obter mais informações sobre os métodos de cada ferramenta, consulte o **Anexo A**.

<sup>13</sup> O Litpop corresponde ao conjunto de dados de exposição global para avaliação de risco de desastres implementado no software CLIMADA. <https://www.research-collection.ethz.ch/handle/20.500.11850/331316>



**Tabela 16. Métodos de avaliação probabilística que podem ser usados por cada ferramenta**

Avaliação probabilística do risco			CAPRA	HAZUS	RiskScape	OASIS LMF	IN-CORE	CLIMADA	CATSIM	RiskChanges	FloodRisk	Delft-FIAT	HEC-FDA	OpenQuake	
Método	Descrição	Ferramenta													
<b>Avaliação probabilística do risco</b>	<p>Uma avaliação probabilística do risco tem como objetivo tratar algumas das incertezas inerentes ao risco de desastres.</p> <p>Essas incertezas decorrem de (i) disponibilidade limitada de dados históricos, (ii) baixa frequência de eventos catastróficos, (iii) janela de observação reduzida dos desastres e (iv) mudanças nas tendências climáticas, entre outros fatores (ERN-AL, s.d.).</p> <p>Em uma avaliação probabilística, os componentes que integram o risco (principalmente ameaça e vulnerabilidade) são modelados e, em seguida, integrados matematicamente de forma probabilística, reconhecendo e incorporando formalmente a incerteza em todo o modelo.</p> <p>Assim, o modelo pode representar estatisticamente a probabilidade de todos os eventos possíveis, inclusive aqueles que ainda não ocorreram, o que o caracteriza como um modelo prospectivo. Esse tipo de avaliação pode ser aplicado tanto a projetos individuais quanto a grandes portfólios (por exemplo, cidades, sistemas/redes, em nível regional ou até nacional). Isso é, desde que sejam feitos os ajustes necessários no modelo para atender aos diferentes níveis de detalhamento exigidos em cada caso.</p> <p>Embora sejam descritos três tipos de análises probabilísticas, cabe notar que é possível aplicar outros tipos ao combinar elementos desses métodos de diferentes maneiras. Por exemplo, podem ser criados modelos nos quais alguns componentes são tratados de forma totalmente probabilística, outros de forma probabilística simplificada e outros de forma determinística.</p>	<p><b>Avaliação totalmente probabilística:</b> no módulo de ameaça, são gerados dezenas, centenas ou milhares de eventos estocásticos seguindo a teoria probabilística e estatística; da mesma forma, todos esses eventos são usados no cálculo do risco. No módulo de vulnerabilidade, o comportamento e a resposta estrutural recebem um tratamento totalmente probabilístico para integrar os eventos estocásticos e os valores de intensidade da ameaça, exposição e vulnerabilidade, a fim de calcular os danos esperados e suas probabilidades associadas, propagando as incertezas no modelo. O tratamento totalmente probabilístico dos cálculos de risco resulta na distribuição de probabilidades de perdas. Com base nessa distribuição, obtêm-se as métricas de risco: a curva de excedência de perdas (CEP), a perda anual esperada (PAE) e as perdas máximas prováveis (PMP).</p>	<p><b>Avaliação probabilística simplificada:</b> nesse caso, em vez de usar simulações estocásticas, modelam-se apenas alguns períodos de retorno da ameaça. Os períodos de retorno são definidos por meio de diferentes metodologias. Entre as mais frequentes estão: (i) análise estatística de medições instrumentais de eventos geradores de ameaça (precipitação, terremotos); (ii) análise geomorfológica de eventos passados; e (iii) análise estatística de registros históricos (levantamentos, artigos de jornais). Os períodos de retorno são escolhidos de modo a cobrir todo o espectro de eventos possíveis, desde eventos recorrentes até eventos esporádicos. As perdas associadas aos períodos de retorno considerados são estimadas combinando os resultados da ameaça com o módulo de vulnerabilidade (curvas de vulnerabilidade ou de fragilidade usadas de forma probabilística). No entanto, como o módulo de ameaça não atende aos requisitos para o cálculo do risco pelo método totalmente probabilístico, as incertezas aleatórias associadas à ameaça não são propagadas no modelo. Ainda assim, é possível calcular a PAE quando se usam vários períodos de retorno (em geral, são necessários cinco ou mais períodos de retorno para uma análise adequada). É possível obter uma aproximação, ou proxy, da CEP e da PMP por meio da extrapolação dos resultados dos períodos de retorno estimados, mas isso incorpora incertezas adicionais ao modelo (ver o manual do Reino Unido como exemplo). Essa abordagem é mais apropriada para infraestruturas individuais, pois o método de cálculo permite aprofundar mais o detalhamento de cada componente.</p>	<p><b>Avaliação mista probabilística-determinística: nesse método, alguns componentes do risco são modelados de forma probabilística e outros de forma determinística. Por exemplo, são comuns os seguintes casos:</b> (i) a ameaça é modelada de forma probabilística, usando apenas alguns períodos de retorno (probabilística simplificada) e a vulnerabilidade é avaliada de forma determinística; ou (ii) a ameaça é modelada de forma determinística e a vulnerabilidade de forma probabilística, um enfoque comum para a avaliação do risco de deslizamentos. Como alguns módulos não atendem aos requisitos para o cálculo do risco pelo método totalmente probabilístico, as incertezas aleatórias não são propagadas no modelo. No primeiro caso, de maneira semelhante ao método probabilístico simplificado, é possível obter a PAE e um proxy da CEP e da PMP por meio da extrapolação dos valores de perda correspondentes aos períodos de retorno da ameaça. Esse método pode ser usado para estimar a resposta de infraestruturas complexas nas quais, por exemplo, são necessários modelos de elementos finitos e se torna impraticável modelar um grande número de cenários de resposta estrutural. Da mesma forma, na modelagem de sistemas de risco complexos, é mais viável usar uma combinação de métodos probabilísticos e determinísticos.</p>	✓	✓	✓ <sup>1</sup>	✓ <sup>2</sup>	✓ <sup>3</sup>	✓	✓	✓	✓ <sup>4</sup>	✓	✓
				✓	✓ <sup>2</sup>	✓ <sup>3</sup>	✓	✓	✓	✓	✓	✓	✓ <sup>4</sup>	✓	✓
				✓	✓ <sup>2</sup>	✓ <sup>3</sup>	✓	✓	✓	✓	✓	✓	✓ <sup>4</sup>	✓	✓

**Nota:**  
 1. Método usado pelo Hazus para furacões.  
 2. Método usado pelo Hazus para inundações, terremotos e tsunamis.  
 3. Requer desenvolvimento de código pelo usuário para implementar os métodos no RiskScape.  
 4. Requer desenvolvimento de código pelo usuário para implementar os métodos no Delft-FIAT.



**Tabela 17. Resumo dos métodos de quantificação de incerteza disponíveis em ferramentas para uma avaliação totalmente probabilística**

Métodos probabilísticos de avaliação de risco	
Ferramenta	Abordagem para a quantificação da incerteza na análise de risco totalmente probabilística
<b>Furacão Hazus</b>	<p>As consequências de um furacão são estimadas usando um conjunto probabilístico de eventos. O modelo de simulação da trajetória da tempestade é iniciado por meio da amostragem aleatória de uma posição inicial, data, hora, direção e velocidade de translação de uma das tempestades tropicais registradas no banco de dados HURDAT. O número de tempestades a serem simuladas em qualquer ano é obtido por amostragem de uma distribuição binomial negativa com um valor médio de 8,4 tempestades por ano e um desvio padrão de 3,56 tempestades por ano. (FEMA 2022b). O modelo de perdas é um modelo físico que calcula as perdas econômicas diretas usando uma combinação de técnicas de cálculo de custos explícitas e implícitas (FEMA 2022b).</p> <p>O modelo de vento do Hazus Hurricane segue uma abordagem probabilística baseada na metodologia de perigo-carga-resistência-dano-perda, desenvolvida a partir de uma estrutura de risco individual. O desempenho das edificações diante de ventos extremos é formulado de maneira probabilística usando conceitos de confiabilidade estrutural. A probabilidade de falha de elementos individuais (como janelas ou portas) é estimada pela comparação da carga de vento com a resistência do elemento. Por meio de simulações em diferentes tipos de edificações, as probabilidades de danos são calculadas e as relações entre a intensidade do vento e os danos físicos são estabelecidas (FEMA). A perda média anual com furacões considera todas as perdas futuras causadas pelo perigo de furacões resultantes de possíveis eventos de risco com diferentes magnitudes e períodos de retorno em média por ano (FEMA 2022b).</p>
<b>CAPRA</b>	<p>Teorema da probabilidade total para calcular a taxa de excedência de perdas, considerando a incerteza na intensidade do evento e na resposta estrutural.</p> $v(p) = \sum_{i=1}^{Eventos} Pr(P > p   Evento i) \cdot F_A(Evento i)$ <p>A taxa de excedência dos valores de perda <math>v(p)</math> é dada em função da <math>Pr(P &gt; p   Evento i)</math> probabilidade de excedência de perda dada a ocorrência do evento <math>i</math> e <math>F_A(Evento i)</math> a frequência anual de ocorrência do evento <math>i</math>.</p> $PAE = \sum_{i=1}^{Events} E(P   Event i) F_A(Event i)$ <p>A PAE é a perda anual esperada, em que <math>E(P   Evento i)</math> é a perda esperada do evento <math>i</math>, e <math>F_A(Evento i)</math> é sua frequência anual de ocorrência.</p>
<b>OASIS LMF</b>	<p>Um conjunto de eventos representativos de todos os possíveis eventos que podem ocorrer, juntamente com sua intensidade e probabilidade em um período de tempo suficientemente longo para abranger toda uma distribuição.</p> $p_{id} = p_i^f * p_d^v$ <p>Onde:  <math>p_{id}</math> é a probabilidade de que ocorra uma intensidade <math>i</math> e provoque um dano <math>d</math>.  <math>p_i^f</math> é a massa de probabilidade correspondente ao intervalo de intensidade.  <math>p_d^v</math> é a massa de probabilidade correspondente ao intervalo de dano.</p> <p>O cálculo de <math>p_{id}</math> é realizado para cada combinação de evento, área de perigo (<i>peril</i>), e função de vulnerabilidade. Em seguida, o valor de <math>p_{id}</math> é somado ao longo dos intervalos de intensidade:</p> $p_d = \sum_i p_{id}$ <p>O resultado é <math>p_d</math>, que representa a probabilidade de um intervalo de dano <math>d</math> para cada evento, área de perigo e função de vulnerabilidade.</p> <p><b>1. Integração determinística</b></p> $x_{EY} = tiv_Y * d_{EY}$



Métodos probabilísticos de avaliação de risco

Ferramenta

Abordagem para a quantificação da incerteza na análise de risco totalmente probabilística

Onde:  
 $x_{\epsilon\gamma}$  é a perda em um evento  $\epsilon$  e a cobertura  $\gamma$ .  
 $tiV_{\gamma}$  é o valor total segurado.  
 $d_{\epsilon\gamma}$  é o fator de dano.

2. Amostragem aleatória (Monte Carlo)

Análise determinística e probabilística e análise de incerteza e sensibilidade com métodos de Monte Carlo.

$$x_{ij} = val_j f_{imp}(h_{ij} | y_i)$$

Em que  $x_{ij}$  e  $h_{ij}$  representam, respectivamente, o dano e a intensidade da ameaça para o evento  $i$  na localização  $j$ ;  $val_j$  é o valor de exposição na localização  $j$ ;  $\gamma_j$  são os parâmetros de exposição que caracterizam sua vulnerabilidade e  $f_{imp}$  é a função de dano.

$$EAI_j = \sum_{i=1}^{N_{hist}} \sum_{i'} x_i F(E_i) = \sum_{i=1}^{N_{EV}} x_{ij} F(E_i)$$

$EAI_j$  é o dano anual esperado do elemento  $j$  onde  $X$  é a variável aleatória de dano,  $E$  sua expectativa,  $E_i$  é um evento e  $F$  sua frequência (anual).  $N_{hist}$  é o número de eventos históricos,  $i'$  representa um evento histórico,  $i$  representa todos os membros do conjunto do evento  $i$  e  $N_{EV}$  representa o número total de eventos.

CLIMADA

Quantificação da incerteza no risco de inundação por meio da simulação de Monte Carlo para amostragem de curvas, incluindo o desempenho das obras de proteção contra inundações.

$$E[X] = \int_{-\infty}^{\infty} x f_x(x) dx = \int_{-\infty}^{\infty} (1 - F_x(x)) dx \quad F_x(x) = P(x \leq x) \quad 1 - F_x(x) = P(X \geq x)$$

Onde:  
 $X$  = consequências (por exemplo, dano por inundação, perda de vidas, custos de atendimento de emergência).  
 $E[X]$  = valor esperado das consequências  
 $x$  = valor das consequências  
 $f_x(x)$  = função de densidade de probabilidade da probabilidade de  $X$   
 $F_x(x)$  = função de distribuição acumulada de  $X$

HEC-FDA

Cálculo baseado em cenários, eventos probabilísticos, com base no PSHA clássico

1. Cenários

$$LR = \frac{\sum_{n=1}^m LR_n | IML}{m}$$

$LR$  é a taxa de perda média para cada ativo em todas as simulações possíveis do evento, em que  $m$  representa o número de campos de movimento de solo simulados e  $IML$  representa os níveis de medição de intensidade.

2. 2. Eventos probabilísticos

$$\lambda(L_n) = \frac{NE_L}{TSES}$$

$\lambda$  representa a taxa de excedência do respectivo índice de perda,  $NE_L$  representa o número de excedências da perda em questão e  $TSES$  representa o período de tempo de todos os conjuntos de eventos estocásticos.

$$PE(L_n) = 1 - \exp - \lambda_n \times t$$

$PE(L_n)$  a probabilidade de exceder o conjunto de perdas em um determinado período de tempo

OpenQuake



SEÇÃO

# 4

# **MÉTODOS QUE INCORPORAM A VULNERABILIDADE SOCIAL E/OU A GOVERNANÇA NA ANÁLISE DE RISCOS**





## 4.1. INTRODUÇÃO



Imagem: Adobe Stock

Uma abordagem holística fornece informações essenciais que complementam as avaliações de risco de desastres, ajudando os tomadores de decisão a entender as causas específicas de perdas significativas em grupos vulneráveis (Nkwunonwo et al. 2015). A necessidade de incluir fatores sociais, econômicos, ambientais e físicos nas avaliações de vulnerabilidade está incorporada no Quadro de Ação de Hyogo e enfatizada no Quadro de Sendai para a Redução do Risco de Desastres 2015-2030, que estabelece como prioridade a compreensão dos riscos de desastres em todas as suas dimensões (Assembleia Geral das Nações Unidas, 2015).



A quantificação da dimensão física da vulnerabilidade pode ser feita com métodos empíricos e analíticos (Sterlacchini et al. 2014). No entanto, ao considerar as várias dimensões da vulnerabilidade, surgem desafios para medir aspectos que não podem ser facilmente quantificados. Birkmann (2006) sugere que indicadores e índices podem ser usados para medir a vulnerabilidade a partir de uma perspectiva integral e multidisciplinar, capturando tanto os impactos físicos diretos (exposição e suscetibilidade) quanto os indiretos (fragilidade socioeconômica e falta de resiliência). A importância dos indicadores está em seu uso potencial para o gerenciamento de riscos, pois são ferramentas úteis para (i) identificar e monitorar a vulnerabilidade ao longo do tempo e do espaço, (ii) desenvolver uma melhor compreensão dos processos subjacentes à vulnerabilidade, (iii) desenvolver e priorizar estratégias para reduzir a vulnerabilidade e (iv) determinar a eficácia dessas estratégias (Rygel et al. 2006). Entretanto, desenvolver, testar e implementar indicadores que capturem a complexidade da vulnerabilidade continua sendo um desafio.

Embora o amplo desenvolvimento de ferramentas de análise estatística e de geoprocessamento forneça uma estrutura sólida para a construção de indicadores, a disponibilidade desigual de dados em diferentes regiões geográficas e os desafios associados à captura dos determinantes da vulnerabilidade em comunidades específicas tornam a criação de indicadores e índices de vulnerabilidade uma tarefa complexa e desafiadora.

O processo de construção de indicadores começa com o desenvolvimento de uma estrutura teórica que fornece a base conceitual necessária. As variáveis relevantes são então selecionadas para representar as múltiplas dimensões da vulnerabilidade. No caso de dados ausentes, é feita uma estimativa para completar as informações necessárias. Posteriormente, é realizada uma análise multivariada para explorar as relações entre as variáveis. Esse processo geralmente inclui a padronização de dados para garantir a comparabilidade entre diferentes conjuntos. As variáveis são então ponderadas e agregadas para construir o indicador final. Por fim, a robustez e a sensibilidade do indicador são avaliadas, e uma análise de incerteza pode ser realizada (OECD & JRC, 2008). Há métodos diferentes para cada uma dessas etapas. Por exemplo, a análise multivariada pode usar técnicas como a análise dos componentes principais, análise fatorial, coeficiente alfa de Cronbach, análise de cluster, entre outras. Em termos de ponderação, podem ser usados métodos como a análise de componentes principais ou análise hierárquica, entre outros (OECD e JRC 2008).

Os métodos estatísticos geralmente estão disponíveis em pacotes de funções R ou Python, bem como em softwares de informações geográficas (SIG), como QGIS e ArcGIS. Entretanto, o maior desafio está na criação de indicadores que se ajustem à disponibilidade de informações e que capturem adequadamente as dimensões específicas da vulnerabilidade em cada comunidade.

Este capítulo apresenta uma análise das ferramentas gratuitas disponíveis para a criação de indicadores de vulnerabilidade. No entanto, deve-se observar que não existe uma estrutura única e universalmente aceita para a criação de indicadores.



## 4.2. MÉTODOS INCORPORADOS NO PLUG-IN DO OPENQUAKE



Imagem: Adobe Stock

O plug-in OpenQuake Integrated Risk Modelling Toolkit (IRMT) é uma ferramenta desenvolvida pela GEM<sup>14</sup> que se integra ao QGIS para uma avaliação integral do risco sísmico e qualquer outro tipo de risco. Isso facilita o desenvolvimento de indicadores para avaliar as características socioeconômicas relacionadas à vulnerabilidade e ao risco. O plug-in também integra a capacidade de resposta das populações e combina medidas de risco físico e social. Ele permite que os usuários desenvolvam um fluxo de trabalho integrado para a construção de métricas que avaliam as características sociais que afetam o risco sísmico, fornecendo uma plataforma baseada em SIG para a criação de indicadores e índices compostos, o que promove avaliações comparativas (GEM, 2024c).

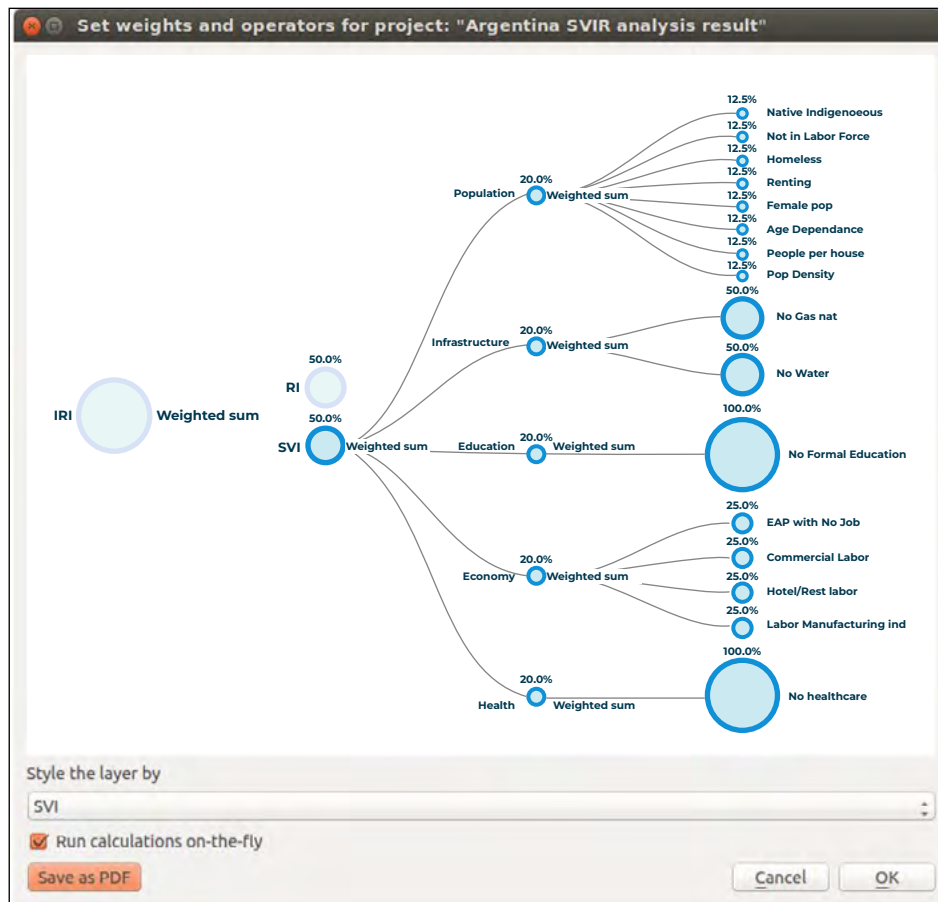
O OpenQuake IRMT facilita a integração de indicadores compostos de características socioeconômicas com medidas de risco físico, como estimativas de perdas humanas ou econômicas, proveniente do OpenQuake Engine (OQ-engine) ou de outras fontes. O plug-in pode ser usado para qualquer tipo de desenvolvimento de indicador (GEM, 2024c).

<sup>14</sup> <https://www.globalquakemodel.org/products>



O plug-in OpenQuake IRMT oferece vários recursos para a criação e o gerenciamento de indicadores compostos na análise de risco. Os usuários podem definir procedimentos de ponderação e agregação para os indicadores, que podem ser simples (ponderação igual) ou mais complexos (ponderações específicas, agregação linear ou geométrica). Além disso, proporciona uma interface gráfica dinâmica, que facilita a criação e a edição de modelos compostos com uma árvore de ponderação e agregação (consulte **Figura 13**). Essa interface permite que os usuários desenvolvam modelos de forma visual e fácil. A estrutura em árvore permite o desenvolvimento de modelos hierárquicos de risco integrado. O ponto de partida é um nó raiz que corresponde ao desenvolvimento de um modelo hierárquico que pode ser: 1) um Índice Integrado de Risco (IRI) que é uma função da agregação de um Índice de Vulnerabilidade Social (IVS) e um Índice de Risco (IR); ou 2) um Índice de Vulnerabilidade Social (IVS) que é o resultado da agregação de vários subindicadores definidos pelo usuário (por exemplo, Economia, Educação e Meio Ambiente, etc.). A árvore pode ser modificada dinamicamente, adicionando ou excluindo nós, invertendo variáveis, definindo um peso para cada variável ou nó e escolhendo os operadores a serem usados para combinar variáveis.

**Figura 13. Estrutura em árvore para o desenvolvimento de indicadores compostos**



Fonte: GEM (2024c).



O plug-in oferece suporte a dois tipos principais de modelos compostos para indicadores:

**1****Modelos dedutivos:**

Em geral, eles usam menos de dez indicadores padronizados e agregados.

**2****Modelos hierárquicos**

Eles usam de dez a vinte indicadores, agrupados em subíndices (por exemplo, população, economia) que são agregados para formar um índice composto final (por exemplo, índice de vulnerabilidade social).

Os usuários podem modificar a árvore de indicadores compostos adicionando ou excluindo nós, atribuindo pesos e escolhendo operadores para combinar variáveis. As alterações são refletidas imediatamente nos cálculos e nas visualizações.

Os cálculos de risco físico e os índices compostos podem ser executados diretamente no QGIS, com os resultados exibidos como camadas vetoriais.

O plug-in oferece operadores básicos para combinar variáveis, e os usuários podem definir fórmulas personalizadas para o cálculo dos indicadores. As técnicas de ponderação podem ser baseadas em modelos estatísticos ou abordagens participativas.



## 5.3 PLUGINS QGIS PARA ANÁLISE MULTICRITÉRIO

O QGIS, uma plataforma de software livre para Sistemas de Informações Geográficas (SIG), é amplamente utilizado para realizar a análise multicritério (MCA), uma metodologia comumente empregada na criação de indicadores de vulnerabilidade e risco. No QGIS, a MCA pode ser realizada diretamente usando os recursos de cálculo entre camadas vetoriais ou rasterizadas, ou por meio do uso de plug-ins especializados que facilitam a criação de indicadores e a análise de dados complexos. Entre os mais proeminentes estão o Modelo de Avaliação de Sustentabilidade Espacial (SSAM) e a Análise Multicritério Ponderada (WMCA).



### 4.3.1. Modelo de Avaliação de Sustentabilidade Espacial (SSAM)<sup>15</sup>

O SSAM é um plug-in do QGIS projetado para avaliação da sustentabilidade em ambientes geográficos, usando critérios ambientais, econômicos e sociais. Ele implementa o algoritmo TOPSIS, que gera uma classificação com base na distância até o pior ponto e na proximidade de um ponto ideal para cada critério. As ponderações podem ser inseridas diretamente ou usando uma tabela de comparação de pares, permitindo que o usuário defina um vetor de ponderação final de forma repetível e verificável. O SSAM produz resultados geográficos e gráficos, exibindo mapas dos resultados da análise multicritério e valores numéricos de sustentabilidade usando barras, bolhas e pontos.

O SSAM também implementa o algoritmo DOMLEM com base na teoria do “conjunto aproximado baseado em dominância”, permitindo que o usuário conheça as regras de decisão derivadas do algoritmo TOPSIS e tenha uma visão melhor da classificação de sustentabilidade exibida em mapas e gráficos. Essa abordagem aumenta significativamente a transparência e a capacidade analítica.

O plug-in usa arquivos vetoriais geográficos (*shapefiles*), em que os dados gráficos representam as unidades de avaliação e os dados alfanuméricos descrevem os indicadores ambientais, econômicos e sociais. Os algoritmos do plug-in permitem tratar esses indicadores separadamente e calcular três índices diferentes, cuja combinação linear fornece um índice geral de sustentabilidade para cada unidade geográfica.

O usuário pode usar uma ampla variedade de indicadores ou um conjunto de dados preparado por ele. Os indicadores a serem usados em uma análise correspondem aos atributos que o usuário atribui no arquivo base (*shapefile*) de sua análise. Devido a essa flexibilidade, embora o plug-in tenha sido criado para análise de sustentabilidade, ele pode ser adaptado para o cálculo de indicadores de risco considerando vários critérios socioeconômicos.

### 4.3.2. Análise Multicritério Ponderada (WMCA)<sup>16</sup>

O plug-in WMCA é outra ferramenta fundamental do QGIS para realizar análises multicritério ponderadas. Esse plug-in permite que os usuários atribuam pesos específicos a diferentes critérios e calculem uma avaliação combinada com base nesses pesos. O plug-in exibe os valores de pixel de um raster para o usuário, permitindo atribuir pesos a cada raster e classificações a cada classe dentro deles. Ele foi desenvolvido para realizar análises multicritério ponderadas, especialmente em estudos ambientais, como análise de fragilidade ou favorabilidade, zoneamento ambiental e outros tipos de zoneamento.


<sup>15</sup> <http://maplab.alwaysdata.net/doc/html/index.html>

<sup>16</sup> <https://github.com/romariocarvalhoneto/Weighted-Multi-Criteria-Analysis---WMCA>



SEÇÃO  
**5**

# MUDANÇAS CLIMÁTICAS E CÁLCULOS DE RISCO





## 5.1. INTRODUÇÃO



Imagem: Adobe Stock

A incorporação das mudanças climáticas na estimativa de riscos requer metodologias robustas que permitam estimar os possíveis impactos futuros na infraestrutura e na população. Nesse contexto, a modelagem de riscos em diferentes cenários climáticos torna-se fundamental para informar as estratégias de adaptação e resiliência.

Nesta seção, é apresentada uma análise das abordagens das plataformas apresentadas na seção 1 para incorporar as mudanças climáticas nos cálculos de risco, com foco especial na plataforma CLIMADA.



## 5.2. Estimativa de risco ao incorporar a mudança climática nas plataformas



Entre todas as plataformas analisadas, a CLIMADA é a única que possui métodos específicos para a análise de mudanças climáticas na avaliação de riscos. Isso a torna uma ferramenta particularmente útil para a tomada de decisões em contextos de incerteza climática, pois permite avaliar não apenas os riscos atuais, mas também sua evolução sob diferentes trajetórias de emissões.

No entanto, isso não significa que outras plataformas multiameaça ou de inundações sejam incapazes de incorporar as mudanças climáticas em seus cálculos de risco. Desde que a modelagem da ameaça inclua cenários climáticos projetados, é possível avaliar o risco incorporando o impacto da mudança climática em qualquer um deles. A avaliação da ameaça futura exigirá projeções ou cenários relacionados à mudança climática, que devem ser gerados a partir de modelos climáticos que possam estimar as mudanças nas principais variáveis, como precipitação, temperatura e nível do mar.

No caso das enchentes, por exemplo, os métodos para analisar as projeções de precipitação e convertê-las em fluxos que podem ser usados em modelos hidrodinâmicos para gerar camadas de risco em cenários de mudança climática podem ser agrupados em três abordagens principais, conforme mostrado na **Tabela 18**. Essas abordagens incluem o uso de projeções baseadas em modelos climáticos aos quais são aplicadas técnicas de downscaling para refinar as projeções globais em escalas locais. Por meio dessas metodologias, é possível gerar cenários de perigo que, quando



combinados com cenários de crescimento econômico, urbano e populacional, permitem uma avaliação de risco considerando a incerteza climática futura e facilitam a formulação de estratégias de adaptação e mitigação.

É importante mencionar que não há uma metodologia de consenso para estimar as inundações sob as mudanças climáticas (Wasko et al., 2021), mas, sim, um grande número de métodos relatados na literatura que variam amplamente de acordo com a escala, o objetivo da análise e o local de aplicação. A seleção do método adequado depende de fatores como a disponibilidade de dados, a resolução espacial e temporal necessária, bem como a incerteza inerente às projeções climáticas.

**Tabela 18. Fontes de evidências que podem ser usadas para informar como as mudanças climáticas podem afetar as futuras inundações**

Método	Descrição	Vantagens	Desvantagens
<b>Abordagens heurísticas baseadas em raciocínios físicos</b>	Eles estimam as mudanças na precipitação usando princípios físicos, como um aumento médio global de 2% °C <sup>-1</sup> para a precipitação média e 6-7% °C <sup>-1</sup> para eventos extremos devido à maior capacidade da atmosfera de reter umidade.	Simple de aplicar; baseado em princípios físicos compreensíveis.	Não capturam a complexidade das mudanças futuras; podem ser muito gerais para casos específicos.
<b>Projeção de tendências históricas</b>	Extrapolam as tendências observadas nos dados históricos, presumindo que as relações causais observadas, como a não estacionariedade das chuvas,	Baseiam-se em dados observados e podem refletir mudanças já em andamento.	Presumem que as relações observadas permanecem constantes; podem haver uma confusão com outros fatores, como a urbanização.
<b>Projeções baseadas em modelos climáticos</b>	Usam modelos climáticos para simular mudanças futuras em larga escala, que são então dimensionadas localmente usando métodos estatísticos ou dinâmicos para estimar o crescimento do projeto.	Representam processos físicos complexos em escala global e permitem análises detalhadas com vários cenários.	Não capturam os principais processos em escala local; podem introduzir vieses; exigem dimensionamento e recursos computacionais

Fonte: Wasko et al. (2021).

Embora a CLIMADA possa processar uma camada de ameaça gerada por qualquer método que considere a mudança climática, seu desenvolvimento está alinhado com a metodologia Economia da Adaptação Climática (Souvignet et al. 2016), o que a torna especialmente projetada para avaliar o impacto econômico da mudança climática e as possíveis estratégias de adaptação. Nas seções a seguir, essa metodologia será apresentada juntamente com os recursos específicos da CLIMADA para a avaliação de riscos climáticos.



## 5.3. ABORDAGEM DE MUDANÇA CLIMÁTICA DA CLIMADA



Imagem: Adobe Stock

CLIMADA é a ferramenta usada para a metodologia de Economia da Adaptação Climática (ECA) desenvolvida pela Universidade das Nações Unidas UNU-EHS e pelo Banco Estatal de Desenvolvimento da República Federal da Alemanha KfW.

A ECA é uma abordagem projetada para identificar, de forma flexível e sistemática, as medidas de adaptação às mudanças climáticas (CCA) mais econômicas em diferentes setores e projetos. Seu principal objetivo é responder a três perguntas fundamentais: quais são os possíveis danos relacionados ao clima nas próximas décadas? Que parte desses danos pode ser evitada e por meio de quais medidas de adaptação? E quais investimentos são necessários para implementar essas medidas, garantindo que os benefícios superem os custos? Essa abordagem permite que os riscos climáticos sejam avaliados de forma estruturada, promovendo a transparência e facilitando discussões intersetoriais entre diferentes partes interessadas. Além disso, ele pode ser aplicado em diferentes níveis, do nacional ao local, e em diferentes setores e tipos de riscos climáticos (Souvignet et al. 2016).

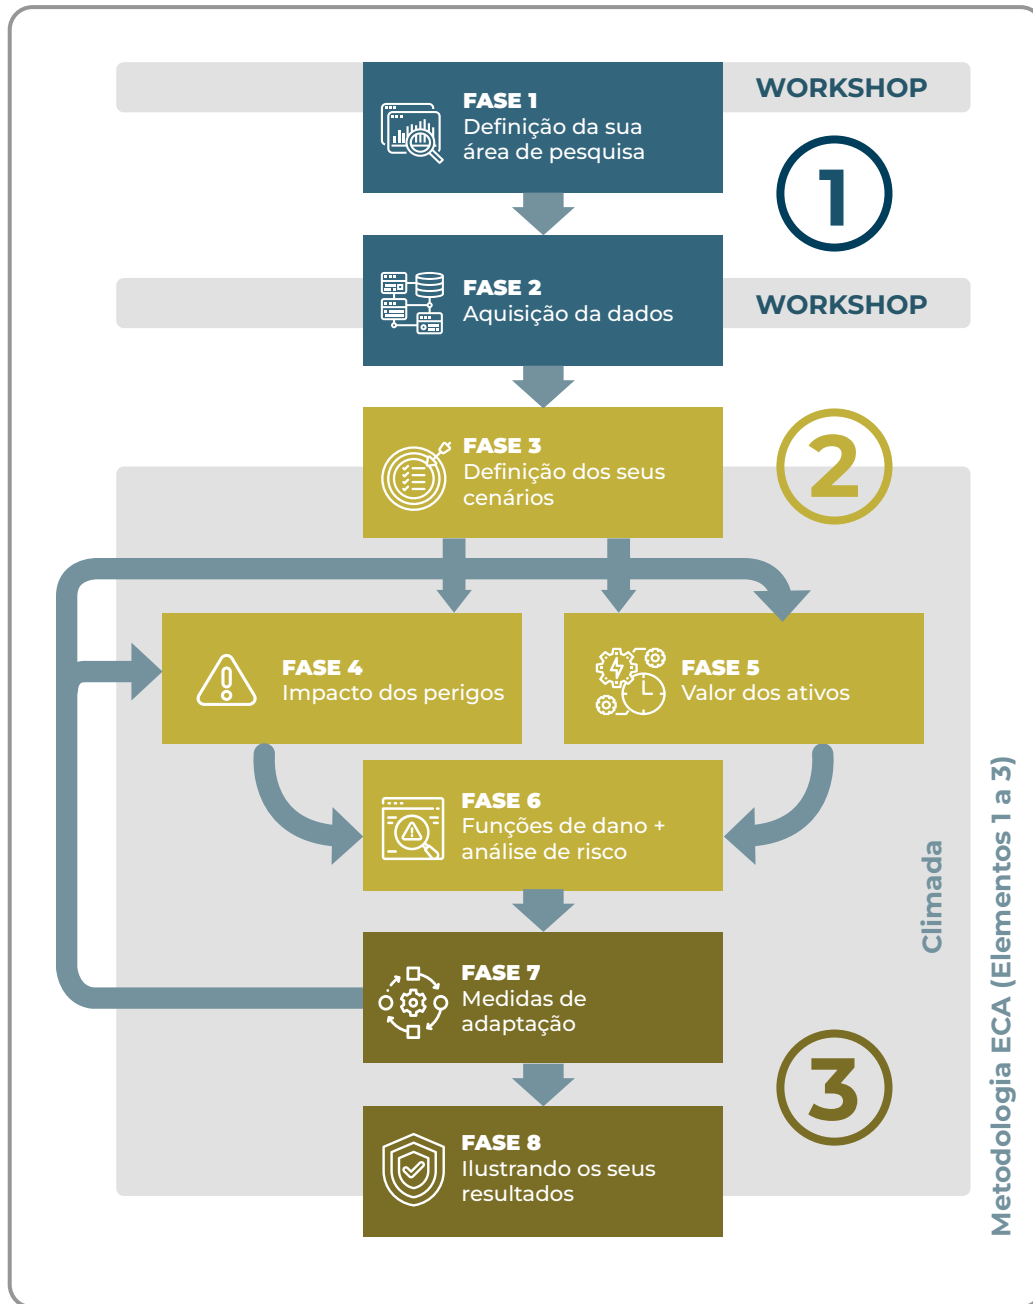


A ECA fornece uma estrutura prática para que os tomadores de decisão nacionais e locais avaliem de forma abrangente os riscos climáticos enfrentados por suas economias, minimizando os custos de adaptação usando estratégias eficientes. Com base em uma abordagem robusta e científica, a metodologia é composta por três elementos principais, conforme mostrado na **Figura 14**: (1) identificação do risco climático, analisando os perigos, as populações e os setores vulneráveis em uma determinada região; (2) quantificação do risco climático, avaliando os danos esperados em diferentes cenários climáticos e econômicos; e (3) identificação e priorização de medidas de adaptação, usando a análise de custo-benefício para definir as estratégias ideais. Além disso, a ECA é dividida em 8 fases, conforme mostrado na **Figura 15**. As duas primeiras fases estabelecem a área de estudo e gerenciam a aquisição dos principais dados. Posteriormente, são definidos cenários climáticos e socioeconômicos atuais e futuros (Fase 3), os perigos identificados são modelados (Fase 4), os ativos expostos são avaliados (Fase 5) e as funções de danos são geradas para a análise de risco (Fase 6). Nas fases finais, as medidas de adaptação são simuladas (Fase 7) e os resultados são apresentados para a tomada de decisões (Fase 8). Durante todo o processo, a CLIMADA é usada como a principal ferramenta, especialmente nas fases 3 a 8 (Souvignet et al. 2016).

**Figura 14. Elementos da metodologia ECA**



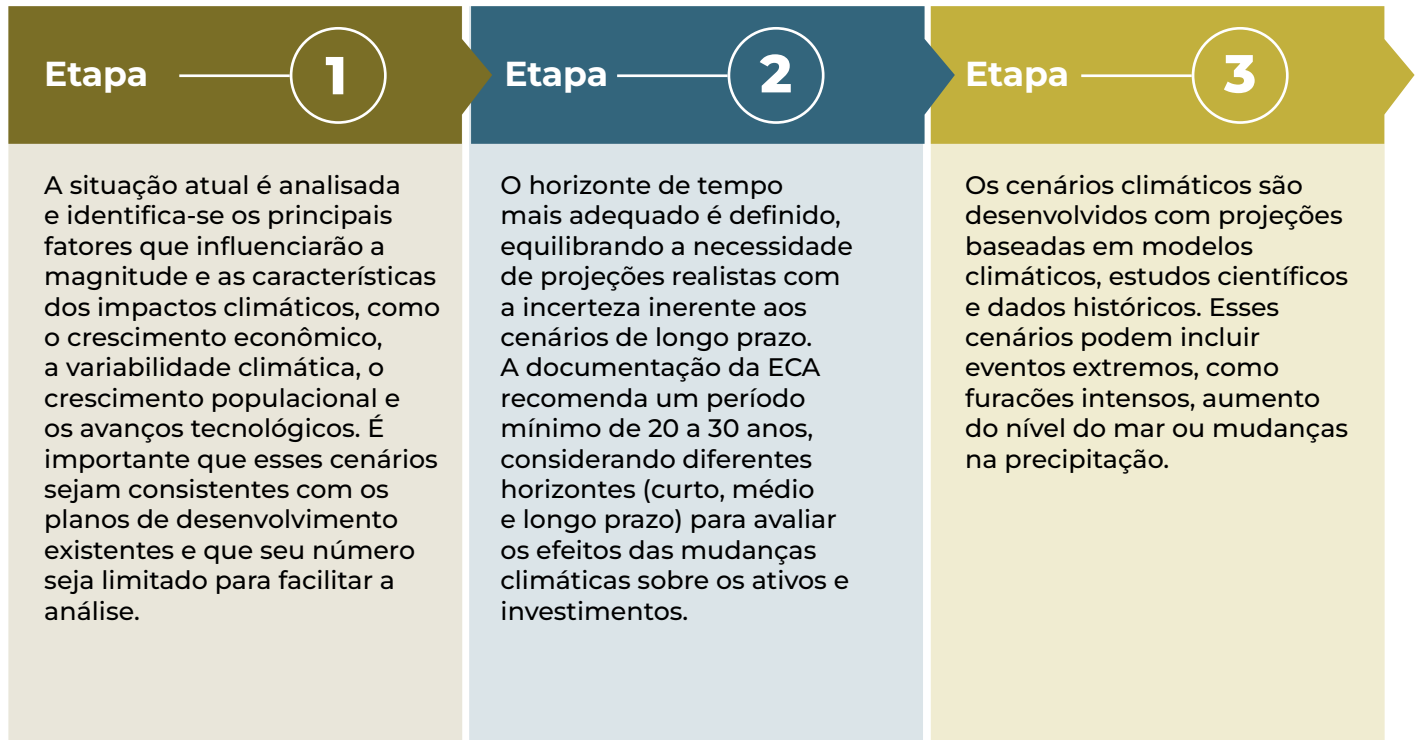
Fonte: Souvignet et al. (2016).


**Figura 15. Fases da metodologia ECA**


Fonte: Souvignet et al. (2016).

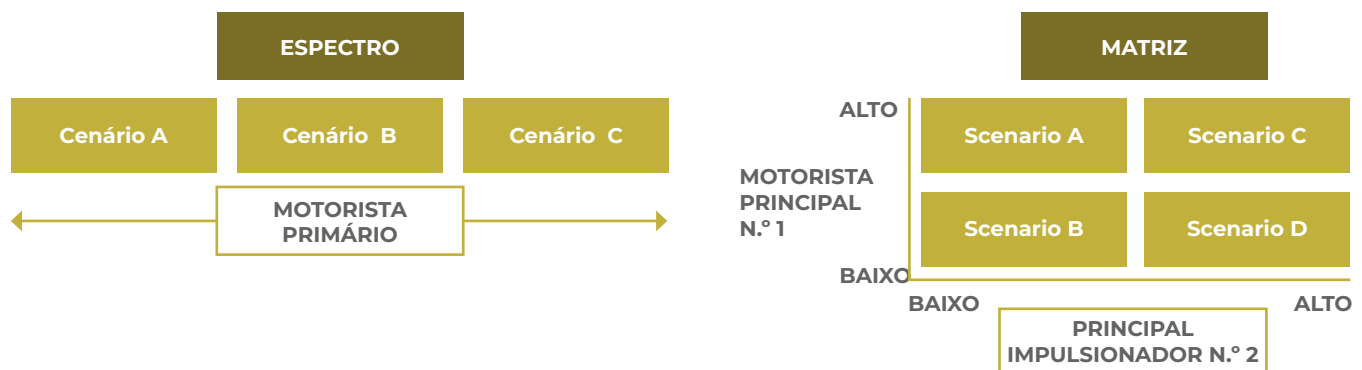


A Fase 3, que envolve a criação de cenários, começa com a descrição consistente de possíveis futuros, avaliando o impacto da variabilidade e das mudanças climáticas sobre a população e os ativos em risco. Para isso, são seguidas três etapas principais (Souvignet et al. 2016):



Por fim, os cenários climáticos e socioeconômicos são combinados em uma matriz agregada (consulte **Figura 16**) que facilita a comunicação com as partes interessadas e permite sua integração na CLIMADA para a avaliação das medidas de adaptação.

**Figura 16. Tipos de agregação de cenários**



Fonte: Souvignet et al. (2016).



## 5.4. MÉTODOS INCORPORADOS NA CLIMADA PARA MUDANÇAS CLIMÁTICAS




Imagem: Adobe Stock

A CLIMADA permite estimar o dano econômico esperado como uma medida do risco atual, bem como o aumento derivado do crescimento econômico e o aumento associado à mudança climática. A metodologia de economia da adaptação ao clima, implementada na CLIMADA, fornece aos tomadores de decisão uma base objetiva para entender o impacto dos eventos climáticos e meteorológicos em suas economias, incluindo uma análise de custo-benefício de medidas específicas para a redução de riscos (ETH Zurich 2025).

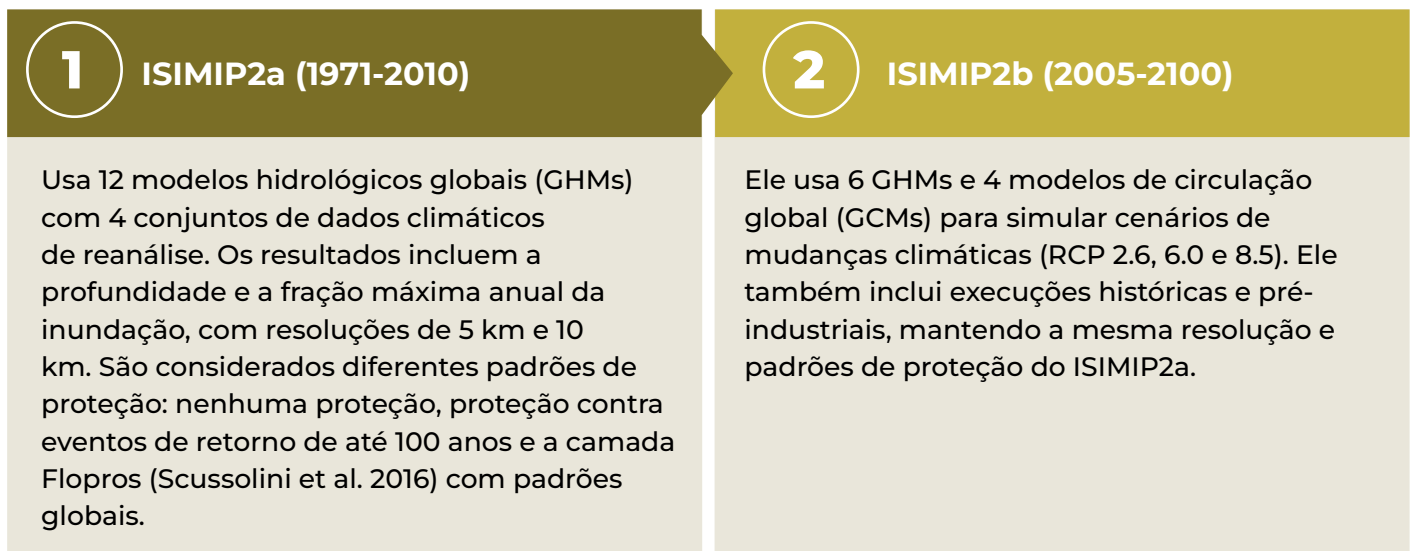
A CLIMADA incorpora a mudança climática à análise de **ciclones tropicais** por meio da função *apply\_climate\_scenario\_knu*, que implementa mudanças na intensidade e na frequência desses eventos com base nos cenários climáticos projetados no estudo de Knutson et al. (2015). Este estudo utiliza um *downscaling* dinâmico dos cenários CMIP5/RCP4.5 para estimar como a atividade de ciclones tropicais poderia evoluir até o final do século XXI. Para representar outros cenários de concentração de gases de efeito estufa (RCP), a CLIMADA interpola os valores do RCP4.5 de acordo com sua força radiativa relativa, permitindo uma aproximação simplificada dos efeitos da mudança climática nos ciclones tropicais (ETH Zurich z2017b).



É importante observar que esse método de implementação da mudança climática se concentra exclusivamente nas mudanças na frequência e na intensidade dos ciclones tropicais e não capta todos os fatores que influenciam os danos causados por esses eventos. Estimar as perdas econômicas associadas a furacões continua sendo um desafio devido à alta variabilidade nos registros históricos, pois os eventos mais destrutivos tendem a ser raros e dependem de condições específicas de impacto na terra (ETH Zurich 2017b).

O módulo RiverFlood() da CLIMADA permite a geração de dados de inundação de rios a partir de simulações do projeto ISIMIP (Inter-Sectoral Impact Model Intercomparison Project) (Sven Willner et al. 2024). Usando o método from\_nc(), são extraídos dados sobre a profundidade da água (em metros) e a fração da área inundada em cada ponto central. Esses dados são provenientes de modelos hidrológicos globais que utilizam diferentes forçantes climáticas.

Os dados de entrada necessários para o módulo RiverFlood incluem informações espacialmente explícitas sobre a profundidade da inundação e a fração inundada, disponíveis no ISIMIP. É feita uma distinção entre duas rodadas de simulação:



O método from\_nc() permite a definição de centroides para diferentes níveis espaciais (países, regiões ou global).

Um exemplo da aplicação dos métodos implementados na CLIMADA para considerar a mudança climática na análise de risco pode ser visto no cálculo de risco composto apresentado por Stalhandske et al. (2024). Neste estudo, são analisados 5000 anos de impactos de vários riscos com efeitos espaciais e espaço-temporais compostos sobre os ativos físicos e a população exposta aos riscos de ciclones tropicais (TC) e inundações fluviais (RF) do projeto ISIMIP. A ameaça de ciclone tropical na CLIMADA baseia-se em conjuntos de trajetórias de TC, que são combinadas com um modelo de vento paramétrico para simular



um campo de vento bidimensional. Neste trabalho, usamos as trajetórias de TC do arquivo ISIMIP, geradas por um modelo de ciclone tropical estatístico-dinâmico, ajustado a quatro modelos climáticos globais (HadGEM2-ES, MIROC5, IPSL-CM5A-LR e GFDL-ESM2M) do arquivo CMIP5, sob os cenários de aquecimento RCP2.6 e RCP6.0. Para as inundações fluviais, mapas globais espacialmente explícitos de áreas inundadas e profundidade de inundação em uma resolução de 150" são derivados da implementação da CLIMADA, usando dados derivados das simulações ISIMIP2. O conjunto de dados aplicado inclui simulações harmonizadas de seis modelos hidrológicos globais (GHMs) que participam do ISIMIP2b para os cenários RCP2.6, RCP6.0 e RCP8.5, embora neste estudo apenas o RCP2.6 e o RCP6.0 sejam considerados para fins de consistência com a modelagem de ciclones tropicais.

Uma das mais recentes adições à CLIMADA é uma API (Interface de Programação de Aplicativos) que permite o acesso a dados de exposição e perigo em uma grade uniforme de 4 km, facilitando avaliações de risco consistentes. Atualmente, a API inclui conjuntos de dados de ameaças globais para ciclones tropicais, secas, ondas de calor, incêndios florestais, inundações de rios e rendimentos agrícolas. Além disso, ele fornece dados específicos da região, como tempestades de inverno na Europa (Stalhandske et al. 2022). Entre os dados disponíveis por meio da API estão os mostrados na **Tabela 19**, que correspondem a conjuntos de dados de risco para os quais há um atributo relacionado a cenários de mudanças climáticas.

**Tabela 19. Conjuntos de dados de risco disponíveis por meio da API CLIMADA com atributos de mudança climática**

Nome	Descrição
<b>aqueduct_coastal_flood</b>	Mapas globais probabilísticos de inundação costeira para climas históricos e futuros (resolução de ~1 km). Disponível para períodos de retorno de 2 a 1.000 anos em 2030, 2050 e 2080 nos cenários RCP 4.5 e 8.5, considerando três projeções de aumento do nível do mar e incluindo ou excluindo a subsidência.
<b>relative_cropyield</b>	Simulações globais de produção agrícola em termos relativos (resolução de 4 km), incluindo milho, arroz, soja e trigo. Com base em modelos de culturas e modelos climáticos com correção de viés fornecidos pelo ISIMIP.
<b>river_flood</b>	Pegadas globais de inundação fluvial (profundidade da água e fração da área inundada) com uma resolução de 150 segundos (~4 km no equador). Com base na saída do CaMa Flood e em modelos de circulação global. Disponível por país e cenários climáticos futuros do IPCC.
<b>storm_europe</b>	Pegadas de tempestades de inverno na Europa (rajadas de vento em m/s). Dados disponíveis nos projetos Copernicus WISC (1940-2014) e modelos CMIP6 (1980-2010 e 2070-2100). Cobertura somente para países europeus.
<b>tropical_cyclone</b>	Pegadas de vento de ciclones tropicais (m/s) com uma resolução de 150 segundos (~4 km no equador). Dados disponíveis globalmente e por país, com base em registros históricos e eventos probabilísticos gerados por modelos.
<b>wildfire</b>	Conjunto de dados globais de incêndios florestais com resolução de 4 km, com base em dados de satélite MODIS (2000-2021).

Fonte: ETH Zurich (2025a).



## 5.5. PONTOS-CHAVE PARA A ANÁLISE DE RISCO NO CONTEXTO DAS MUDANÇAS CLIMÁTICAS



Imagem: Adobe Stock

Em resumo, a integração das mudanças climáticas nos cálculos de risco requer a consideração de vários elementos metodológicos que afetam diretamente a qualidade e a utilidade dos resultados. A seguir, apresentamos um resumo de algumas questões importantes a serem consideradas ao desenvolver esse tipo de análise, especialmente em contextos de planejamento e tomada de decisões para adaptação.



## Pontos-chave para a análise de risco no contexto das mudanças climáticas



### Trabalhar com vários cenários climáticos

É fundamental evitar o uso de um único cenário. A análise com um conjunto de trajetórias futuras permite captar melhor a incerteza inerente às projeções climáticas.



### Considerar a escala da análise

A escala espacial e temporal do estudo deve ser compatível com o objetivo da análise. As decisões sobre a resolução afetam diretamente a interpretação dos resultados e a aplicabilidade das medidas de adaptação.



### Escolher cuidadosamente o método de downscaling

Há várias abordagens (estatísticas, dinâmicas, híbridas) para trazer as projeções globais para escalas locais. A seleção deve se basear na disponibilidade de dados, na região do estudo e nos recursos técnicos.



### Implementar a análise de sensibilidade nos modelos de risco

É aconselhável avaliar como as mudanças nas principais variáveis climáticas (como precipitação ou temperatura) afetam o perigo e, conseqüentemente, o risco. Isso reforça a robustez da análise e ajuda a priorizar as intervenções.



### Aproveite as plataformas que integram projeções climáticas com dados de exposição e vulnerabilidade

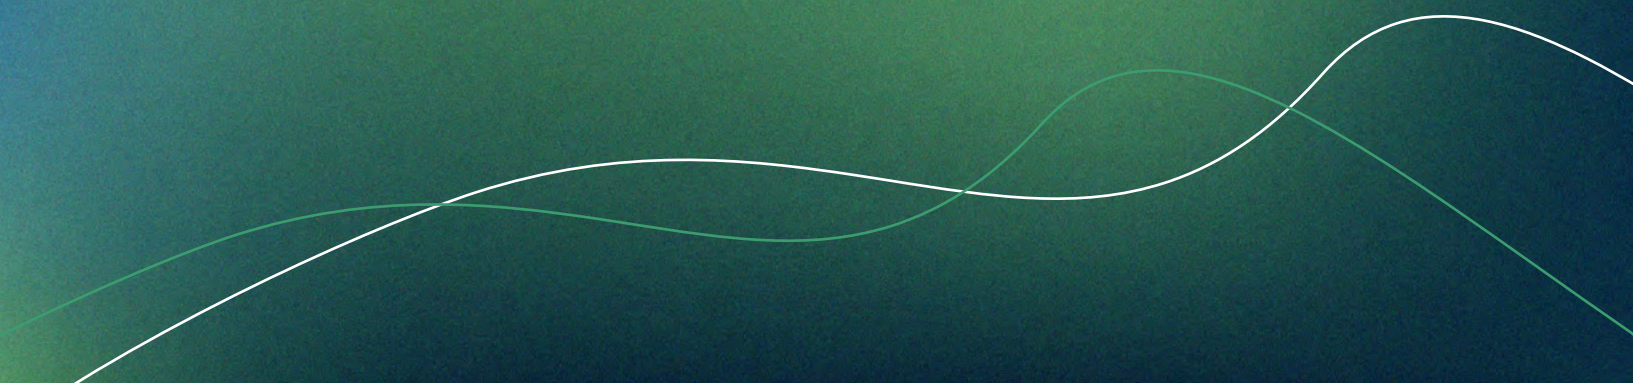
Ferramentas como a CLIMADA permitem uma avaliação integrada dos possíveis impactos das mudanças climáticas e das estratégias de adaptação, facilitando a tomada de decisões com base em evidências.



SEÇÃO

# 6

**PRODUTOS  
GLOBAIS DE  
PRECIPITAÇÃO  
DISPONÍVEIS  
GRATUITAMENTE**

The image features a dark green to blue gradient background. At the bottom, there are several thin, white, wavy lines that create a sense of movement and depth.



## 6.1. INTRODUÇÃO



Imagem: Adobe Stock

A precipitação é uma das principais variáveis para a avaliação de riscos de enchentes, movimentos de massa e secas. Compreender sua variabilidade temporal e espacial é essencial para enfrentar os desafios da modelagem das ameaças. O forçamento atmosférico nos modelos hidrológicos, que inclui a precipitação, pode vir da reanálise ou de produtos de satélite em áreas com escassez de dados de redes hidrometeorológicas. Com várias décadas de registros de alta resolução de dados de precipitação por satélite quase globais, eles se tornaram essenciais para analisar a frequência de inundações em regiões com poucas informações (Dis et al. 2018).

Este capítulo explora várias fontes de dados de precipitação, com ênfase em produtos globais disponíveis gratuitamente. Esses produtos, gerados a partir de satélites e modelos numéricos, fornecem informações valiosas para o monitoramento e a avaliação do clima, especialmente em regiões onde os dados in situ são escassos ou inexistentes. Os principais produtos de satélite e de reanálise são analisados, destacando suas características, aplicações e limitações.



## 6.2. PRODUTOS DE PRECIPITAÇÃO POR SATÉLITE



Os satélites usam a luz refletida para detectar, coletar, medir e registrar a energia eletromagnética da superfície da Terra. Os avanços no sensoriamento remoto por satélite tornaram-no uma excelente fonte de dados, pois pode fornecer informações meteorológicas para apoiar a modelagem hidrológica. Além disso, os dados de precipitação com sensoriamento remoto têm o potencial de complementar os sistemas tradicionais de pluviômetros (Masood et al. 2023). Recentemente, os instrumentos ativos de sensoriamento remoto melhoraram consideravelmente, fornecendo informações detalhadas com uma alta resolução espacial e temporal. Como resultado, o número de produtos de precipitação por satélite disponíveis e a qualidade dos dados que eles geram aumentaram (Tedla et al. 2024).

Alguns produtos de precipitação baseados em satélite superam as tecnologias de medição em terra em termos de resoluções espaciais e temporais mais altas. No entanto, ainda apresentam alguns vieses em comparação com o valor da precipitação medida com pluviômetros (Q. Zhu et al. 2021).



Os produtos de precipitação por satélite quase em tempo real demonstraram um alto potencial para o monitoramento de inundações em bacias hidrográficas onde não há uma rede extensa de pluviômetros, o que é fundamental para a implementação de um sistema de alerta precoce (Llauca et al., 2021), produzindo bons resultados na previsão de inundações com erros em uma faixa aceitável (Tedla et al. 2024).

O uso da precipitação por satélite para derivar distribuições de frequência de inundação também foi explorado, como o trabalho desenvolvido por Dis et al. (2018) em várias sub-bacias da bacia hidrográfica do rio Connecticut, concluindo que os produtos de satélite podem ser valiosos para derivar frequências de inundação em regiões com dados de medição terrestres escassos.

Com relação ao uso de produtos com alta resolução temporal, Q. Zhu et al. (2021) avaliaram e compararam estatisticamente a precisão dos produtos de precipitação em comparação com as observações de precipitação in situ em escala horária, descobrindo que os produtos de precipitação por satélite de alta temporalidade têm um grande potencial para a previsão de enchentes em áreas com dados in situ limitados. Os desenvolvimentos futuros devem se concentrar na redução das incertezas e no aprimoramento da precisão das simulações hidrológicas para prever melhor os desastres causados por enchentes.

Entretanto, os produtos de satélite têm as seguintes limitações:

- ➔ Eles podem conter erros devido a estimativas indiretas, incerteza de amostragem e algoritmos usados. As características desses erros variam consideravelmente em função dos climas, tempestades, estações e altitudes (Masood et al. 2023). Para que os produtos de precipitação por satélite sejam usados de forma confiável na modelagem hidrológica, seu desempenho precisa ser validado e aprimorado com antecedência.

---

- ➔ Vários estudos descobriram que o uso direto de dados de satélite não é recomendado e que a correção de viés é geralmente necessária (Tedla et al. 2024; Masood et al. 2023).

---

- ➔ Estudos como o desenvolvido por Sapountzis et al. (2021) analisando o uso de produtos de satélite na avaliação de inundações repentinas, constatou que não é possível usar produtos de satélite sem calibração e validação prévias. No entanto, o estudo mostrou que a combinação de dados de precipitação de satélite com dados de precipitação em terra pode ser muito útil para a análise de inundações repentinas em bacias hidrográficas não monitoradas.

---

- ➔ Os métodos de estimativa ainda estão em desenvolvimento e um progresso considerável está sendo feito o tempo todo. A estimativa de precipitação com sensoriamento remoto ainda é uma área de pesquisa relativamente nova, e muitos de seus produtos sofrem de imprecisões consideráveis (Nguyen et al. 2019). Essas desvantagens se traduzem em grandes incertezas que precisam ser compreendidas para que se possa aproveitar ao máximo o potencial dos produtos baseados em satélite.



- As latitudes norte e sul de cerca de 60° limitam a maioria dos produtos quase globais devido à crescente falta de confiabilidade das leituras de dados de satélite à medida que os satélites em órbita geoestacionária (GEO) se aproximam dos polos (Nguyen et al. 2019).

Devido a essas limitações, é fundamental validar a precisão dos produtos de precipitação por satélite e sua aplicabilidade na área em que serão usados. Esse processo de validação pode ser realizado com análises estatísticas com base em dados de pluviômetros terrestres e em uma estrutura de modelagem hidrológica adequada. A análise estatística determina a precisão e a consistência dos dados de precipitação por satélite, enquanto a simulação hidrológica esclarece sua utilidade e aplicação (Masood et al. 2023).



Por exemplo, Trinh e Molkenhain (2021) antes de aplicar uma técnica de desagregação temporal, usaram produtos de precipitação derivados de satélite para avaliar sua precisão em comparação com as medições de pluviômetros, a fim de selecionar o produto mais adequado para a área de estudo. Em seguida, eles desagregaram os dados diários do pluviômetro em escalas subdiárias, dividindo a precipitação diária medida nas estações de monitoramento pela precipitação subdiária acumulada derivada dos dados de satélite e, em seguida, multiplicando esse resultado pela precipitação subdiária por satélite. No procedimento, eles também incluíram um coeficiente de correção para ajustar a precipitação por satélite a uma escala local. Dessa forma, a precipitação por satélite em locais não monitorados pode ser corrigida usando a diferença determinada entre os locais monitorados e os resultados de satélite dos locais vizinhos.

A **Tabela 20** resume as principais características dos produtos de precipitação por satélite para potencial uso na avaliação de riscos.

**Tabela 20. Produtos de precipitação por satélite**

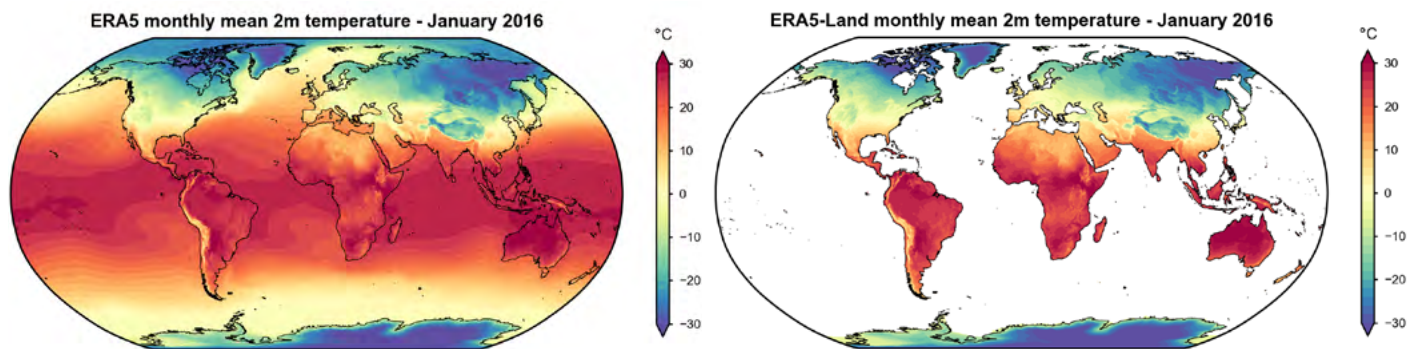
Resultado	Resolução espacial mais fina	Resolução temporária	Cobertura espacial	Cobertura temporal	Latência	Informações descritivas
<a href="#"><b>PERSIANN-CCS (CHRS)</b></a>	0.04°×0.04°	Horária	Quase global (60°S–60°N; 180°W–180°E)	Janeiro de 2003 até a presente data	1 hora	Esse produto categoriza as características da mancha de nuvem com base na altura da nuvem, na extensão da superfície e na variabilidade da textura estimada com imagens de satélite (Tedla et al. 2024).
<a href="#"><b>CMORPH (NOAA)</b></a>	0,07°×0,07° (8 km no Equador)	30 minutos	Quase global (60°S–60°N; 180°W–180°E)	Janeiro de 1998 até a presente data	18 horas	O Registro de Dados Climáticos (CDR) de Precipitação por Satélite - CMORPH consiste em estimativas de precipitação por satélite que foram corrigidas por viés e reprocessadas usando a Técnica de Morfologia do Centro de Previsão Climática (CPC) para criar uma análise de precipitação global de alta resolução.
<a href="#"><b>IMERG (NASA)</b></a>	0.1°×0.1°	30 minutos	90°S – 90°N; 180°W–180°E	Junho de 2000 até a presente data	18 horas	É o algoritmo mais avançado da NASA para estimar a precipitação superficial a partir de dados de satélite. O Sistema de Processamento de Precipitação gera IMERG em tempo real (Early e Late IMERG, com latências de 6 e 18 horas, respectivamente), que é complementado pelo IMERG de maior qualidade ou de pesquisa (Final IMERG, com uma latência de 4 meses)(Huffman et al. 2020; NASA 2020).
<a href="#"><b>Hydro-Estimator (NOAA Star)</b></a>	0.045°×0.045°	15 minutos	Global 65 S–65 N	2002 até a presente data	Tempo real (aprox. 1 hora)	Ele usa dados infravermelhos (IR) dos Satélites Meteorológicos Operacionais Geoestacionários (GOES) da NOAA para estimar as taxas de precipitação. Os produtos H-E foram usados na América Central para alertas antecipados de movimentos de massa e no Guia de Inundações Repentinhas da América Central (Scofield 1987; Scofield & Kuligowski 2003; Strauch 2009).



Resultado	Resolução espacial mais fina	Resolução temporária	Cobertura espacial	Cobertura temporal	Latência	Informações descritivas
<a href="#"><u>GSMaP (JAXA)</u></a>	0,1°	Diariamente	60N-60S	2014 até a presente data	4 horas	O GSMaP consiste em quatro tipos de produtos: dois em tempo real (GSMaP-NRT e GSMaP-Gauge NRT) e dois pós-tempo real (GSMaP-Gauge e GSMaP-MVK). Para calcular a precipitação NRT do GSMaP-Gauge com um período de latência de 4 horas, são usados os parâmetros de erro estimados para o produto pós-tempo real do GSMaP-Gauge. O GSMaP-Gauge também emprega uma combinação de dados de micro-ondas passivas (PMW) e infravermelho (IR), juntamente com uma análise unificada baseada em pluviômetros do conjunto de dados globais de precipitação diária do Climate Prediction Center (CPC) (Masood et al. 2023).
<a href="#"><u>CHIRPS (USGS e CHC)</u></a>	0,05°	Diariamente	50N-50S	1981 até a presente data	48 horas	O CHIRPS é um conjunto de dados de precipitação quase global que consiste em três tipos de dados temporais (diários, pentanais (a cada 5 dias) e mensais) com dois tipos de resolução espacial (0,05° e 0,25°). Os dados diários são considerados dados em tempo real com um período de latência de 2 dias, enquanto os dados pentanais e mensais são considerados conjuntos de dados pós-tempo real com um período de latência de 21 dias. Seu algoritmo é baseado na duração da nuvens frias (CCD) e nas observações do pluviômetro para aproximar a precipitação (Masood et al. 2023).



## 6.3. PRODUTOS DE REANÁLISE



Fonte: Comissão Europeia, Copernicus, ECMWF, Serviço de Mudanças Climáticas.  
[https://climate.copernicus.eu/sites/default/files/inline-images/era5\\_t2m\\_201601.png](https://climate.copernicus.eu/sites/default/files/inline-images/era5_t2m_201601.png)

Os produtos de reanálise são gerados com modelos numéricos orientados por observações meteorológicas registradas, criando assim uma série temporal de diversas variáveis climáticas. Esses conjuntos de dados geralmente têm cobertura global e abrangem várias décadas (consulte **Tabela 21** para obter um resumo dos produtos mais comumente usados e seus atributos). Os dados pluviométricos da reanálise têm sido amplamente utilizados na modelagem de risco de inundação em escala continental e global. Suas principais vantagens são a ampla cobertura espaço-temporal e a facilidade de acesso. Em áreas em que há um número limitado de pluviômetros que fornecem observações de alta qualidade, os produtos de reanálise geralmente são a melhor ou a única fonte de dados de precipitação para simulações de enchentes e outros riscos climáticos. No entanto, não há garantia de que eles representem com precisão eventos extremos nem que caracterizem adequadamente o risco de inundação (McClean et al. 2023).

Existem vários produtos de reanálise diferentes, e sua qualidade varia com as atualizações recorrentes. Assim como ocorre com os produtos de precipitação por satélite, é essencial avaliá-los cuidadosamente antes do uso. Portanto, a validação de campo da precipitação de reanálise é muito importante, mas também muito desafiadora, especialmente em áreas onde as redes de pluviômetros são escassas. A comparação dos dados de reanálise com a precipitação medida com pluviômetros mostrou resultados variáveis, dependendo das abordagens usadas, das regiões e das escalas de tempo, o que implica que pode ser necessária uma avaliação de rendimento específica para cada local (Wanzala et al. 2022a).



Em estudos de risco de inundação que usaram dados de reanálise, foram relatados resultados satisfatórios, resultando em um uso potencialmente positivo. Entretanto, os dados de reanálise global ou regional ainda não devem ser considerados como substitutos das observações locais de alta resolução. As incertezas na avaliação de risco de inundação usando dados de reanálise devem ser adequadamente quantificadas e comunicadas, para garantir que as decisões de gerenciamento de risco de inundação não estejam mal informadas (McClellan et al. 2023).

Embora alguns estudos tenham demonstrado um melhor desempenho de determinados produtos em comparação com outros, como o estudo de (Wanzala et al. 2022b) que constatou que o ERA5 teve um desempenho melhor no Quênia, e o ERA5 geralmente supera o desempenho de outros produtos de reanálise (Carr et al. 2024), a literatura sugere que é preferível usar vários produtos, como ERA5, CFSR e MERRA-2, para captar toda a gama de incertezas na precipitação. Isso ocorre porque cada um desses produtos demonstrou ter melhor desempenho em diferentes áreas ou sob diferentes critérios de avaliação (McClellan et al. 2023).

A partir do produto ERA5, foi gerado o conjunto de dados global de intensidade, duração e frequência (IDF) de precipitação, conhecido como Parametrized eXtreme Rain (PXR), produzido por (Courty et al. 2019). Na avaliação dessas IDF globais (Carr et al. 2024) descobriram que promete ser útil para avaliar o risco de inundação em escala urbana para eventos de baixa e alta frequência.

**Tabela 21. Produtos de reanálise**


Resultado	Resolução	Cobertura	Período	Frequência	Informação
ERA-5	~ 30 km	Global	1979–	Horária	O produto de reanálise 5 do Centro Europeu de Previsões Meteorológicas de Médio Prazo (ERA-5) substituiu e aprimora o ERA-Interim, que deixou de ser produzido em agosto de 2019. O ERA-5 oferece uma maior resolução espacial e temporal, juntamente com um sistema atualizado de modelagem e assimilação de dados, o que resultou em uma melhor representação da precipitação convectiva. Além disso, foi demonstrado que ele supera vários outros produtos de reanálise.
MERRA-2	~ 55 km	Global	1980–	Horária	A análise retrospectiva da Era Moderna para a pesquisa e aplicações 2 (MERRA-2) baseia-se em seu antecessor, o MERRA, e apresenta uma redução dos vieses em aspectos do ciclo da água, entre outras melhorias. O MERRA-2 usa produtos de precipitação observados para corrigir as previsões e fornecer estimativas melhores.
CFSR	~ 35 km	Global	1979– 2011	Horária	O Sistema de Reanálise de Previsão Climática do NCEP (CFSR) substituiu a reanálise anterior do NCEP/NCAR e usa um sistema de análise muito semelhante ao MERRA-2.
JRA-55	~ 60 km	Global	1958–	3-horas	O produto de reanálise da Agência Meteorológica do Japão, JRA-55, substituiu o JRA-25, incorporando uma maior resolução e uma melhor assimilação de dados, entre outras melhorias.

Fonte: McClellan et al. (2023).



SEÇÃO  
7

**INFORMAÇÕES  
GLOBAIS  
DISPONÍVEIS  
GRATUITAMENTE  
PARA ANÁLISE  
DE EXPOSIÇÃO E  
VULNERABILIDADE**





Nas seções a seguir, exploraremos as fontes de informações globais disponíveis gratuitamente que são essenciais para a análise de exposição e vulnerabilidade no contexto da gestão de riscos de desastres.



## 7.1. Exposição



Imagem: Adobe Stock

A seguir, destacamos alguns dos modelos globais de exposição, que são esforços internacionais para desenvolver bancos de dados e metodologias que permitam uma avaliação dos ativos expostos em nível mundial. Ele também apresenta as informações disponíveis que podem ser usadas para gerar camadas de exposição, fornecendo uma visão geral das ferramentas e dos dados acessíveis que facilitam a criação de mapas de exposição em várias escalas geográficas.



## 7.1.1. Modelos globais

Há vários esforços internacionais para desenvolver modelos de exposição global. Por exemplo, (i) De Bono e Mora (2014) desenvolveram um modelo global de exposição de livre acesso com uma resolução espacial de 5 km, que foi inicialmente apresentado no Relatório de Avaliação Global (GEG-2013) com uma atualização posterior (de Bono e Chatenoux 2015) criando o banco de dados GEG-2015; (ii) a fundação Global Earthquake Model (GEM) introduziu o Banco de Dados Global de Exposição (GED4GEM) (Gamba 2014). O banco de dados de exposição mais recente produzido pela GEM é a versão v2023.1 (Yepes-Estrada et al. 2023), que fornece uma distribuição espacial de edifícios residenciais e população em três resoluções espaciais diferentes: nacional, limites administrativos de nível 1 e nível 2 (Mistry e Lombardi 2023); e (iii) na estrutura da biblioteca de funções CLIMADA, os métodos LitPop e BlackMarble foram gerados para produzir camadas de exposição globais (Eberenz et al. 2019). Esses exemplos são descritos em detalhes a seguir.

O principal objetivo do **GEG-2013** é gerar uma avaliação global dos ativos expostos em áreas urbanas. Seu objetivo é fornecer dados de exposição específicos que possam ser usados em avaliações de risco gerais e em larga escala. Esse modelo considera apenas os danos físicos diretos aos edifícios urbanos, usando dados socioeconômicos nacionais e modelos de distribuição geográfica da população e do Produto Interno Bruto (PIB) como as principais fontes de informação. Uma das características mais importantes da abordagem top-down adotada pelo GEG-2013 é que ela garante a comparabilidade entre países e territórios em todo o mundo, facilitando uma análise consistente em escala global (De Bono e Mora, 2014).

O GEG-2013 se concentra nos ativos expostos, definidos principalmente como o estoque de edifícios (residências e edifícios comerciais ou industriais) e a população que vive ou trabalha neles. Isso usa uma abordagem baseada no capital produzido em áreas urbanas, onde o valor econômico dos ativos é avaliado sem considerar os efeitos indiretos ou secundários, que estão explicitamente fora do escopo do relatório GAR 2013. O modelo é baseado em dados do Banco Mundial e apresenta um banco de dados de exposição subnacional em uma grade global de 5 x 5 km<sup>2</sup>, adequado para a avaliação de risco probabilístico em áreas urbanas em nível nacional. Essa abordagem é implementada por meio da plataforma CAPRA (<http://www.ecapra.org>) (De Bono e Mora, 2014).

A exposição no **GEG-2013** é representada como o valor de um grupo de edifícios em cada célula de 5 x 5 km<sup>2</sup>. Para estimar as características dos edifícios em nível subnacional, são considerados quatro setores socioeconômicos, em que a distribuição dos tipos de edifícios está relacionada à população que vive em cada tipologia, e não ao número total de edifícios por tipo de edifício. O valor do capital produzido (ativos) é distribuído por setor e tipo de edifício em cada célula da grade, levando em conta a densidade de ocupação e o custo unitário por setor. Seu objetivo final é contribuir para a estimativa probabilística do risco em escala global, apresentando os resultados em termos relativos usando classes de risco. Essa abordagem permite comparar as possíveis perdas econômicas entre diferentes países e apresentar uma ordem de magnitude dos impactos esperados (De Bono e Mora 2014).



O **GEG-2015** é a versão atualizada do GEG-2013. O GEG-2015 consiste em duas grades de exposição: uma grade global de 5x5 km adequada para a avaliação de riscos em grandes áreas e uma grade global costeira de alta resolução de 1x1 km para riscos em escala menor, para a avaliação de riscos de tsunamis e tempestades. Cada registro do GEG-2015 representa uma tipologia de construção estrutural específica, associada a um nível de renda ou setor, com uma representação pontual no centroide da célula correspondente. Uma das características mais importantes do GEG-2015 é a inclusão da população rural, que não foi considerada na edição de 2013, multiplicando o número total de ativos expostos em aproximadamente 18 vezes. Além disso, foram feitas melhorias significativas, como o uso de uma máscara de área construída aprimorada e correções das limitações do modelo MODIS 500 em regiões densamente povoadas, como o Sudeste Asiático. As camadas de base também foram atualizadas, incluindo o banco de dados de distribuição da população e os dados de construção. Outra melhoria importante foi a distribuição geográfica do capital produzido, ponderada por um novo indicador que considera a variação entre os valores do PIB em nível nacional e subnacional (De Bono e Chatenoux 2015). A **Figura 17** apresenta um exemplo do banco de dados em uma área de teste que mostra o estoque de capital total.

O **Modelo de Global de Exposição desenvolvido pelo GEM** (Yepes-Estrada et al. 2023) é um mosaico de modelos locais e regionais que contém informações sobre o inventário de edifícios residenciais, comerciais e industriais na menor divisão administrativa disponível de cada país. Ele inclui detalhes como o número de edifícios, ocupantes, características de vulnerabilidade, área média construída e custo





O modelo de exposição GEM está disponível como um Mapa Global de Exposição no formato shapefile, que consiste em quatro camadas que representam o número de edifícios, a área construída, o valor total de reposição e a população total. Os mapas do número de edifícios e do valor total de reposição estão disponíveis para download direto como arquivos PNG de alta definição sob a licença CC BY-NC-SA 4.0<sup>18</sup>, que exige atribuição, uso não comercial e compartilhamento de derivados sob a mesma licença. Em casos de uso comercial ou para obter o conjunto completo de camadas como um shapefile, é necessário fazer uma solicitação específica, na qual uma licença personalizada será concedida de acordo com o caso de uso. Para fins não comerciais, a licença exige que se dê os devidos créditos, um link para a licença e a menção de quaisquer alterações feitas (GEM 2024b).

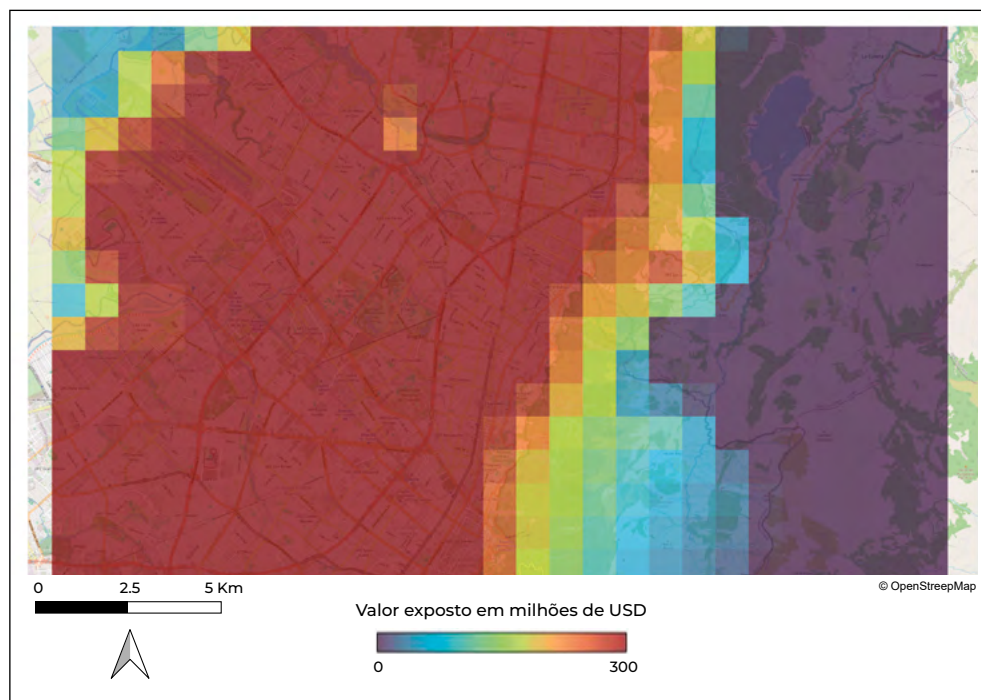

O **LitPop** é uma metodologia projetada para estimar a distribuição espacial dos valores dos ativos físicos em nível global com alta resolução. Essa abordagem usa dados da intensidade da luz noturna e populacionais como proxies para modelar a atividade econômica, atribuindo indicadores macroeconômicos, como o produto interno bruto (PIB), a células geográficas específicas. O LitPop oferece uma base homogênea e consistente para modelar os impactos econômicos diretos em diferentes regiões do mundo. A metodologia baseia-se na multiplicação da intensidade da luz noturna pela densidade populacional em cada célula geográfica, criando assim um indicador que reflete a atividade econômica naquele espaço. Esse valor é então usado para distribuir o capital produzido nacionalmente ou outros indicadores macroeconômicos, como o PIB ou o produto regional bruto (GRP), de maneira proporcional. Esse processo permite a obtenção de uma representação espacial dos valores dos ativos físicos, adaptada a diferentes níveis de resolução, dependendo da qualidade dos dados disponíveis (Eberenz et al. 2019). A **Figura 18** e **Figura 19** mostram um exemplo do LitPop com informações geradas em uma resolução de aproximadamente 930 m.




<sup>18</sup> A licença Creative Commons Attribution-Non Commercial-Share Alike 4.0 (CC BY-NC-SA 4.0) permite que outras pessoas compartilhem, copiem e adaptem o material, desde que seja dado o devido crédito ao autor original, que o material não seja usado para fins comerciais e que os trabalhos derivados sejam distribuídos sob a mesma licença (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).



**Figura 18. Valor do ativo em milhões de dólares LitPop gerados com a CLIMADA para o ano de referência de 2025**



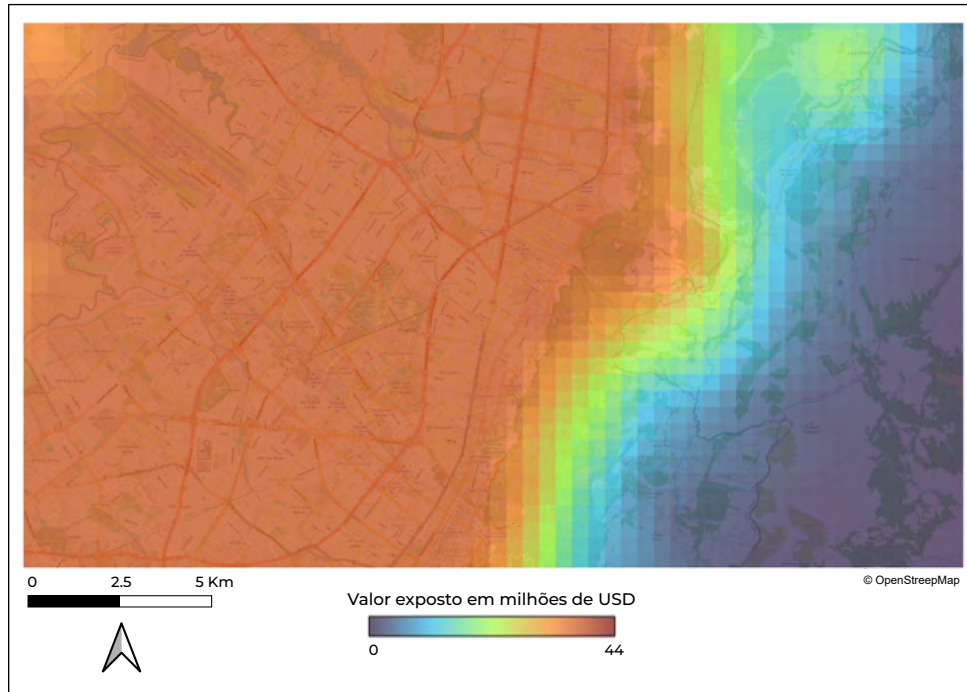
**Observação:** camada gerada para a mesma área mostrada na Figura 17. A imagem superior mostra a saída da CLIMADA com os valores atribuídos aos centroides e a imagem inferior mostra o raster exportado da CLIMADA.

**Figura 19. População LitPop gerada com a CLIMADA para o ano de referência de 2025**

**Observação:** camada gerada para a mesma área mostrada na Figura 17

Embora as informações geradas pelo LitPop sejam extremamente úteis para a análise de risco em escala grosseira, uma de suas principais limitações é a qualidade e a resolução dos dados de população e luz noturna, que variam significativamente entre os países, afetando a precisão do modelo. Além disso, sua abordagem *top-down*, embora eficaz para análises em larga escala, não considera as variações locais nos tipos de infraestrutura e vulnerabilidades, limitando sua aplicabilidade para avaliações detalhadas em nível local. Os dados de luz noturna também apresentam problemas como a saturação em áreas urbanas densas e o “blooming”, em que a luz refletida não corresponde necessariamente à atividade econômica real. Por fim, a falta de dados subnacionais detalhados dificulta a validação direta do modelo em determinados contextos, e sua dependência de indicadores nacionais, como o PIB, pode não captar totalmente as desigualdades ou particularidades regionais (Eberenz et al. 2019).

O **BlackMarble** é uma das classes de exposição geradas pela CLIMADA e é usado para aproximar a exposição econômica a nível de países e províncias. Esse modelo interpola os valores do PIB e os grupos de renda a partir da intensidade da luz noturna em um ano específico, permitindo assim uma estimativa espacialmente distribuída da exposição econômica. Para isso, o BlackMarble usa imagens de satélite da luz noturna de diferentes fontes. Entre 2012 e 2016, são usadas imagens da NASA com resolução de 15 segundos de arco (~500 m), enquanto nos anos entre 1992 e 2013 são usadas imagens da NOAA com uma resolução de 30 segundos de arco (~1 km). Por padrão, os dados da NASA são usados para os anos posteriores a 2013 e os dados da NOAA para os anos anteriores, embora haja uma opção para selecionar a fonte mais próxima. Além disso, a resolução padrão é a da imagem de entrada, mas pode ser ajustada por interpolação. Os dados do PIB e dos grupos de renda são obtidos do banco de dados do Banco Mundial por meio da API *pandas-datareader* e, quando os valores não estão disponíveis, é considerado o mais próximo no tempo ou são usados dados do repositório do *Natural Earth*. A **Figura 20** mostra um exemplo do BlackMarble com uma resolução de aproximadamente 460 metros.

**Figura 20. Valor do ativo em milhões de dólares BlackMarble gerado com a CLIMADA**

A maioria dos modelos de exposição disponíveis fornece informações suficientes para a avaliação de riscos em nível nacional e global. No entanto, eles tendem a não ter a resolução necessária para realizar avaliações de risco em escala urbana com um alto nível de confiança. O principal desafio no desenvolvimento de um modelo de exposição de alta resolução está nas informações limitadas disponíveis no nível do ativo (Mistry e Lombardi 2023). No entanto, há um progresso significativo na geração de informações detalhadas que podem ser usadas para a construção de camadas de exposição, conforme mostrado na seção 7.1.2

## 7.1.2. Informações disponíveis que podem ser usadas para gerar camadas de exposição

Para grandes áreas urbanas, os dados de exposição podem ser obtidos a partir de bancos de dados proprietários e de código aberto, como o OpenStreetMap (OSM), o Google Earth e cadastros gerados localmente. No entanto, em pequenas áreas urbanas e regiões rurais, esses dados geralmente são incompletos ou inexistentes, o que exige a coleta de informações com sensoriamento remoto e trabalho de campo. Pesquisas recentes exploraram o uso de modelos de exposição estocásticos, como o proposto por (Mistry e Lombardi 2023), que usa o método de amostragem Monte Carlo para levar em conta a



incerteza relacionada à localização dos ativos e seus atributos no modelo de exposição. Essa abordagem reconhece a complexidade e a precisão necessárias para as análises de exposição, especialmente em escalas mais detalhadas. A seguir, há uma descrição das principais fontes de dados com cobertura global que podem fornecer informações básicas para a criação de bancos de dados de elementos expostos localmente.

- ➔ **OpenStreetMap (OSM)**<sup>20,21</sup> é uma plataforma de mapeamento gratuita e colaborativa que fornece dados geospaciais de todo o mundo, criados e mantidos por uma comunidade global de voluntários. Esses dados são coletados de forma aberta, permitindo seu uso e modificação sob uma licença de conteúdo aberto. Em termos de análise de exposição, os dados do OSM fornecem informações detalhadas sobre infraestrutura, como estradas, pontes, edifícios, redes de transporte e outros ativos construídos (consulte **Figura 21**, **Figura 22** e **Figura 23**). Esses dados podem ser usados para mapear o local e as características dos bens expostos. Além disso, o OSM também fornece informações sobre elementos relevantes para a resposta e recuperação de desastres, como hospitais, quartéis de bombeiros, escolas e áreas de abrigo.



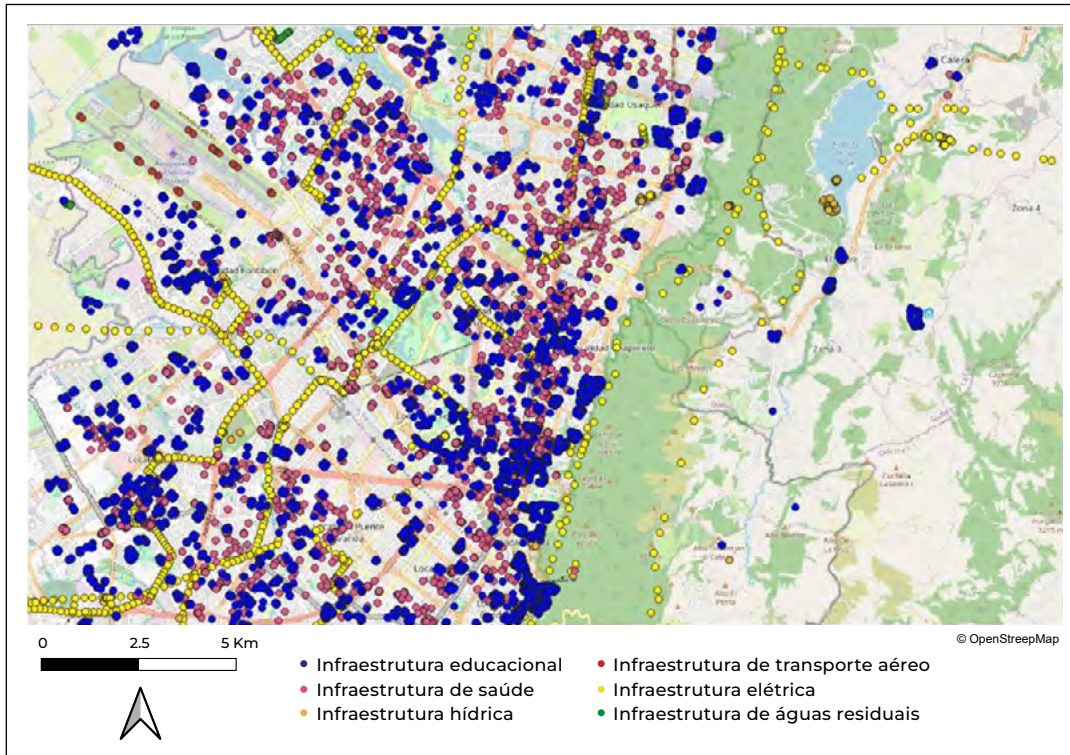
Imagem: Adobe Stock

<sup>19</sup> [https://wiki.openstreetmap.org/wiki/About\\_OpenStreetMap](https://wiki.openstreetmap.org/wiki/About_OpenStreetMap)

<sup>20</sup> <https://www.hotosm.org/what-we-do>



**Figura 21. Extração de diferentes tipos de infraestrutura disponíveis no OpenStreetMap em formato de ponto**

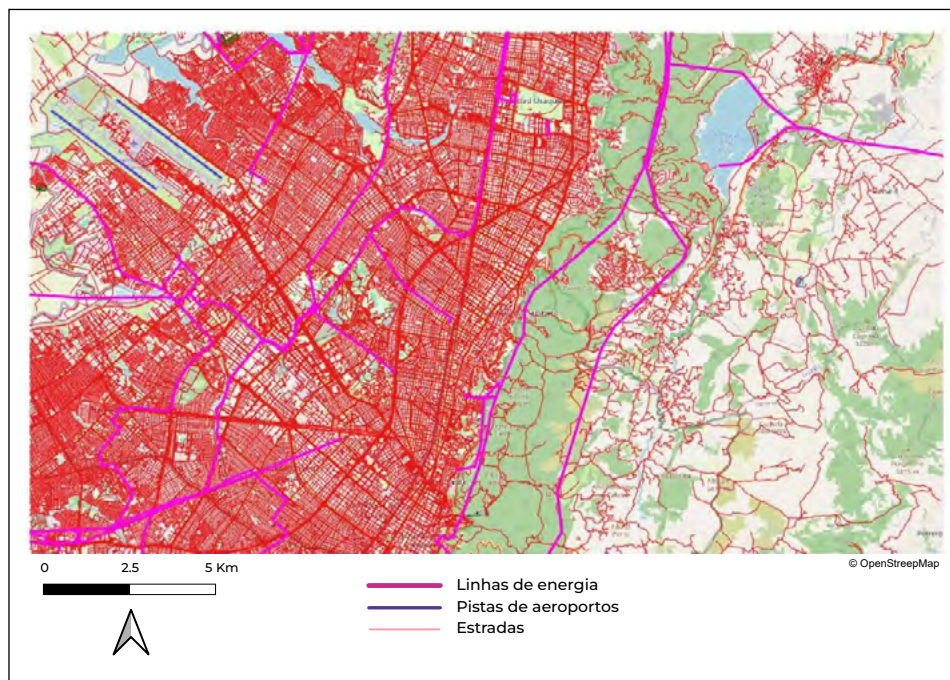


Fonte de dados da infraestrutura: OpenStreetMap contributors (2017).

A Humanitarian OpenStreetMap Team (HOT) é uma organização que usa os dados do OpenStreetMap (OSM) para apoiar a resposta a desastres e os esforços de preparação em áreas vulneráveis, especialmente em regiões onde os dados geoespaciais são escassos ou inexistentes. A HOT trabalha em parceria com comunidades locais e organizações humanitárias para coletar, aprimorar e atualizar dados geoespaciais, com o objetivo de criar mapas detalhados para facilitar a análise de exposição e o gerenciamento de riscos. O trabalho da HOT se concentra no mapeamento em tempo real durante situações de emergência, além de melhorar a cobertura do OSM em áreas de alto risco. Nesses casos, a equipe se concentra na identificação das áreas mais vulneráveis e na atualização dos dados de infraestrutura, como edifícios, estradas, pontes e outras instalações críticas que podem ser afetadas por um desastre. Além disso, a HOT organiza campanhas de mapeamento nas quais os voluntários, usando imagens de satélite e outras fontes de dados, contribuem para a criação de mapas que refletem a situação atual no local. Essas informações são essenciais para a realização de análises de exposição, pois permitem que as autoridades e organizações humanitárias planejem e implementem respostas mais eficazes, identifiquem os riscos com precisão e coordenem as intervenções com eficiência.

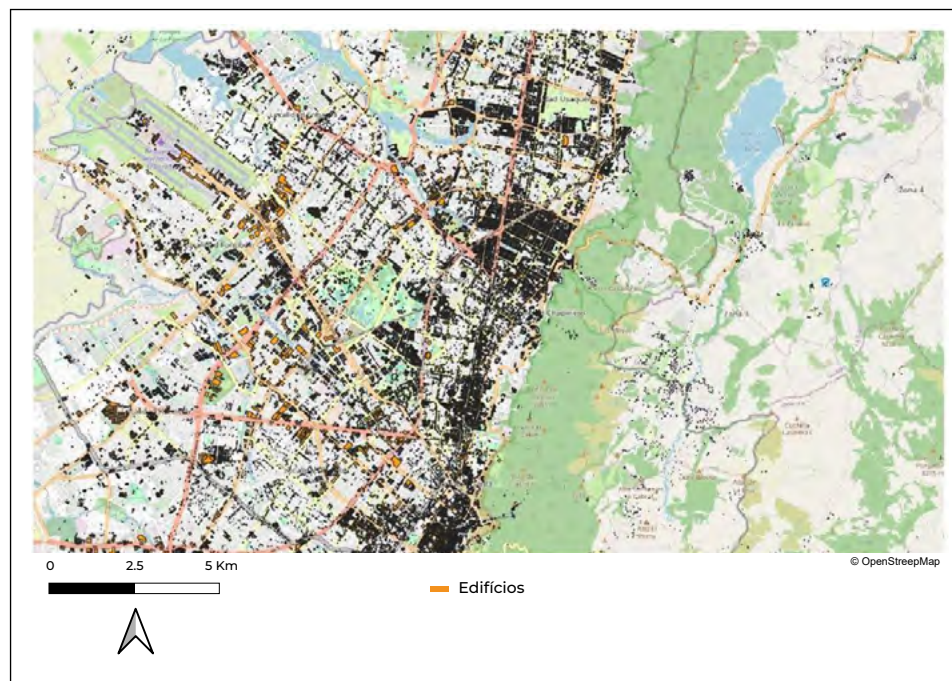


**Figura 22. Extração de diferentes tipos de infraestrutura disponíveis no OpenStreetMap em formato de linha**



Fonte de dados da infraestrutura: OpenStreetMap contributors (2017)

**Figura 23. Extração de edifícios disponíveis no OpenStreetMap em formato de polígono**



Fonte de dados de edifícios: OpenStreetMap contributors (2017).



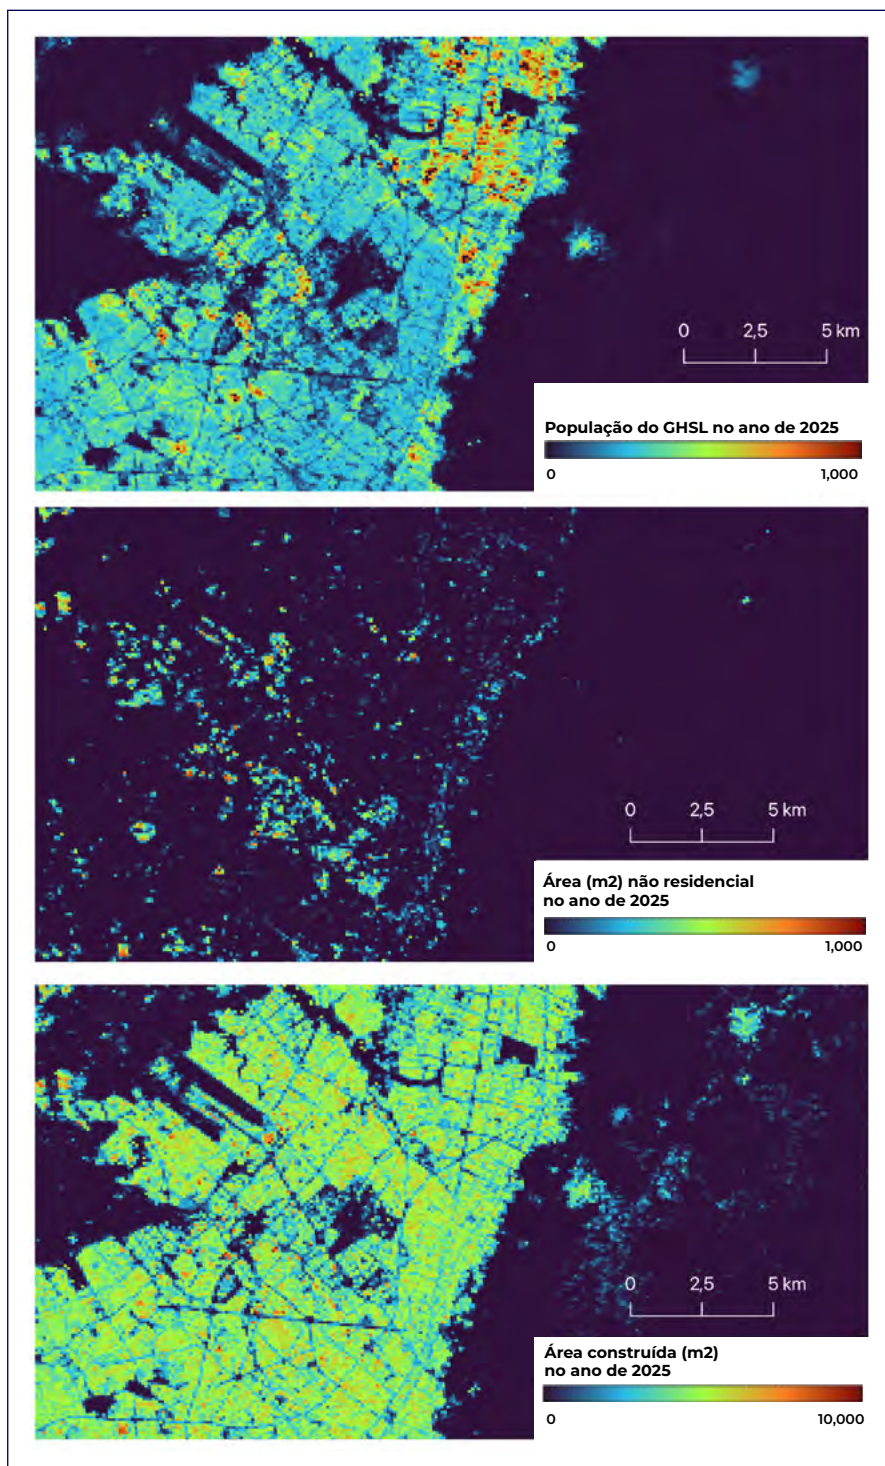
- ➔ **O Global Human Settlement Layer (GHSL)**<sup>21</sup> é um projeto desenvolvido pela Comissão Europeia que usa técnicas de sensoriamento remoto para gerar camadas de dados geoespaciais relacionadas à ocupação humana e ao desenvolvimento urbano em escala global. Esses dados são obtidos com imagens de satélite e com outras fontes de informações geoespaciais e foram projetados para fornecer uma visão detalhada das áreas urbanas e dos assentamentos humanos, tornando-os úteis para a análise de exposição no contexto do gerenciamento de riscos de desastres. Uma das principais características do GHSL é sua capacidade de identificar áreas construídas, fornecendo dados sobre a proporção da área construída em cada célula da grade, o que permite estimar a densidade e a extensão dos assentamentos urbanos. Os dados mais comumente usados na análise de risco são provenientes de camadas como a GHS\_BUILT\_S2, que tem uma resolução de 10 metros e foi derivada de imagens do satélite Sentinel-2 (2018). Esses dados permitem o mapeamento de áreas urbanas dentro de áreas afetadas por desastres, como enchentes ou terremotos, e o cálculo da exposição da infraestrutura e da população a esses eventos. Diferentemente dos dados do OpenStreetMap, que dependem de contribuições voluntárias, o GHSL usa uma metodologia baseada no processamento de imagens de satélite, o que proporciona uma cobertura mais uniforme, especialmente em áreas remotas ou de difícil acesso. No entanto, a resolução espacial, embora alta, ainda pode ter limitações para detectar estruturas menores ou áreas com alta variabilidade no desenvolvimento urbano, como áreas rurais ou semiurbanas (Copernicus 2024). A **Figura 24** mostra um exemplo das camadas de população, área não residencial e área construída para o ano de 2025. As informações disponíveis são multitemporais para o período de 1975 a 2030.
- ➔ **O WorldPop**<sup>22</sup> é uma iniciativa global que fornece dados espaciais de alta resolução sobre a distribuição da população em todo o mundo. Usando uma combinação de imagens de satélite, censo nacional e outros dados geoespaciais, o WorldPop gera mapas populacionais em nível de grade, o que é crucial para a análise de exposição no contexto do risco de desastres. Esses mapas populacionais permitem estimar a densidade e a distribuição de pessoas em áreas específicas. Em termos de análise de risco, o WorldPop fornece uma camada de dados de alta resolução com estimativas populacionais em diferentes pontos geográficos, geralmente no nível de 100 metros ou menos, o que permite uma precisão espacial significativa. Além disso, o banco de dados do WorldPop também permite projeções futuras da população, o que facilita o planejamento de longo prazo em termos de preparação para desastres. A **Figura 25** mostra um exemplo da população para um tamanho de pixel de 100 metros.

<sup>21</sup> <https://ghsl.jrc.ec.europa.eu/data.php>


<sup>22</sup> <http://worldpop.org.uk>



**Figura 24. Camadas GHSL de população, área não residencial e área construída**

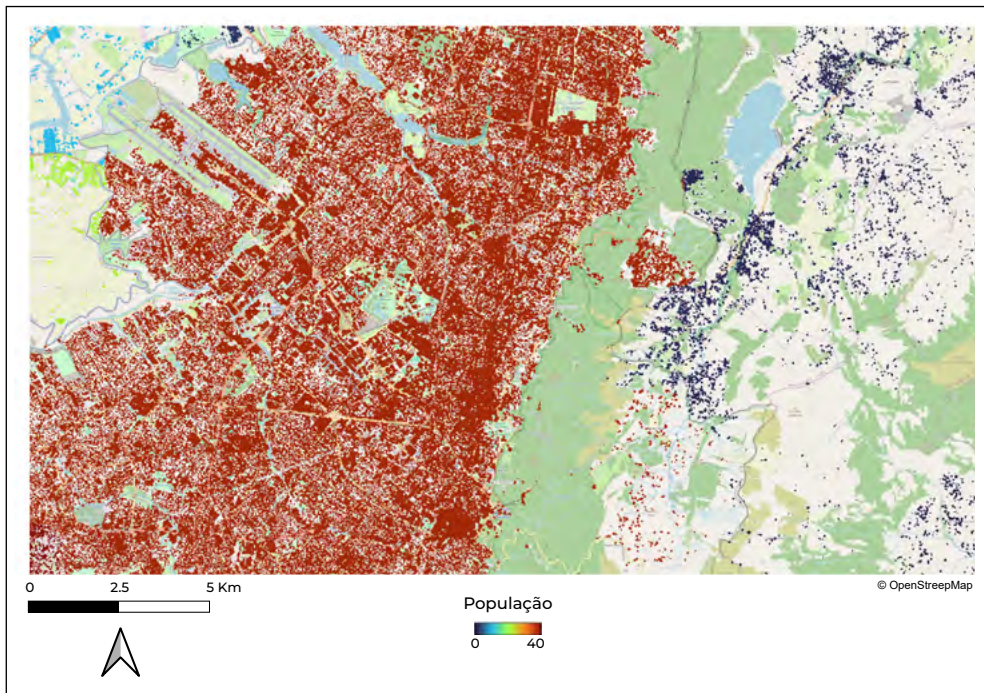


Fonte: Pesaresi e Politis (2023).

**Figura 25. População obtida do WorldPop**

Fonte: University of Southampton (2018).

- ➔ Os mapas de **densidade populacional de alta resolução desenvolvidos pela Meta** em colaboração com o Centre for International Earth Science Information Network - CIESIN representam uma ferramenta inovadora para estimar a distribuição da população. Por meio do uso de inteligência artificial e da análise de imagens de satélite, esses mapas identificam a localização dos edifícios e distribuem a população em grades de 30 metros. O processo inclui a coleta de dados do censo, a análise de imagens usando algoritmos de aprendizagem automática e a alocação da população de acordo com a densidade de construção em cada mosaico. Essa abordagem fornece informações demográficas, como o número de crianças, mulheres em idade fértil e idosos. O acesso a esses dados é público e está disponível nas plataformas Humanitarian Data Exchange (HDX) e Amazon Web Services (AWS) (META 2025). A **Figura 26** mostra um exemplo das informações sobre a população produzidas pelo META. Os pixels com valores correspondem a células de grade em que a presença de uma estrutura foi detectada. Os valores da população são distribuídos uniformemente em cada uma dessas células, representando uma estimativa da população da área do censo.

**Figura 26. População elaborada pela META**

Fonte de dados populacionais: Humanitarian Data Exchange (HDX).

➔ **Microsoft AI Microsoft Bing Maps Building Footprints** é uma iniciativa global que fornece dados abertos sobre os contornos dos edifícios em todo o mundo. Usando imagens de satélite de alta resolução de fontes como Maxar, Airbus e IGN France, mais de 1,4 bilhão de edifícios foram detectados entre 2014 e 2024. Esses dados podem ser acessados sob a licença ODbL (Open Database License)<sup>23</sup>, que permite que sejam baixados e usados gratuitamente. A atualização de dezembro de 2024 inclui aproximadamente 999 milhões de polígonos de construção no formato GeoJSON delimitado por linhas. Além disso, as coordenadas são referenciadas ao sistema EPSG: 4326, garantindo a compatibilidade com ferramentas de análise geoespacial (Microsoft 2024).

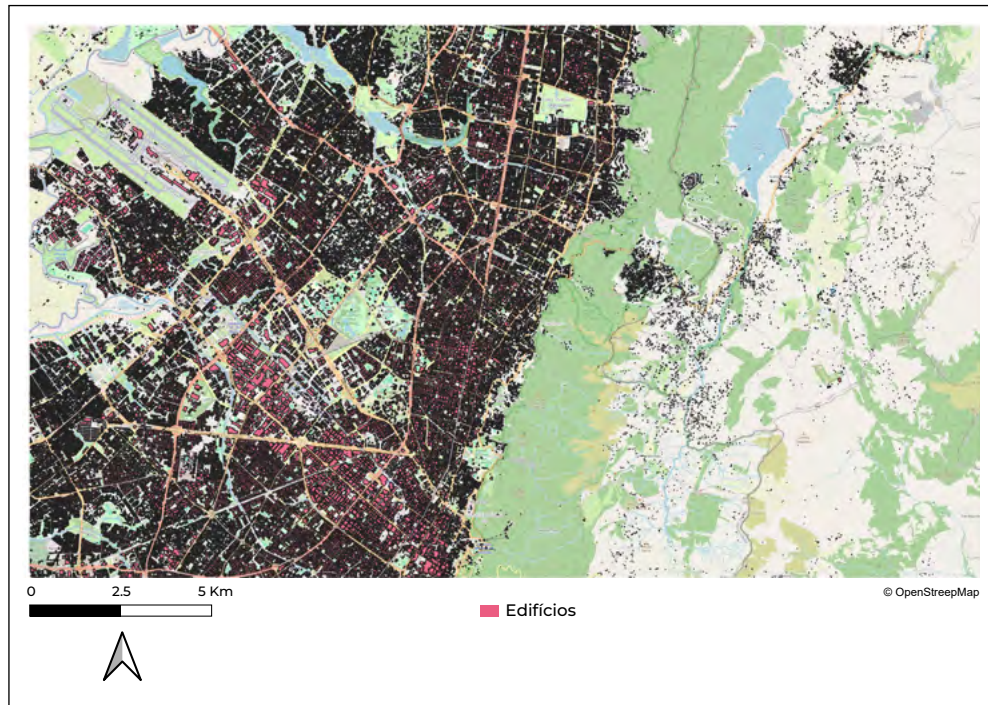
O processo de extração de dados consiste em dois estágios: segmentação semântica usando redes neurais profundas (DNNs), que identificam os pixels correspondentes a edifícios em imagens aéreas, e poligonização, em que esses pixels são convertidos em geometrias. Para melhorar a qualidade dos dados, foram implementadas pontuações de confiança que variam de 0 a 1, indicando a certeza da detecção. Os dados são avaliados usando métricas como Precisão, Recuperação e Intersecção sobre União (IoU) e, embora a qualidade seja alta na

<sup>23</sup> A licença aberta de bancos de dados (Open Database License - ODbL) é uma licença que permite aos usuários compartilhar, modificar e usar livremente um banco de dados, desde que mantenham a devida atribuição, compartilhem as modificações sob a mesma licença e mantenham as versões derivadas abertas (<https://opendatacommons.org/licenses/odbl/>).



maioria dos casos, ela varia entre áreas urbanas densas e áreas rurais. Essa iniciativa apoia o ecossistema do OpenStreetMap (OSM) e é usada em aplicativos humanitários, como a plataforma HOT Tasking Manager, onde o mapeamento em regiões vulneráveis é facilitado. Os dados podem ser acessados pelo [GitHub](#) (Microsoft 2024). A **Figura 27** mostra um exemplo dos edifícios de uma área selecionada.

**Figura 27. Extração de edifícios disponíveis no Microsoft Bing Maps**



Fonte de dados de edifícios: GlobalMLBuildingFootprints.

➔ **O Google Building Footprints** é um conjunto de dados em grande escala que fornece contornos de edifícios derivados de imagens de satélite de alta resolução. O projeto, liderado pelo escritório do Google em Gana, concentra-se no continente africano e nas regiões do Sul Global, abrangendo áreas críticas como a África, o Sul da Ásia, o Sudeste Asiático, a América Latina e o Caribe. A versão atual, v3, abrange aproximadamente 1,8 bilhão de edifícios distribuídos em uma área de inferência de 58 milhões de km<sup>2</sup>. O conjunto de dados inclui polígonos que descrevem a geometria de cada edifício, pontuações de confiança (intervalo de 0,65 a 1,0) que indicam a probabilidade de um objeto identificado ser um edifício e um Plus Code que representa o centroide do edifício. Os dados são organizados em arquivos CSV segmentados espacialmente por células S2 de nível 4. Cada registro contém informações como latitude, longitude, área em metros quadrados, geometria no formato WKT (POLYGON ou MULTIPOLYGON) e o código Plus do centroide do edifício. O modelo de aprendizagem



profunda usado na detecção passou por várias melhorias desde seu lançamento inicial, com atualizações significativas nas versões v2 e v3. Além disso, os limites de pontuação de confiança são incluídos para garantir precisões específicas de 80%, 85% e 90%, permitindo um controle mais detalhado da qualidade dos dados. Esse conjunto de dados está disponível sob duas licenças abertas: Creative Commons Attribution (CC BY-4.0) e Open Database License (ODbL) v1.0, permitindo flexibilidade em seu uso, desde que os termos estabelecidos sejam respeitados (Google Research 2024). A **Figura 28** mostra um exemplo dos edifícios de uma área selecionada.

**Figura 28. Extração de edifícios disponíveis no Google Building Footprints**



Fonte de dados de edifícios: Google Research.

➔ **Projeto ML Road Detections.** A Microsoft, por meio do Bing Maps, lançou um conjunto de dados rodoviários globais extraídos de imagens de satélite de alta resolução, com um total de 48,9 milhões de quilômetros de estradas detectadas e 1.165.000 quilômetros de estradas que não constavam no OpenStreetMap (OSM). Esse projeto usa imagens de satélite do Bing Maps, Maxar e Airbus, coletadas entre 2020 e 2022, e disponibiliza os dados sob a Licença Aberta de Bancos de Dados (ODbL), permitindo que sejam baixados e usados livremente dentro dos termos estabelecidos.



O processo de geração desses dados foi realizado em quatro etapas. Primeiro, a segmentação semântica com redes neurais convolucionais (CNN) foi aplicada para identificar os pixels correspondentes aos caminhos. Em seguida, esses resultados foram transformados em geometrias vias usando processos de geração e melhoria de conectividade. Posteriormente, os caminhos redundantes que já existiam no OSM foram excluídos e, por fim, os dados foram classificados para descartar elementos de baixa confiança e definir os tipos de estradas. O modelo usado, baseado nas arquiteturas UNet e ResNet, foi treinado com 20.000 imagens etiquetadas de várias regiões, incluindo montanhas, desertos e áreas costeiras, para garantir uma representação geográfica variada. A qualidade dos dados foi validada com métricas específicas, como uma precisão por pixel de 85,24% e uma similaridade média de comprimento de caminho (APLS) de 87,53%, garantindo a conectividade do sistema rodoviário gerado. Antes da publicação, um classificador adicional confirmou que os caminhos ausentes no OSM tinham pelo menos 95% de precisão. Esse esforço tem como objetivo fortalecer o ecossistema do OpenStreetMap, promovendo a colaboração da comunidade para melhorar a qualidade e a cobertura dos mapas rodoviários em todo o mundo. A Microsoft também incentiva as contribuições da comunidade sob contratos de licenciamento que respeitem os direitos autorais e o uso apropriado dos dados (Microsoft 2024). A **Figura 29** mostra um exemplo das estradas de uma área selecionada.

**Figura 29. Estradas do projeto ML Road Detections**



Fonte de dados das estradas: RoadDetections.



## 7.2. VULNERABILIDADE



Imagem: Flickr - Cidades Sustentáveis do BID / Nassau, Bahamas

As curvas de vulnerabilidade permitem o estabelecimento de relações entre o nível de dano ou perda e a intensidade de um evento. Há esforços para gerar informações sobre **as curvas de vulnerabilidade em nível global** com base em dados globais e metodologias de modelagem, como a de Huizinga et al. (2017), que desenvolveram uma série de curvas de vulnerabilidade para avaliar os efeitos das inundações em edifícios em todo o mundo. Sua pesquisa se concentrou na criação de um conjunto de curvas de vulnerabilidade genéricas que poderiam ser aplicadas a diferentes tipos de edifícios, desde residências até infraestruturas comerciais e industriais. As curvas de Huizinga usam parâmetros como a altura da inundação, o tipo de construção e o material das estruturas para estimar o dano esperado em função desses fatores. O trabalho de Huizinga et al. (2017) se baseia em dados globais e em uma metodologia padronizada para criar curvas de vulnerabilidade que sejam as mais representativas possíveis para uma variedade de contextos. Essas curvas foram projetadas para serem aplicadas globalmente, o que as torna úteis para análises de risco realizadas em regiões com poucas informações locais ou nacionais específicas.



Várias plataformas de modelagem de risco agora integram **curvas de vulnerabilidade** para estimar as perdas econômicas e os impactos sociais das ameaças naturais. As curvas de vulnerabilidade podem ser encontradas nas funções CLIMADA, no banco de dados de vulnerabilidade ERN-Vulnerability da CAPRA, no HAZUS e **as funções de fragilidade** podem ser encontradas no banco de dados da IN-CORE.

A Global Earthquake Model Foundation (GEM) tem um extenso banco de dados de funções de vulnerabilidade para uso na avaliação de riscos sísmicos com uma documentação detalhada. A GEM desenvolveu mais de 1.500 funções que consideram uma ampla gama de combinações de materiais de construção, alturas, sistemas de resistência lateral e níveis de projeto sísmico. A fragilidade e a vulnerabilidade são determinadas com análises não lineares no tempo, aplicadas a osciladores equivalentes de um grau único de liberdade e usando um amplo conjunto de registros de movimentos de solo que representam diferentes ambientes tectônicos. As funções resultantes são validadas com testes que incluem o cálculo das probabilidades médias anuais de colapso e a taxa média anual de perdas para diferentes locais, bem como a comparação dos resultados de simulações de eventos históricos com os danos e perdas observados (GEM 2024c).



Imagem: Flickr - Cidades Sustentáveis do BID / Santa Marta, Colômbia

# REFERÊNCIAS





- 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](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](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/FENV.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. Rösli, 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](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](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](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.google.com/portal/resources/hazus?\\_x\\_tr\\_sl=en&\\_x\\_tr\\_tl=es&\\_x\\_tr\\_hl=es&\\_x\\_tr\\_pto=tc](https://msc-fema-gov.translate.google.com/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. *EGU sphere*, 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](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](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.ENVSOF.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](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?
- McClellan, 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>.
- Pregolato, 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>.
- RiskChangas, 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](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](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](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 CLOSI THE GLOBAL LIBRARY OF SCHOOL INFRASTRUCTURE GPSS.
- Trinh, M. X., and F. Molkenhain, 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](http://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. Driscoll, 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>.



# ANEXOS





# ANEXO A. CARACTERÍSTICAS DAS FERRAMENTAS EXISTENTES PARA O CÁLCULO DE RISCO

---

## A.1. CAPRA (PROBABILISTIC RISK ASSESSMENT PLATFORM)

### A.1.1. Descrição geral

O CAPRA é uma plataforma projetada para a avaliação de riscos de desastres usando uma abordagem probabilística. Essa plataforma permite que os usuários quantifiquem e analisem o risco associado a vários perigos, facilitando a tomada de decisões informadas no gerenciamento de riscos de desastres.

A plataforma CAPRA oferece módulos específicos para o cálculo de perigo de inundação, movimentos de massa, furacões e terremotos (Universidad de Los Andes 2024a). O módulo de avaliação de riscos é chamado CAPRA-GIS e permite realizar cálculos probabilísticos de risco com base em dados de perigo, exposição e vulnerabilidade física.

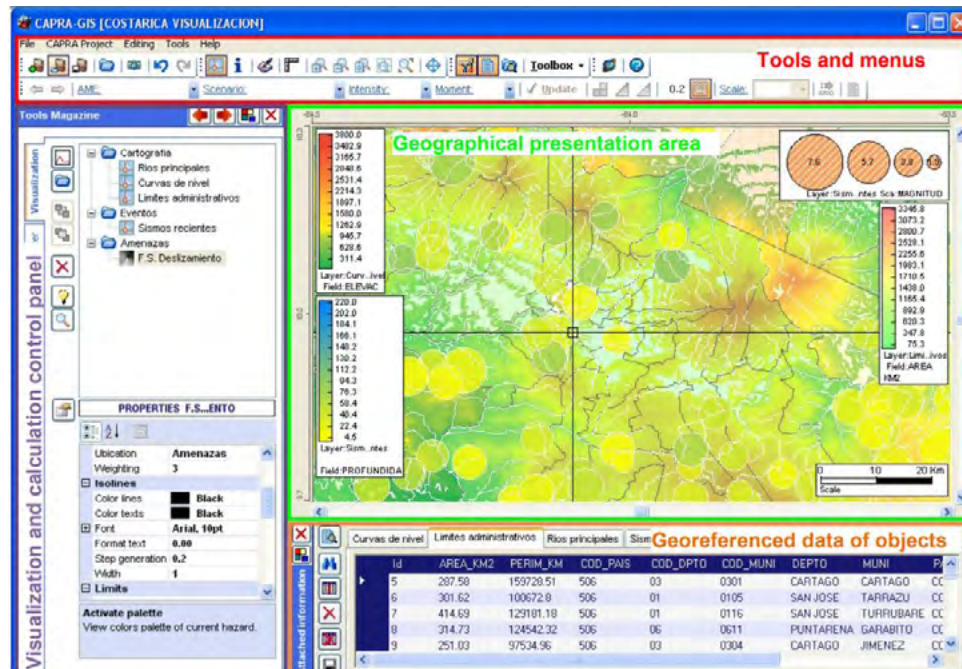
### A.1.2. Métodos aplicados

O CAPRA aplica modelos probabilísticos para avaliar a exposição e a vulnerabilidade a diferentes tipos de perigos. Ele usa uma abordagem modular que inclui avaliação de perigo, exposição, vulnerabilidade e cálculo de danos. Os métodos incluem simulações estocásticas e análise de cenários para fornecer estimativas de risco.

O CAPRA-GIS pode processar os resultados de perigos obtidos dos módulos do CAPRA ou de outras fontes, desde que os arquivos de ameaça estejam no próprio formato do software (extensão de arquivo .AME). A tela principal da ferramenta tem as seguintes áreas: menu e ferramentas; exibição geográfica; exibição de informações de dados georreferenciados; barra de status; e mensagem de processamento, conforme mostrado em **Figura 30** (Banco Mundial et al. 2009).



**Figura 30. Tela principal do CAPRA-GIS**



Fonte: Banco Mundial et al. (2009).


A ferramenta requer os seguintes tipos de informações (Banco Mundial et al. 2009):

- ➔ **Arquivos de ameaça (\*.ame):** os arquivos de ameaça podem armazenar qualquer número de combinações de configurações, intensidades e tempos, para uma determinada frequência de ocorrência.
- ➔ **ShapeFiles (\*.shp):** tratam-se de camadas vetoriais que contêm informações geográficas espaciais. Os arquivos .shp contêm os elementos expostos e seus atributos devem conter a tipologia dos elementos expostos por meio dos quais eles estão vinculados a uma determinada curva de vulnerabilidade.
- ➔ **Arquivo de vulnerabilidade ERN (\*.dat):** arquivos de texto externos com referência e parâmetros adicionais armazenados junto com o projeto, usados para configurar o cálculo das perdas.

Quando os três componentes estiverem organizados em um projeto, será possível iniciar os cálculos e obter as métricas de risco, incluindo a curva de risco e a distribuição espacial dos danos. Os cálculos podem ser executados por cenário ou de forma probabilística.



Figura 31. Janela de visualização dos cálculos de risco



Fonte: Banco Mundial et al. (2009).

### A.1.3. Abordagem matemática

A abordagem matemática usada pelo CAPRA foi desenvolvida em Cardona et al. (2012) para o caso de terremotos, mas a mesma abordagem é usada para todos os perigos. Um resumo é apresentado a seguir.

O risco é calculado usando a taxa de excedência de valores de perda,  $v(p)$ . Esse número representa o número esperado de eventos por unidade de tempo que gerarão perdas iguais ou superiores a  $p$ . Seu cálculo é baseado no teorema da probabilidade total:

#### Equação 4

$$v(p) = \sum_{i=1}^{\text{Eventos}} \Pr(P > p \mid \text{Evento } i) \cdot F_A(\text{Evento } i)$$

em que  $\Pr(P > p \mid \text{Evento } i)$  é a probabilidade de exceder a perda dada a ocorrência do evento  $i$  e  $F_A(\text{Evento } i)$  é a frequência anual de ocorrência do evento  $i$ . As funções de vulnerabilidade são usadas para estimar  $\Pr(P > p \mid \text{Evento } i)$ . Para calcular  $\Pr(P > p \mid \text{Evento } i)$ , supõe-se que, em um evento com magnitude e localização conhecidas, a intensidade no local da estrutura segue uma distribuição lognormal com uma mediana e



um desvio padrão logarítmico. Sob essa premissa, a probabilidade necessária é obtida encadeando duas distribuições condicionais (Marulanda et al. 2013):

### Equação 5

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

em que  $p_{Sa}(Sa \mid M, R)$  é a função de densidade de probabilidade da intensidade  $Sa$ , dado que um terremoto ocorre com magnitude  $M$  a uma distância  $R$ . Em geral,  $Sa \mid M, R$  é modelado por uma distribuição lognormal cuja mediana e desvio padrão logarítmico dependem de  $M$  e  $R$ , e são determinados a partir do modelo de previsão de movimento de solo selecionado pelo(a) analista. O primeiro termo da integral é obtido a partir da relação de vulnerabilidade da estrutura em análise.

As perdas econômicas são estimadas pela multiplicação do índice de danos obtido no módulo de vulnerabilidade pelo valor em risco de cada classe de ativos e localização. Posteriormente, as perdas são agregadas conforme exigido na análise.

As principais métricas de estimativa de risco incluem a Perda Anual Média (PAM), a Curva de Excedência de Perdas (CEP) e a Perda Máxima Provável (PMP). A PAM é a perda anual esperada e é definida como a expectativa matemática da perda anual:

### Equação 6

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

em que  $E(P \mid \text{Evento } i)$  é a perda esperada do evento  $i$ , e  $F_A(\text{Evento } i)$  é sua frequência anual de ocorrência. A CEP representa a frequência anual com a qual uma perda monetária específica será excedida e é a métrica mais relevante no gerenciamento de riscos catastróficos. Já a PMP indica a perda associada a uma determinada frequência de excedência ou período de retorno. A curva da PMP normalmente é definida em termos de valor econômico ou porcentagem relativa ao período de retorno e é usada para determinar o tamanho das reservas que as seguradoras devem manter para evitar perdas que excedam sua capacidade financeira.

## A.1.4. Avanços recentes no CAPRA

A versão 2.4 do CAPRA-GIS apresenta uma versão de 64 bits que melhora o gerenciamento de grandes quantidades de RAM, otimizando o desempenho em sistemas operacionais de 64 bits. Além disso, essa atualização inclui recursos de segurança melhorados, como proteção contra estouro de buffer, proteção



de execução de dados (DEP) e Patch Guard, proporcionando um ambiente mais seguro para a avaliação probabilística de riscos. Essas melhorias tornam o CAPRA-GIS mais eficiente para a análise de riscos. Infelizmente, a versão 2.4 é de 2018 e não há informações no site oficial sobre atualizações do software ou de seus manuais. No caso dos manuais, eles foram desenvolvidos em 2009 (Banco Mundial et al. 2009).

### A.1.5. Comunidade de desenvolvimento

Em julho de 2016, o Banco Mundial lançou uma chamada pública para gerenciar e administrar o site do CAPRA. A Uniandes (Universidad de Los Andes – Colômbia) foi selecionada depois que um painel avaliou a proposta levando em conta critérios como a qualidade técnica da proposta, o apoio internacional da proposta e o conhecimento e a experiência com o CAPRA, obtendo a maior pontuação de avaliação. Desde janeiro de 2017, a Uniandes gerencia e é proprietária da plataforma CAPRA (Universidad de Los Andes 2024b).

### A.1.6. Limitações

One of the main limitations of CAPRA is the lack of documentation on the methods used to perform the calculations. This lack of documentation is also reflected in the creation of the .ame input file, which makes it difficult for users to generate the information required to perform risk calculations using only the documentation. On the other hand, the software code is not available in any repository, and although the initiative initially advocated for open-source code, it is currently not possible to access the code publicly.

### A.1.7. Casos de uso

O CAPRA tem sido usado em vários países para avaliar o risco de desastres e desenvolver estratégias de mitigação. Por exemplo, na Colômbia, ele foi aplicado na avaliação de riscos sísmicos e de inundações, informando o planejamento urbano e as políticas de gerenciamento de riscos. Ele também tem sido usado em projetos de infraestrutura para garantir que os edifícios sejam resilientes, como no caso da infraestrutura de saúde, governo e educação descrita no **Quadro 2**.

## **Estudo de caso do CAPRA na Região Metropolitana de San Salvador (AMSS)**

---



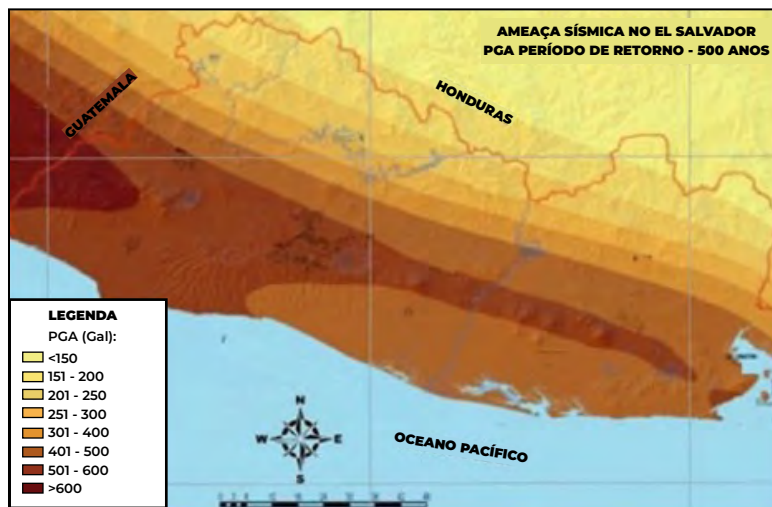
O perigo sísmico na Região Metropolitana de San Salvador (AMSS) se refere à probabilidade de ocorrência de um movimento sísmico de determinada intensidade em um local e período específicos. Esse perigo é determinado por fatores não modificáveis, como a sismicidade, que inclui a frequência e a magnitude dos terremotos, e a geologia da região. Um aspecto fundamental da análise de perigo sísmico é a compreensão da atenuação sísmica regional, que é a perda de energia que uma onda sísmica sofre ao passar pelo solo.

Para avaliar a resposta sísmica na AMSS, foram coletados e validados dados sobre a geologia da área, análises estratigráficas, registros de poços de água e parâmetros dinâmicos, bem como registros acelerográficos. Essas informações, gerenciadas pelo escritório de monitoramento do Ministério do Meio Ambiente e Recursos Naturais (MARN) de El Salvador, são essenciais para entender como o solo e outras características do local influenciam a magnitude e o tipo de movimento sísmico. Isso inclui os efeitos do tipo de solo e a coincidência entre os períodos de vibração das estruturas e do terreno.

Os mapas de perigo e risco sísmico na AMSS foram desenvolvidos com o CAPRA e incluem vários cenários sísmicos prováveis, com um total de 24.996 possíveis eventos sísmicos. Esses mapas fornecem estimativas de aceleração máxima do solo e dos movimentos estruturais associados para diferentes alturas de construções em cada cenário. Os mapas são ferramentas essenciais para identificar áreas com diferentes níveis de resposta sísmica, ajudando a prever o impacto de futuros terremotos e facilitando o planejamento e a redução de riscos.

A avaliação da vulnerabilidade na AMSS incluiu o desenvolvimento de curvas de vulnerabilidade com base em dados de danos de terremotos anteriores e registros de aceleração espectral de cada estrutura. Foi realizada uma análise específica dos edifícios pertencentes aos Ministérios da Saúde e do Governo de El Salvador, bem como uma amostra de 20% dos edifícios pertencentes ao Ministério da Educação. Essa análise considerou fatores como o ano de construção, materiais, danos anteriores e características estruturais, ajudando a identificar as edificações mais vulneráveis a futuros eventos sísmicos.

**Perigo sísmico para o período de retorno de 500 anos (esquerda) e áreas de resposta sísmica semelhante (direita)**



Em resposta aos resultados da análise de vulnerabilidade sísmica, o governo de El Salvador elaborou um programa de redução de vulnerabilidade com foco inicial no setor educacional. Esse programa busca não apenas atender às necessidades urgentes das edificações em condições críticas, mas também estabelecer uma estratégia de longo prazo para melhorar as características estruturais e funcionais das construções existentes e novas. Esse esforço complementa outras políticas de redução de riscos implementadas nos últimos anos.

Essa análise inicial usando o CAPRA fornece uma estimativa dos danos prováveis com base nas informações disponíveis, destacando a importância de avaliar a vulnerabilidade sísmica para a tomada de decisões. Embora os resultados sejam passíveis de revisão, a análise é fundamental para identificar os níveis de risco existentes e desenvolver estratégias para reduzir esses riscos a níveis aceitáveis. Em áreas urbanas como a AMSS, onde os terremotos são frequentes, a infraestrutura existente e o conhecimento dos perigos potenciais são determinantes para o planejamento da mitigação de riscos.

Fonte: CEPREDENAC et al. (2015).



## A.2. HAZUS

### A.2.1. Descrição geral

O Hazus fornece uma metodologia padronizada nacionalmente, desenvolvida pela Agência Federal de Gerenciamento de Emergências (FEMA) dos Estados Unidos. Ele é distribuído como um software de desktop gratuito baseado em SIG, com um conjunto de bancos de dados de inventário para cada estado e território dos EU A. O Hazus é usado para avaliar perigo, vulnerabilidade e risco e estimar os impactos físicos, econômicos e sociais de terremotos, furacões, inundações e tsunamis (FEMA 2023).

O Hazus é um software projetado para ser executado no ArcGIS. Os requisitos mínimos para o software de suporte são: Esri ArcGIS 10.8.2, Microsoft Windows 10 ou 11 de 64 bits (Pro e Enterprise), extensão Spatial Analyst da Esri necessária para avaliação de inundações e tsunamis e Windows NETFramework 4.8 (FEMA 2024b).

O programa Hazus fornece dados, ferramentas analíticas autônomas e software que é executado na plataforma ArcGIS Desktop da Esri. As ferramentas independentes incluem o Sistema Integrado de Gestão de Dados (CDMS) e vários módulos de código aberto que simplificam a análise de riscos, a exportação de dados e a geração de relatórios. Os dados do Hazus incluem inventários de referência de edificações, instalações essenciais e infraestrutura nos Estados Unidos (FEMA 2022c).

O Hazus tem outras ferramentas complementares, como:

- ➔ **Ferramenta de Importação de Perigo por Inundação (Flood Hazard Import Tool – FHIT):** trata-se de uma ferramenta de código aberto que permite aos usuários do Hazus pesquisar, baixar e preparar dados de perigo por inundação disponíveis publicamente para importação em uma região de estudo de inundação do Hazus. Atualmente, é compatível com os modelos de profundidade de tempestade do ADCIRC (ADvanced CIRCulation Model) (FEMA 2022d).
- ➔ **Ferramenta de Exportação do Hazus:** uma ferramenta de código aberto que facilita a extração e a análise dos resultados da avaliação de riscos do Hazus, sem a necessidade de experiência prévia em mapeamento ou codificação. A Ferramenta de Exportação permite que várias regiões de estudo do Hazus sejam processadas com eficiência e rapidez (FEMA 2022d).

### A.2.2. Métodos aplicados

O Hazus emprega modelos de estimativa de perdas que usam ferramentas geográficas para calcular danos físicos e perdas econômicas e sociais.

O Modelo de Inundação compartilha uma arquitetura de software modular geral comum aos modelos sísmico e eólico. As telas da interface do usuário variam até certo ponto para cada tipo de perigo, mas



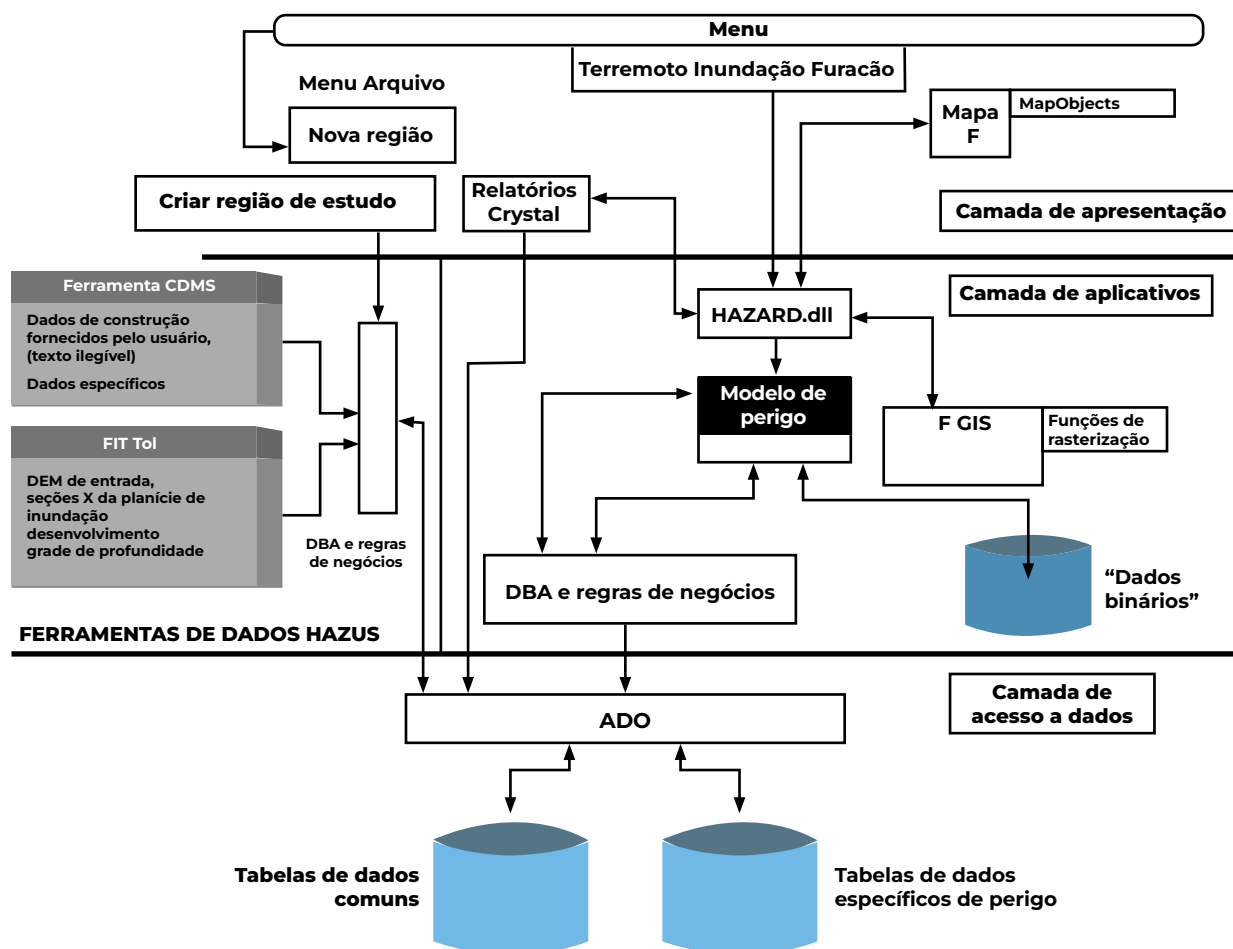
têm uma aparência comum. A **Figura 32** apresenta uma visão geral da arquitetura do Hazus e de seus diversos componentes de perigo.

Os modelos de perigo específicos do Hazus são descritos abaixo (FEMA 2023):



**Terremotos:** estima danos a estruturas, conteúdo, inventários e perdas econômicas. Avalia a probabilidade de danos a construções e infraestrutura com base nos dados do USGS ShakeMap. O modelo calcula os danos e as perdas em edificações, instalações essenciais, sistemas de transporte, redes de serviços públicos e população, com base em terremotos em tempo real, cenários ou análises probabilísticas. Além disso, contempla os cálculos necessários para o manejo de escombros, o monitoramento de incêndios, o número de vítimas e a gestão de abrigos. As perdas diretas são estimadas com base em danos físicos a estruturas, conteúdo, inventário e interiores de edifícios. O modelo de terremoto inclui o Módulo de Construção de Engenharia Avançada, usado para a análise de edificações individuais e em grupo (FEMA 2024c).

**Figura 32. Arquitetura de software do Hazus com ferramentas de dados do Hazus**



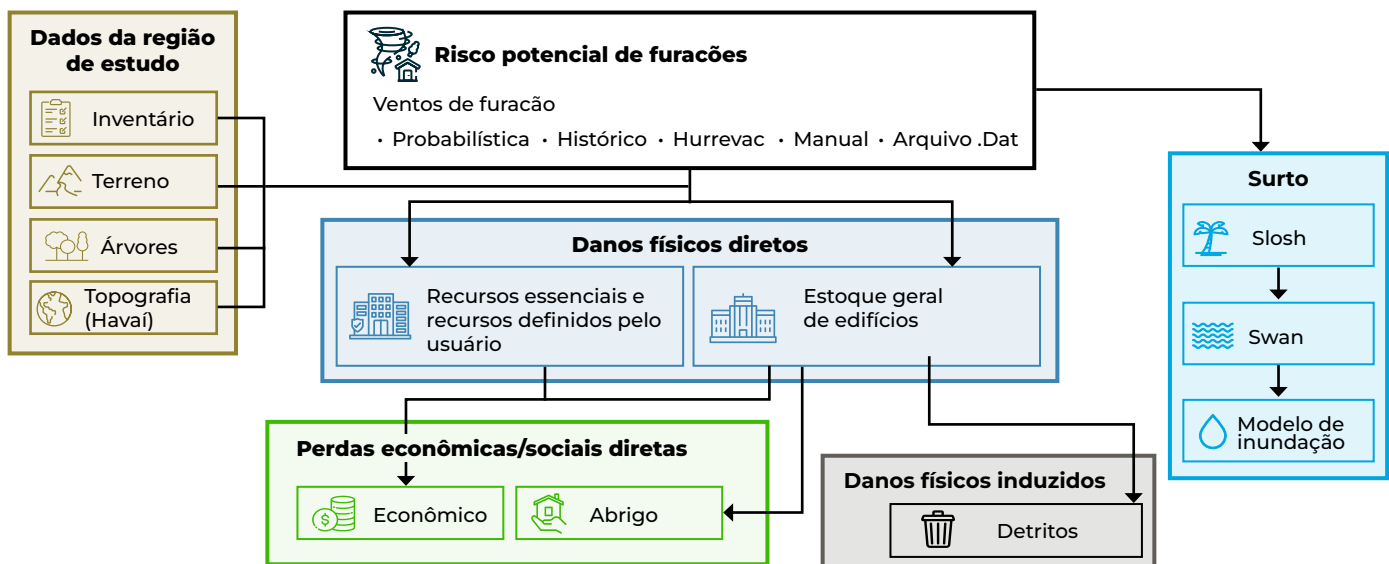
Fonte: FEMA (2022b).



**Furacão:** avalia os danos causados por ventos com força de furacão, geração de escombros e perdas econômicas. Calcula os danos físicos e econômicos a construções devido ao vento e a escombros transportados pelo vento. Os dados de perigo de vento são gerados no nível de unidade censitária. O modelo considera as rajadas máximas de vento, a rugosidade do terreno e os dados de cobertura arbórea, tanto para tempestades históricas quanto para eventos probabilísticos. Os resultados podem ser combinados com um modelo interno de maré de tempestade ou com dados de maré fornecidos pelo usuário, a fim de estimar os danos às construções causados por inundações costeiras. Os manuais técnicos e do usuário do Hazus Hurricane Wind fornecem informações sobre os resultados do modelo, as incertezas, a execução de análises básicas e avançadas, as funções de dano, a geração de escombros, os requisitos de abrigo, as marés de tempestade e os impactos. O manual técnico também inclui estudos de validação de furacões históricos (FEMA 2024c).

A metodologia Hazus para furacões, mostrada na **Figura 33**, permite estimar as consequências para uma cidade ou região com base em um cenário de furacão ou em um conjunto de eventos probabilísticos de 100 mil anos. As informações geradas incluem estimativas quantitativas de perdas em termos de custos diretos de reparo e substituição de edificações danificadas, perda de receitas comerciais, gastos de realocação, deslocamento de domicílios, requisitos de abrigo, quantidade de escombros e impactos econômicos regionais. Além disso, estima-se a perda de funcionalidade e os tempos de restauração de hospitais, delegacias de polícia, quartéis de bombeiros e centros de operações de emergência (FEMA 2022a).

**Figura 33. Metodologia do modelo de furacões Hazus**



Fonte: FEMA (2022a).



O modelo probabilístico usa uma abordagem de simulação de ciclo de vida na qual a trajetória completa de um furacão ou tempestade tropical é modelada, começando com seu início no oceano e terminando com sua dissipação final. Usando essa abordagem, a pressão central é modelada como uma função da temperatura da superfície do mar, do rumo da tempestade, da velocidade etc., e atualizada em intervalos de seis horas no histórico da tempestade. É usada a interpolação linear entre os pontos de seis horas. A abordagem é validada pela comparação das estatísticas dos principais parâmetros dos furacões simulados com as estatísticas derivadas de dados históricos. Esse modelo inclui um modelo numérico de campo de vento (Vickery et al. 2009), que incorpora uma solução não linear completa para as equações de movimento (FEMA 2022a).



**Inundações:** estima os danos às edificações, ao conteúdo e as perdas econômicas. Calcula danos físicos e perdas econômicas decorrentes de inundações costeiras ou fluviais, usando funções que relacionam a profundidade e o tipo de inundação ao grau de dano. Os produtos específicos incluem danos ao conteúdo das edificações, redes de serviços essenciais e perdas econômicas. A metodologia de estimativa de perda por inundações consiste em dois módulos que executam processos analíticos básicos: 1) análise de perigo de inundação; e 2) análise de estimativa de perdas por inundações. Os resultados do modelo podem ser visualizados em uma série de relatórios e mapas (FEMA 2024c).

**1**

O módulo de perigo de inundação usa o fluxo e a elevação do solo, entre outros, para estimar a profundidade da inundação e a velocidade da vazão. Os usuários também podem importar diretamente as grades de perigo de inundação definidas pelo usuário em vários formatos.

**2**

O módulo de estimativa de perdas por inundações calcula o dano físico e a perda econômica a partir dos resultados da análise de perigo usando curvas de vulnerabilidade.

A **Figura 34** mostra o esquema do Modelo de Inundação. No momento, alguns recursos não estão disponíveis, mas estão em desenvolvimento. Nesses casos, os modelos são mostrados em quadros de cor cinza e as conexões que levam a esses componentes também estão em cinza.

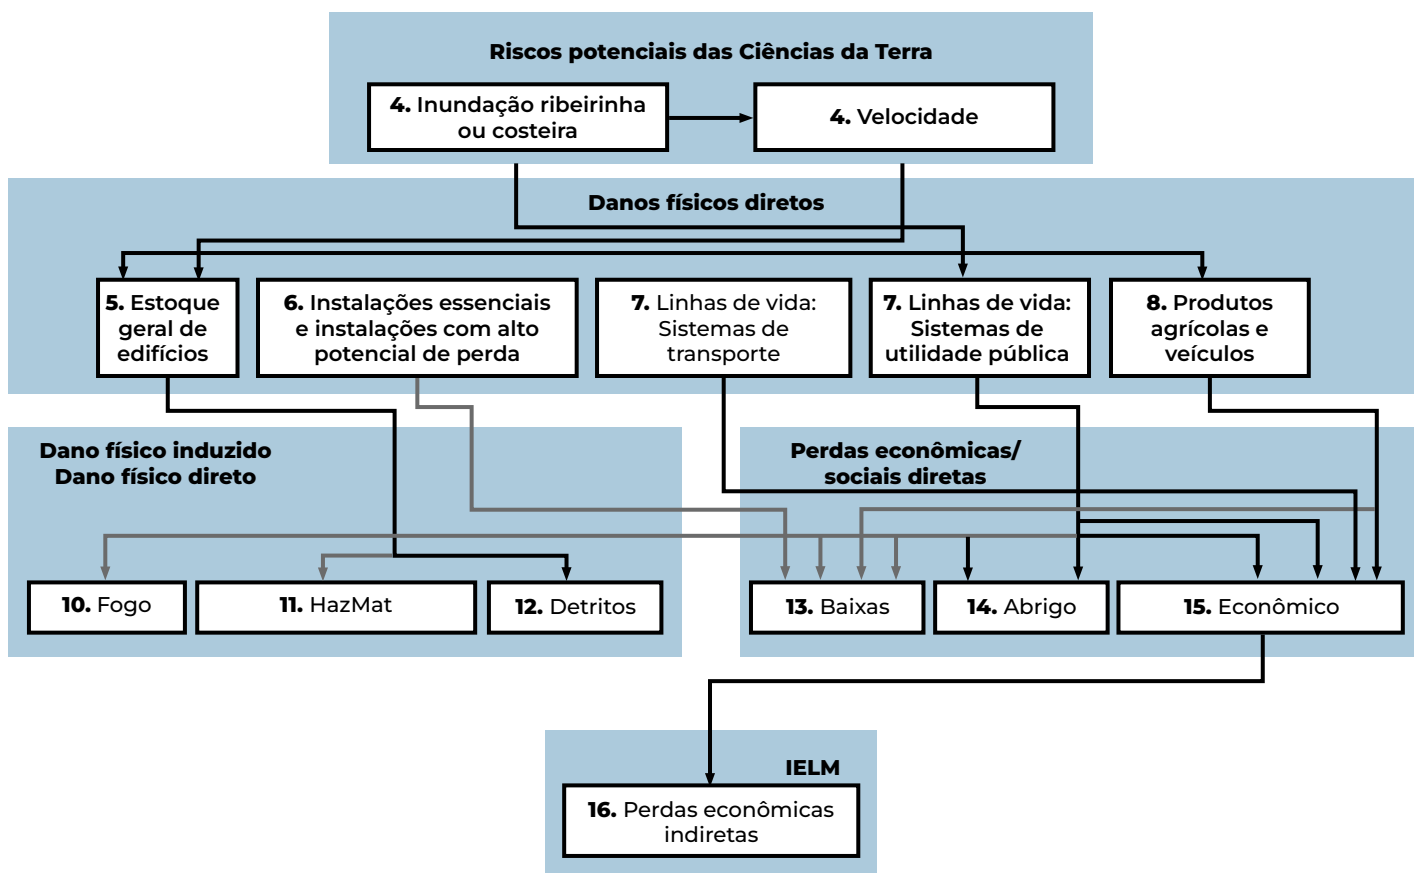
A metodologia incorpora as informações mais recentes disponíveis sobre a metodologia de estimativa de perdas por inundações. Por exemplo, os usuários podem desenvolver suas grades de profundidade com base em seus modelos hidrológicos e hidráulicos e usar as funções de dano mais atualizadas. Os módulos incluem estimadores de perdas por danos não encontrados anteriormente na maioria dos estudos, como perdas econômicas indiretas.



Dependendo da experiência do usuário, o Modelo de Inundação é projetado para operar com uma interface de usuário e dados mínimos, ou o usuário pode pré-processar dados de maior qualidade e realizar análises mais rigorosas. Por exemplo, a metodologia permite estimativas simplificadas de danos e perdas, principalmente usando dados padrão fornecidos com o software. Essas estimativas de danos/perdas não exigem uma coleta extensiva de inventário e podem ser feitas com um orçamento modesto. Estimativas mais precisas de danos/perdas (análise de dados fornecida pelo usuário) exigem informações de inventário mais extensas, com custo adicional para o usuário.

Em todos os casos, os usuários devem fornecer um Modelo Digital de Elevação (DEM). O Modelo de Inundação foi projetado para permitir que o usuário defina facilmente o DEM necessário para sua região de estudo e obtenha o Conjunto de Dados de Elevação Nacional (NED) no site do USGS. O usuário também pode fornecer seu próprio DEM que atenda às necessidades do modelo. Depois que um DEM é fornecido, o usuário pode começar a desenvolver estimativas de danos e perdas. Um usuário que disponha de dados topográficos mais precisos e de informações melhoradas que definam seu perigo de inundação pode importá-los (FEMA 2022b).

**Figura 34. Esquema do modelo de inundação**



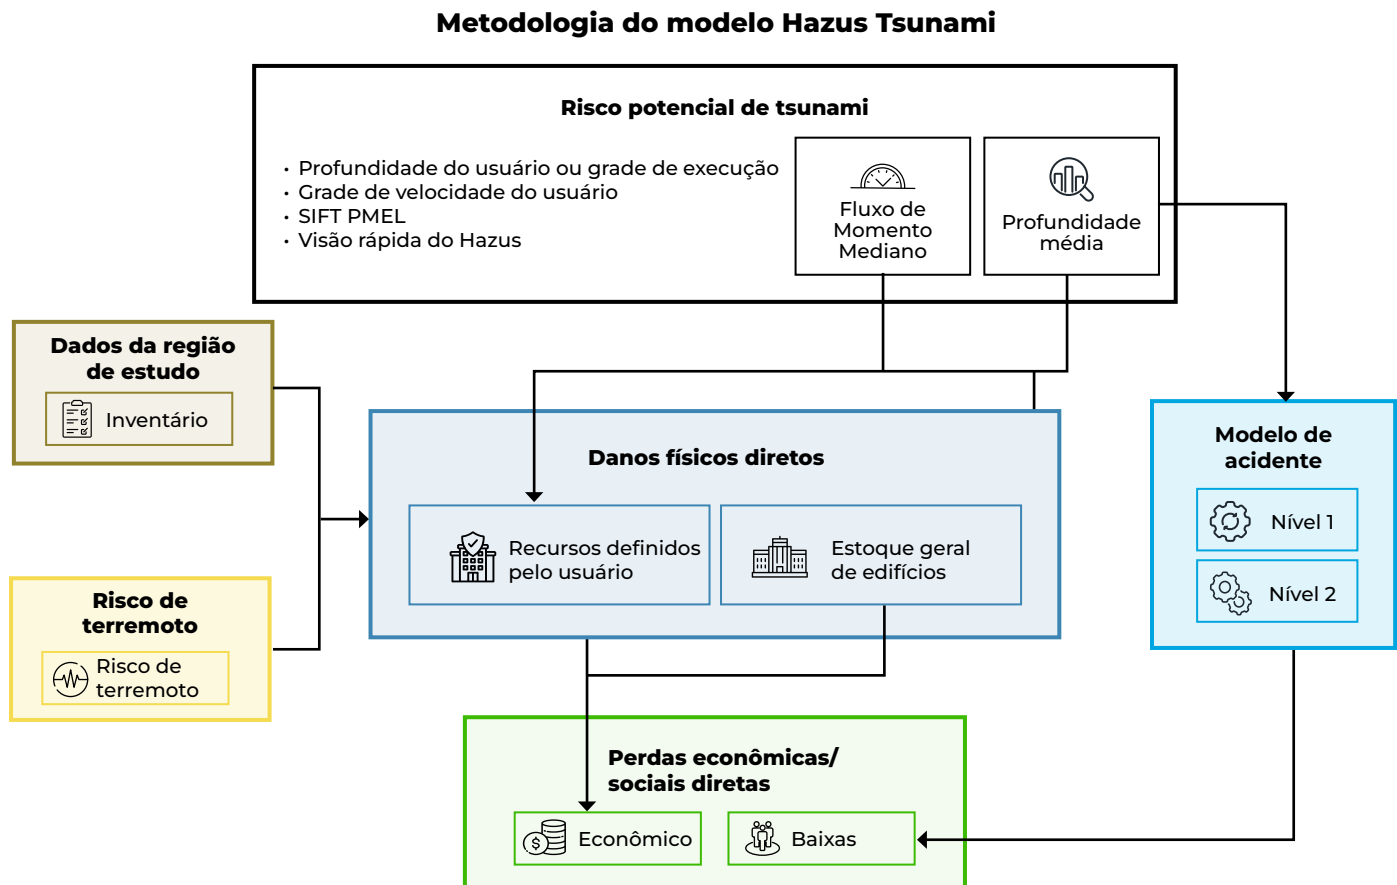
Fonte: FEMA (2022b).



O Modelo de Inundação inclui um conjunto de funções de dano, incorporando a maioria das curvas de danos disponibilizadas pela Administração Federal de Seguros (atualmente denominada Administração Federal de Seguros e Mitigação, vinculada ao Departamento de Segurança Interna dos EUA) e pelo Corpo de Engenheiros do Exército dos EU A. O Inventário Geral de Edificações (General Building Stock – GBS, na sigla em inglês) abrange edificações residenciais, comerciais, industriais, agrícolas, religiosas, governamentais e educacionais. Os danos são estimados em percentual e ponderados pela área de inundação em uma determinada profundidade, correspondente a um bloco censitário específico. Pressupõe-se que toda a composição do parque imobiliário geral dentro de um bloco censitário esteja uniformemente distribuída ao longo de sua área. As informações de inventário necessárias para determinar o percentual de danos de uma área inundada derivam das relações entre as classificações de ocupação específicas e os tipos de edificações. Os três modelos (terremoto, vento e inundação) usam dados comuns, a fim de garantir que os usuários não encontrem discrepâncias no inventário ao alternar de um perigo para outro. Em geral, o Modelo de Inundação apresenta os dados do GBS no nível de bloco censitário, enquanto os modelos de furacões e terremotos exibem os dados de GBS no nível de distrito censitário (FEMA 2022b).



**Tsunamis:** avalia os danos à infraestrutura e as perdas econômicas. Estima a perda econômica e os danos físicos às construções devido à profundidade e à força das ondas de tsunami em cinco estados de alto risco (Califórnia, Washington, Oregon, Havaí e Alasca), bem como nos territórios dos EU A no Pacífico e no Caribe. As estimativas podem ser combinadas com estimativas de perda por terremoto para quantificar impactos adicionais de eventos de tsunami de origem próxima. As metodologias Hazus geram uma estimativa das consequências de um cenário de tsunami em uma cidade, município ou região costeira. A estimativa de perda resultante descreverá a magnitude dos danos e interrupções que podem resultar do tsunami modelado. As seguintes informações podem ser obtidas (consulte a Figura 35): estimativas quantitativas de perdas expressas em custos diretos de reparo e substituição de edificações danificadas, custos diretos associados à perda de função (por exemplo, perda de receita comercial ou gastos de realocação) e acidentes, além de perdas de funcionalidade, definidas em termos de perda de função e tempos de restauração das instalações especificadas pelo usuário. A versão atual do modelo Hazus Tsunami não estima o seguinte: danos, perdas e funcionalidade para instalações essenciais e infraestrutura crítica; requisitos de moradia; volume de escombros; e perdas econômicas indiretas (FEMA 2022e).

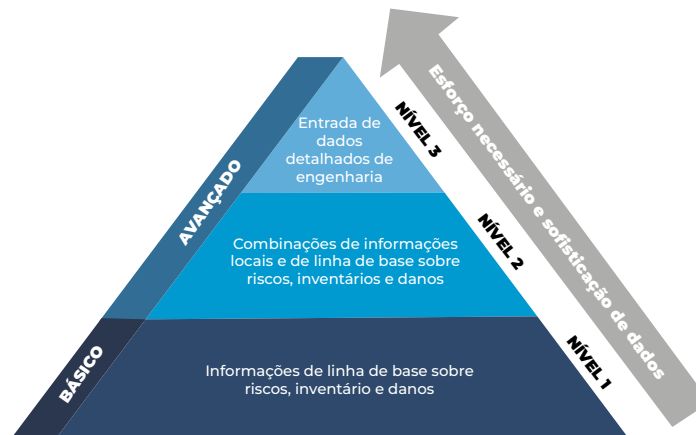

**Figura 35. Esquema da metodologia do modelo de tsunami Hazus**


Fonte: FEMA (2022e).

Esses modelos são apoiados por manuais técnicos e do usuário que fornecem informações detalhadas sobre como os modelos funcionam e como gerar estimativas de perdas.

O desenvolvimento de cada módulo envolveu a participação de um grupo interdisciplinar de especialistas. Por exemplo, o desenvolvimento da metodologia e a implementação do software de inundação foram desenvolvidos por uma equipe de especialistas em perdas por inundações composta por engenheiros, modeladores hidráulicos e hidrológicos, planejadores de emergência, economistas, cientistas sociais, analistas de sistemas de informações geográficas e desenvolvedores de software. O Comitê de Supervisão de Inundações forneceu orientação técnica e revisão do trabalho.

As análises de riscos do Hazus são divididas em básicas ou avançadas (consulte a Figura 36), dependendo do nível de detalhes e do esforço necessário. As análises avançadas usam dados locais mais detalhados para obter estimativas mais precisas.

**Figura 36. Níveis de análise do HAZUS**

Fonte: FEMA (2023).

Por exemplo, no caso das inundações, o modelo de Inundação permite os seguintes três níveis de análise:

## Level

### 1

Nível 1 Esse é o tipo de análise mais simples, que requer esforço mínimo por parte do usuário, pois se baseia principalmente nas informações fornecidas pela metodologia (por exemplo, dados censitários, padrões regionais amplos de adoção do código de planícies aluviais, entre outros). Não se espera que o usuário tenha conhecimento técnico avançado. Embora os métodos exijam algumas entradas de dados fornecidas pelo usuário, essas informações podem ser obtidas com contato com agências governamentais ou consulta a fontes publicadas. Nesse nível, **as estimativas serão aproximadas, sendo adequadas apenas como estimativas iniciais de perdas, com o objetivo de indicar onde se justificam análises mais detalhadas.** Alguns componentes da metodologia não podem ser executados em um análise de dados padrão, pois exigem um inventário mais detalhado do que o disponibilizado pela metodologia. Os seguintes itens não estão incluídos na análise de dados padrão: danos e perdas devido a falhas no solo ou erosão fluvial; danos e perdas provocados por inundações induzidas por terremotos, como tsunamis; danos e perdas resultantes de falhas em barragens. Nesse nível, o usuário tem a opção (não obrigatória) de inserir informações sobre instalações específicas, como locais com materiais perigosos ou instalações essenciais, entre outras. O tempo estimado para coleta de informações relevantes varia de uma semana a um mês, dependendo do tamanho da região e do nível de detalhe desejado.



## Level

2

A análise de nível 2 visa aperfeiçoar os resultados do Nível 1, considerando dados adicionais que estejam facilmente disponíveis ou que possam ser convertidos ou calculados para atender aos requisitos metodológicos. Nesse nível, o usuário pode ter que definir parâmetros com base em relatórios ou mapas publicados que sirvam de entrada para o modelo. Isso requer dados de inventário mais extensos e mais esforço do usuário do que a análise de dados padrão. O objetivo desse tipo de análise é fornecer ao usuário as melhores estimativas de danos/perdas por inundação que podem ser obtidas usando os métodos padronizados incluídos na metodologia. Os usuários do Modelo de Inundação devem pré-processar seus dados de perigo de inundação antes de usá-los no modelo. É provável que seja necessário contratar consultores para apoiar a implementação de determinados métodos. Por exemplo, podem ser necessários especialistas em modelagem hidrológica e hidráulica para definir as profundidades das inundações. Todos os componentes da metodologia podem ser executados nesse nível e as estimativas de perda se baseiam em inventários desenvolvidos localmente (pelo próprio usuário). Nesse nível, o software inclui métodos padronizados de análise, mas não há estudos padronizados de dados fornecidos pelo usuário. À medida que o usuário fornece dados mais completos, a qualidade da análise e dos resultados melhora. Dependendo do tamanho da região e do nível de detalhe desejado, estima-se um período de um a seis meses para obtenção das informações necessárias a esse tipo de análise.

## Level

3

A análise de Nível 3 requer grande esforço por parte do usuário para desenvolver informações sobre o perigo de inundação e a exposição. Esse tipo de análise incorpora resultados de estudos econômicos e de engenharia realizados com o uso de métodos e softwares não incluídos na metodologia padrão. Nesse nível, é necessário contar com um ou mais especialistas técnicos para obter dados, realizar análises detalhadas, avaliar danos e perdas e auxiliar o usuário na elaboração de um inventário mais abrangente. Nesse nível, haverá uma ampla participação dos serviços públicos locais e dos proprietários de instalações especiais. A qualidade e o nível de detalhamento dos resultados dependem diretamente do grau de esforço aplicado. O tempo estimado para conclusão de uma análise avançada varia de seis meses a dois anos.

Cada nível subsequente se baseia nos dados e procedimentos analíticos disponíveis nos níveis anteriores, ampliando-os e complementando-os (FEMA 2022b). A **Tabela 22** mostra o nível de informações e análises necessárias para cada componente da análise de inundação.


**Tabela 22. Níveis de análise exemplificados no caso de inundações**

	Nível 1	Nível 2	Nível 3
<b>Perigo</b>	Os usuários fornecem o Modelo Digital de Terreno (DEM), normalmente o DEM de 30 metros do USGS. O Modelo de Inundação usa os dados de perigo padrão, incluindo os códigos de unidades hidráulicas e a metodologia de acumulação para desenvolver linhas centrais aproximadas dos cursos d'água. São empregadas equações de regressão do USGS e registros de medição para determinar as curvas de frequência de vazão.	Dados de perigo fornecidos pelo usuário pré-processados. O usuário fornecerá resultados melhorados de DEM, hidráulica e hidrologia de inundação, incluindo seções transversais dos cursos d'água. Os usuários da análise costeira fornecem polígonos com elevações e limites da área de análise.	Semelhante ao Nível 2, embora seja provável que o usuário trabalhe com modelos hidráulicos fora do Modelo de Inundação e do FIT.
<b>Inventário</b>	Apresenta a metodologia de dados padrão do Hazus, melhorada para atender às necessidades de avaliação de risco de inundações. Realiza a atribuição de dados por blocos censitários com base em análises estatísticas e suposições gerais sobre a elevação do primeiro pavimento. Inclui informações sobre uso e ocupação do solo, infraestruturas críticas (lifelines), agricultura, inventário de veículos e instalações essenciais.	O usuário fornece os dados de inventário processados por meio do CDMS. Os usuários melhoram as informações sobre elevação do primeiro pavimento e outros atributos necessários à estimativa de perdas por inundação.	Dispõe de dados de alta qualidade sobre o valor das edificações, suas vulnerabilidades a inundações, conteúdo, tipos de ocupação e outros parâmetros, estendidos também a instalações industriais e de alto valor econômico.
<b>Curvas de danos</b>	Curvas regionais consistentes com o nível de detalhamento do inventário, com base nas curvas de dano em função da profundidade disponíveis da FIA ou do USACE. Inclui uma biblioteca de curvas disponível para seleção pelo usuário. O usuário pode criar suas próprias curvas de dano usando guias internas.	Também pode fornecer funções próprias ou modificar especificamente a biblioteca existente, de modo a representar práticas e condições locais.	As curvas fornecidas pelo usuário podem se basear em estudos detalhados de edificações, condições específicas de cultivo ou outros parâmetros relevantes.
<b>Estimativa de danos</b>	Estimativas de danos com base na profundidade da inundação dentro de um bloco censitário determinado. As perdas são calculadas para materiais de construção em geral, veículos, produtos agrícolas, infraestruturas de transporte selecionadas e instalações de serviços públicos.	De acordo com o Nível 1, a estimativa é melhorada por meio do uso de dados de perigo de maior resolução e precisão, maior detalhamento dos dados de inventário e ajustes nas curvas de dano.	De acordo com o Nível 1, a estimativa é melhorada por meio do uso de dados de perigo de maior resolução e precisão, maior detalhamento dos dados de inventário e ajustes nas curvas de dano.
<b>Perdas/ impactos diretos</b>	Inclui estimativas de gastos de reparo ou substituição, vítimas humanas, necessidades de abrigo, moradia temporária, perdas de veículos, cultivos e rebanhos.	Assim como no Nível 1, essas estimativas são refinadas por meio da incorporação de dados de perigo de alta resolução, inventários detalhados e curvas de dano modificadas conforme as condições locais.	Assim como no Nível 1, essas estimativas são refinadas por meio da incorporação de dados de perigo de alta resolução, inventários detalhados e curvas de dano modificadas conforme as condições locais.
<b>Perdas/ impactos indiretos</b>	Impactos econômicos setoriais.	Impactos econômicos setoriais.	Impactos econômicos setoriais.
<b>Aplicações típicas</b>	<ul style="list-style-type: none"> <li>Mitigação de inundações e formulação de políticas regulatórias em níveis regional, estadual e federal</li> <li>Estudos de pré-viabilidade</li> <li>Resposta emergencial em tempo real sem aviso prévio</li> </ul>	<ul style="list-style-type: none"> <li>Planejamento e zoneamento</li> <li>Seleção de alternativas de mitigação</li> <li>Estudos de pré-viabilidade de engenharia</li> <li>Planejamento de emergências e resposta em tempo real</li> <li>Análises de impacto ambiental</li> <li>Capacitação e orientação</li> </ul>	<ul style="list-style-type: none"> <li>Análise de instalações essenciais, culturais e de alto potencial de perda</li> <li>Planejamento de emergências e resposta em tempo real</li> <li>Pesquisas em mitigação e engenharia</li> <li>Pesquisas científicas</li> </ul>

Fonte: FEMA (2022b).



### A.2.3. Abordagem matemática

O Modelo de Inundação do Hazus, até a versão 6.1, exigia a consideração dos danos por inundação correspondentes a um conjunto de períodos de retorno: 10 anos, 25 anos, 50 anos, 100 anos e 500 anos para o cálculo do EAD (Dano Anual Esperado). O Modelo de Inundação do Hazus 6.1 calcula os danos por bloco censitário (e por ocupação) para o conjunto de períodos de retorno. O EAD nessa versão do software é aproximado pela **Equação 7** (FEMA 2022b).

#### Equação 7

$$\begin{aligned}
 AAL = & (f_{10} f_{25}) \frac{(L_{10} \bar{L}_{25})}{2} + (f_{25} f_{50}) \frac{(L_{25} \bar{L}_{50})}{2} \\
 & + (f_{50} f_{100}) \frac{(L_{50} \bar{L}_{100})}{2} + (f_{100} f_{500}) \frac{(L_{100} \bar{L}_{500})}{2} \\
 & + (f_{500} \bar{L}_{500})
 \end{aligned}$$

Em que  $L_{xxx}$  corresponde ao dano ou perda para o período de retorno  $xxx$  and  $f_{xxx}$  à probabilidade de excedência para o período de retorno  $xxx$ . Essa equação pode ser simplificada conforme mostrado na **Equação 8** (FEMA 2022b).


#### Equação 8

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

No caso do Hazus versão 7.0, é possível usar três ou mais períodos de retorno nos cálculos de dano (FEMA 2024d).

No Hazus tsunami e terremoto, os dados de saída desenvolvidos pelo módulo de danos a edificações são estimativas da probabilidade cumulativa de estar em cada estado de dano, ou de excedê-lo, para o parâmetro (ou parâmetros, se combinados) de perigo de interesse. As probabilidades de estado de dano discreto são criadas a partir das probabilidades de dano acumuladas. Esses resultados são usados diretamente como entradas para os módulos de perdas econômicas e sociais diretas (FEMA 2022e).

As funções de dano por tsunami das edificações são apresentadas na forma de curvas de fragilidade lognormal, que relacionam a probabilidade de estar em um estado discreto de dano, ou de excedê-lo, dada a estimativa mediana do parâmetro de perigo de interesse (ou seja, a altura máxima mediana de inundação ou a vazão média do momento máximo). A **Figura 37** ilustra as curvas de fragilidade que descrevem os danos estruturais moderados, extensos e completos devido à vazão do tsunami (ou seja, vazão média do momento máximo, F) (FEMA 2022e).


**Figura 37. Exemplo de uma curva de fragilidade para tsunami**


Fonte: FEMA (2022e).

Conceitualmente, a forma das funções de danos causados por tsunamis às edificações é a mesma do formato da curva de fragilidade lognormal usada pelo modelo de terremoto. Cada curva de estado de dano é definida pelo valor médio e pela variabilidade associada do parâmetro de fragilidade de interesse. A variabilidade dessas curvas de fragilidade tem dois componentes fundamentais: a variabilidade da estimativa mediana do parâmetro de perigo (ou seja, a incerteza na demanda) e a variabilidade do valor mediano do estado de dano (ou seja, a incerteza na capacidade) para o perigo de interesse (FEMA 2022e).

Os danos são classificados em três estágios principais: moderados, extensos e completos. Tanto no modelo de tsunami quanto no de terremoto, esses termos são usados para descrever a extensão e gravidade dos danos. No caso dos terremotos, um estado adicional de danos leves também é considerado, enquanto que nos tsunamis essa categoria não é incluída, pois é difícil diferenciá-la de nenhum dano. Embora a causa e a manifestação dos danos variem entre tsunamis e terremotos, presume-se que os estados de dano sejam equivalentes quando representam um nível semelhante de impacto e gravidade (FEMA, 2022d).



Os danos estruturais são calculados usando a **Equação 9** e a **Equação 10**.

#### **Equação 9**

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

#### **Equação 10**

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

Em que:

$CS_{ds,i}$  é o custo do dano estrutural (gastos de reparo e substituição) para o estado de dano  $ds$  e a ocupação  $i$ . Os dados de custo de substituição de edificações para cada uma das 33 classes de ocupação podem ser encontrados no Manual Técnico de Inventário do Hazus.

$BRC_i$  é o custo de reposição da edificação para a ocupação  $i$ .

$PSBTSTR_{ds,i}$  é a probabilidade de que a ocupação esteja no estado de dano estrutural  $ds$ .

$RCS_{ds,i}$  é a taxa de reparo e substituição estrutural para a ocupação  $i$  no estado de dano  $ds$ .

O Hazus Tsunami também calcula os danos ao conteúdo, os tempos de restauração e a funcionalidade das edificações para as instalações individuais definidas pelo usuário, além dos gastos de realocação e da perda de receitas e de aluguel. As funções de restauração, sua metodologia associada e a funcionalidade derivada estão disponíveis no Manual Técnico do Modelo de Terremoto do Hazus (FEMA, 2022),

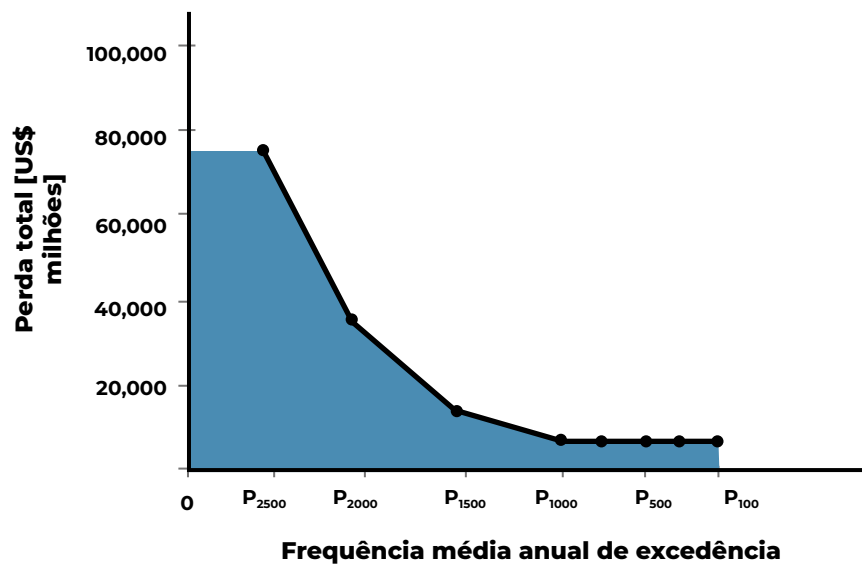
dependendo do tipo de instalação. No modelo de tsunami, uma tabela de consulta foi implementada no banco de dados de parâmetros de análise para que os usuários não precisem localizar e usar as funções de restauração como fazem no modelo de terremoto (FEMA 2022e).

No caso de terremotos, a metodologia Hazus considera intensidades para oito níveis de perigo com uma probabilidade associada: variando de terremoto com 39% de probabilidade de ser excedido em 50 anos (período de retorno de 100 anos) a terremoto com 2% de probabilidade de ser excedido em 50 anos (período de retorno de 2,5 mil anos). Após o processamento dos dados de perigo, um módulo de análise interna do Hazus é usado para transformar as perdas dos oito cenários em uma perda sísmica anualizada (AEL). A **Figura 38** ilustra um exemplo de curva de risco usando o método do Hazus com oito valores de danos associados a probabilidades de excedência. O Hazus calcula a AEL estimando a área sombreada sob a curva de probabilidade de perda mostrada na **Figura 38**. Essa área representa uma aproximação do EAD e equivale a considerar a soma das perdas multiplicada por sua probabilidade anual de ocorrência.



O critério usado pelo Hazus para selecionar o número de pontos na curva de risco foi a eficiência computacional versus a precisão marginal melhorada. Para determinar o número adequado de períodos de retorno, foi realizado um estudo de sensibilidade comparando a estabilidade dos resultados da AEL com o número de períodos de retorno para 10 regiões dos EUA usando cinco, oito, 12, 15 e 20 períodos de retorno. A diferença nos resultados da AEL usando períodos de retorno de oito, 12, 15 e 20 foi insignificante (FEMA 2022f).

**Figura 38. Curva de danos e área sob a curva conforme conceituado pelo Hazus para cálculo de risco sísmico**



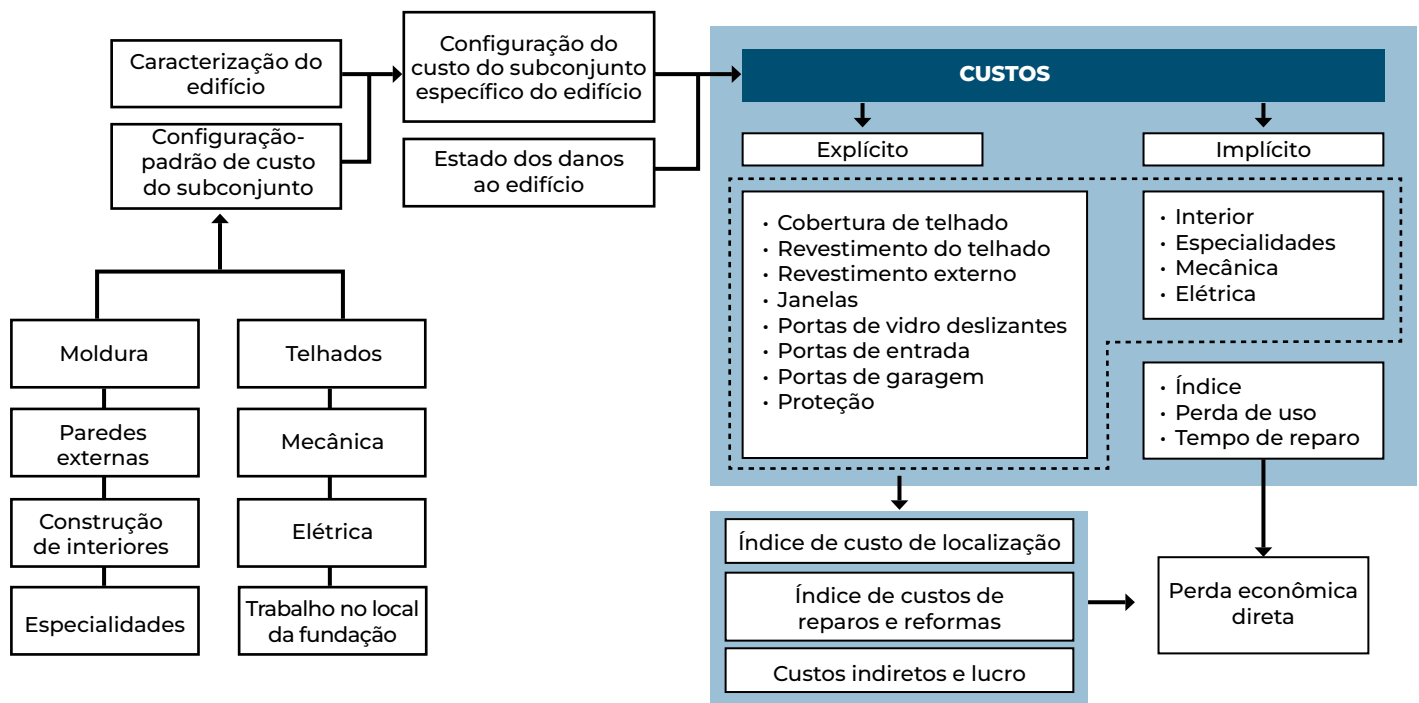
Fonte: FEMA (2022e).

O modelo **Hazus** para furacões usa uma abordagem totalmente probabilística para obter os resultados de risco. A metodologia Hazus estima as consequências de um furacão em uma cidade ou região usando um conjunto probabilístico de eventos, cuja extensão varia de acordo com a geografia. O modelo de simulação da trajetória da tempestade é iniciado por meio da amostragem aleatória de uma posição inicial, data, hora, direção e velocidade de translação de uma das tempestades tropicais registradas no banco de dados HURDAT. O número de tempestades a serem simuladas em qualquer ano é obtido por amostragem de uma distribuição binomial negativa com um valor médio de 8,4 tempestades por ano e um desvio padrão de 3,56 tempestades por ano. A abordagem de modelagem permite que as tempestades se curvem, mudem de velocidade e se intensifiquem à medida que se movem, reproduzindo as estatísticas continuamente variáveis associadas à pressão central, direção etc., ao longo da costa dos EU A (FEMA 2022a).



O modelo de perdas é um modelo físico que calcula as perdas econômicas diretas usando uma combinação de técnicas de cálculo de custos explícitas e implícitas (consulte a **Figura 39**). O modelo de perdas subdivide as edificações em subconjuntos de custos. Essa abordagem oferece uma flexibilidade de custo significativa e a capacidade de processar uma ampla gama de tipos de edificações. O modelo de perdas foi projetado para processar estados de dano detalhados do envoltória da edificação e oferece a capacidade adicional de estimar as perdas econômicas no interior da edificação e em seu conteúdo, considerando diretamente o volume de água que penetra por meio das fenestração danificadas (janelas, portas, portas de garagem etc.). A abordagem de modelagem também é adequada para estimar a perda de uso e o tempo de reparo (FEMA 2022a).

**Figura 39. Representação esquemática do modelo de perdas**



Fonte: FEMA (2022a).

O modelo de vento segue uma abordagem probabilística baseada na metodologia de perigo-carga-resistência-dano-perda, desenvolvida a partir de uma estrutura de risco individual. O desempenho das edificações diante de ventos extremos é formulado de forma probabilística usando conceitos de confiabilidade estrutural. A probabilidade de falha de elementos individuais (como janelas ou portas) é estimada pela comparação da carga de vento com a resistência do elemento. Por meio de simulações em diferentes tipos de edificações, as probabilidades de danos são calculadas e as relações entre a intensidade do vento e os danos físicos são estabelecidas (FEMA).



A perda média anual com furacões considera todas as perdas futuras causadas pelo perigo de furacões resultantes de possíveis eventos de risco com diferentes magnitudes e períodos de retorno em média por ano. Isso pode ser usado para ajudar a examinar os benefícios da mitigação e comparar os riscos econômicos de diferentes perigos no mesmo local. O Hazus pode ser usado para gerar a perda média anual somando todas as perdas durante a simulação de furacões de 20 mil anos e dividindo por 20 mil anos (FEMA 2022a).

## A.2.4. Avanços recentes e inovações

O Hazus incorporou melhorias contínuas para integrar as mais recentes abordagens científicas e tecnológicas. As atualizações recentes incluem o **Hazus 7.0**, que apresenta inovações importantes ao integrar recursos avançados do ArcGIS Pro, melhorando a interface e as ferramentas de análise de SIG. Os principais avanços incluem fluxos de trabalho otimizados para inundações e furacões, metodologias melhoradas para áreas de inundação costeira e um cálculo de Perda Média Anual (AAL) mais flexível que permite usar várias grades de profundidade para análise de inundações. Além disso, o Hazus 7.0 simplifica o acesso aos dados ao eliminar a configuração manual do banco de dados, consolidando as informações em um único arquivo acessível a todos os territórios dos EUA.

## A.2.5. Comunidade de desenvolvimento

O programa Hazus é administrado pelo Programa de Avaliação de Riscos de Ameaças Naturais da FEMA e colabora com outras agências federais, instituições de pesquisa e autoridades de planejamento regional. Essa colaboração garante que os recursos do Hazus incorporem os mais recentes avanços científicos e tecnológicos e atendam às necessidades da comunidade de gerenciamento de riscos (FEMA 2023).

## A.2.6. Limitações

Embora seja uma ferramenta poderosa, seu banco de dados e modelos são adaptados principalmente para o contexto dos EUA, embora possam ser usados em outras áreas geográficas com as adaptações necessárias.

## A.2.7. Casos de uso

Embora o Hazus seja usado principalmente nos EUA, há adaptações e casos de uso em outros países. Kulmesch et al. (2010) usou o Hazus para analisar o risco de inundação em uma região da Áustria; Rozelle (2007) usou e comparou os resultados do modelo de terremoto do Hazus no Nepal. Há também casos de aplicação na América Latina, como o desenvolvido por Chantavilasvong y Guerrero (2019), que é apresentado no **Quadro 10**.

## Hazus Case Study in Piura (Peru)



No norte do Peru, na região de Piura, a estação chuvosa vai de dezembro a março e, em anos de El Niño, pode durar até abril. Em 2017, um ano marcado por um forte El Niño, as chuvas foram 10 vezes mais altas do que o normal, gerando perdas econômicas estimadas em US\$ 3,1 bilhões em todo o país. Em Piura, a região mais afetada, houve quatro mortes, centenas de famílias desalojadas e a perda de cerca de 15 mil hectares de plantações debaixo d'água.

O estudo usa uma adaptação do modelo HAZUS-MH da Agência Federal de Gerenciamento de Emergências dos EU A (FEMA). A metodologia proposta aborda as limitações de dados e de capacidade técnica em Piura usando uma abordagem acessível e replicável que inclui: (i) uma análise simples e acessível usando o QGIS para análise espacial; (ii) mapas de distribuição espacial identificando áreas com riscos de inundação; (iii) avaliação monetária dos custos potenciais de danos a edificações; (iv) análise espacial do risco de inundação; (v) delimitação de áreas de inundação.

O modelo adaptado usa ferramentas de código aberto, como o QGIS, para realizar uma análise espacial do risco de inundação. Os dados de base incluem o Modelo Digital de Elevação (DEM) SRTM3 da NASA e as curvas globais de danos em função da profundidade de inundação (Huizinga et al. 2017). As principais etapas metodológicas incluem:



**Delimitação de áreas de inundação:** identificação de áreas propensas a inundações a partir de altitudes relativas aos níveis estimados dos rios.



**Avaliação da exposição:** sobreposição de mapas de inundação com dados de construções, classificadas de acordo com os materiais de construção (madeira e concreto).



**Cálculo de danos estruturais:** estimativa de edificações colapsadas e danificadas usando curvas de danos de profundidade de inundação.

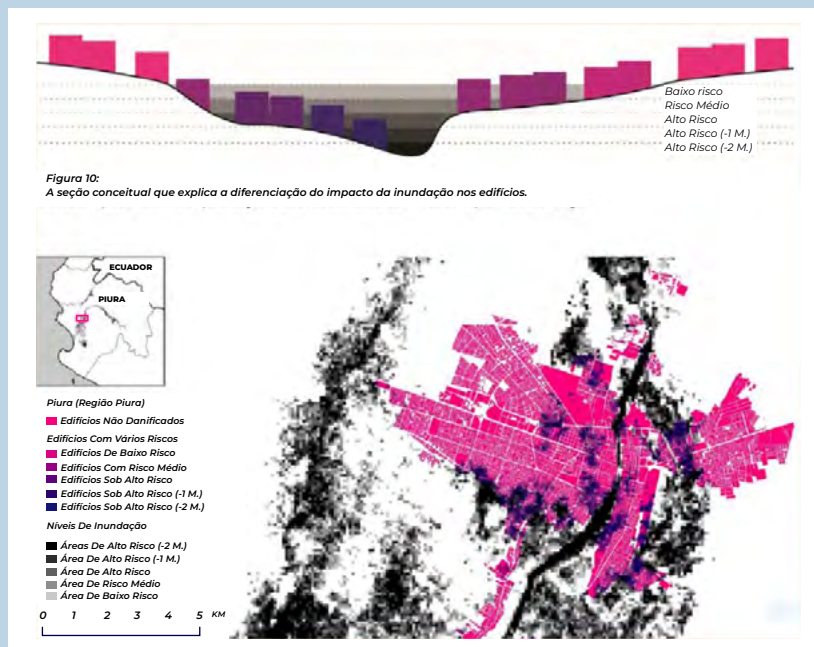


**Avaliação monetária:** quantificação dos gastos de reconstrução e reparo, fornecendo estimativas econômicas dos possíveis impactos.

Os mapas produzidos mostram que muitas áreas propensas a inundações foram desenvolvidas como zonas residenciais ou comerciais, expondo seus habitantes às inundações fluviais. No cenário de maior risco, estima-se que aproximadamente 6.274.439 m<sup>2</sup> de edificações serão afetadas, com um custo potencial de US\$ 4,2 bilhões para toda a região de Piura. Esse valor inclui 5.821.163 m<sup>2</sup> de edificações danificadas e 453.276 m<sup>2</sup> de edificações colapsadas, afetando principalmente moradias de baixa renda construídas com materiais como taipa ou madeira.

O modelo HAZUS-MH adaptado à região de Piura demonstra ser uma ferramenta útil para estimar os riscos de inundação e quantificar os impactos econômicos. No entanto, o sucesso de sua implementação depende de: (i) melhorar a disponibilidade e a qualidade dos dados locais; (ii) capacitar as autoridades locais na análise de riscos e no planejamento de mitigação; (iii) promover uma abordagem participativa que fortaleça os atores locais a gerenciar seus próprios riscos climáticos. A metodologia adaptada do modelo HAZUS-MH representa uma primeira etapa importante na estimativa dos riscos de inundação de forma acessível e eficaz em Piura. Embora existam lacunas de dados e limitações, a simplicidade e a replicabilidade da abordagem a tornam uma ferramenta valiosa para fortalecer as autoridades locais e promover planos de mitigação de riscos mais robustos.

### Mapa de categorização de risco de inundação da cidade de Piura



Fonte: Chantavilasvong & Guerrero (2019).



## A.3. RiskScape: ferramenta de avaliação de risco

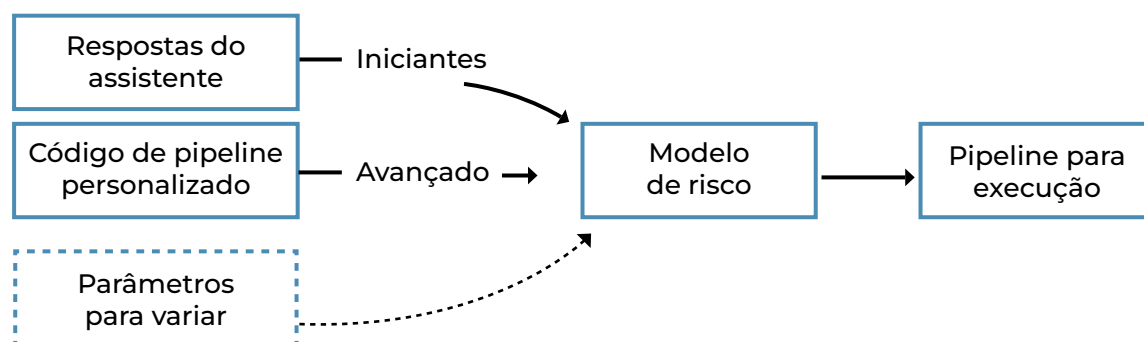
### A.3.1. Descrição geral

O RiskScape é uma aplicação de processamento de dados espaciais de código aberto projetado para análise de riscos multiameaça, desenvolvido em conjunto pela GNS Science e pelo Instituto Nacional de Água e Pesquisa Atmosférica (NIWA) da Nova Zelândia. Altamente personalizável, o RiskScape permite que os modeladores adaptem a análise de riscos às necessidades específicas do domínio e dos dados de entrada que estão sendo modelados. A ferramenta pode integrar dados de várias fontes e formatos, aplicando uma variedade de operações geoespaciais, estatísticas e de manipulação de dados. Isso facilita a modelagem de uma grande variedade de fluxos de trabalho de forma coerente, simplificando as complexidades inerentes ao manuseio de dados geoespaciais. Além disso, o RiskScape permite a execução de modelos determinísticos simples em um laptop até a execução de modelos probabilísticos com uso intensivo em uma instância de computação na nuvem de alto desempenho (National Institute of Water and Atmospheric Research Ltd and Institute of Geological and Nuclear Sciences Ltd 2024a).

### A.3.2. Métodos aplicados

O RiskScape oferece um assistente que orienta os usuários na criação inicial de um modelo de risco simples usando uma série de perguntas relacionadas aos dados de entrada e ao tipo de modelagem que desejam realizar. O RiskScape usa sua própria linguagem de script para descrever o fluxo de processamento do modelo, conhecido como “pipeline”. Esse pipeline define uma série de etapas de processamento de dados, escritas como expressões simples semelhantes a fórmulas de planilhas ou instruções básicas do Python. O RiskScape obtém as respostas do assistente e as converte em código de pipeline que você pode executar (consulte a **Figura 40**).

**Figura 40. Geração do pipeline**



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

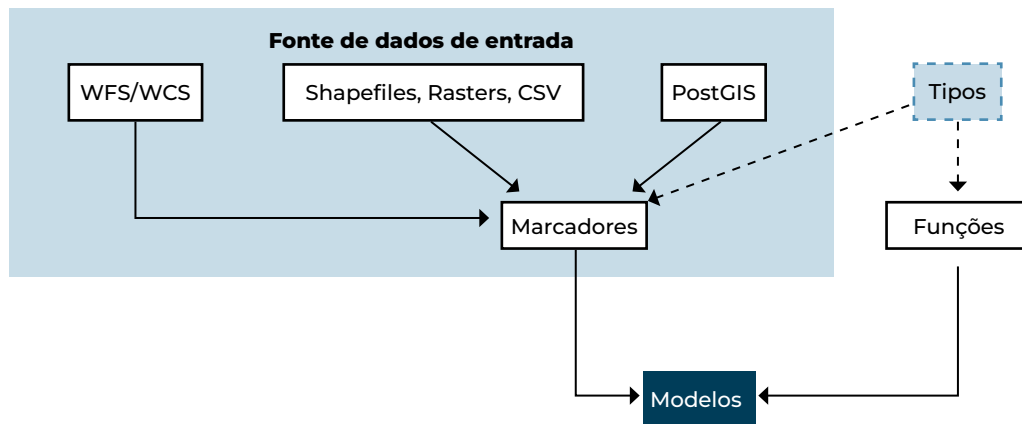


À medida que os modeladores se tornam usuários mais avançados do RiskScape, podem personalizar totalmente seu fluxo de trabalho de modelagem, definindo-o diretamente no código do pipeline, usando o código gerado pelo assistente como ponto de partida. Atualmente, o RiskScape é uma ferramenta de linha de comando (CLI), de modo que os usuários executam seus modelos a partir da linha de comando. Executar um modelo significa que o RiskScape processa os dados de entrada de acordo com as instruções do pipeline e salva os resultados em um arquivo.

Um modelo pode ser executado variando os arquivos de dados de entrada ou outras suposições. Os detalhes dos modelos e pipelines são armazenados em arquivos de texto (por exemplo, arquivos INI) que informam ao RiskScape exatamente o que fazer. Essa coleção de arquivos é chamada de projeto. Um projeto define os fluxos de trabalho do modelo do início ao fim, incluindo quais arquivos de dados de entrada e funções de vulnerabilidade devem ser usados. Os projetos organizam os modelos do RiskScape de modo que aqueles relacionados, que envolvem riscos semelhantes ou afetam as mesmas características de interesse, sejam agrupados de forma coerente.

Um projeto contém o conjunto completo de instruções necessárias para executar um ou mais modelos do RiskScape, incluindo:

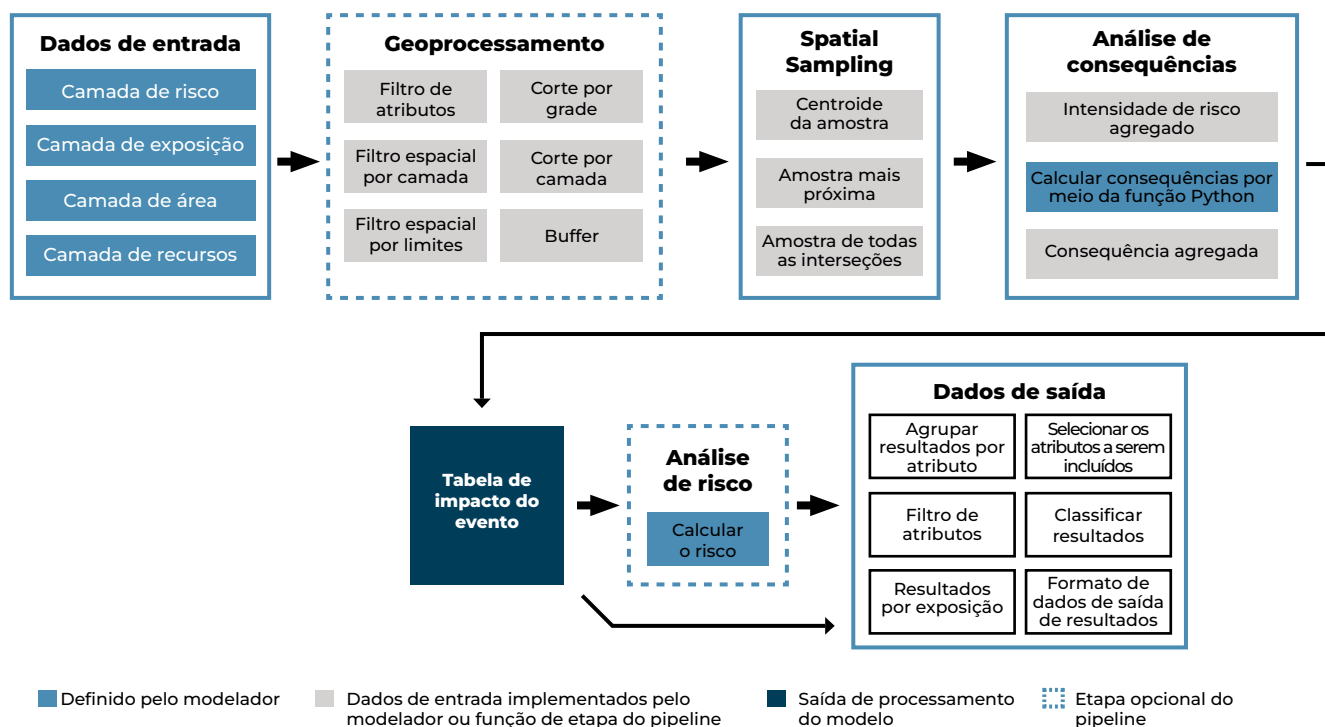
- ➔ **Fontes de dados de entrada:** dados de várias fontes em formato GIS, que podem ser usados sem a necessidade de importação ou pré-processamento. Os locais dos vários arquivos de entrada e quaisquer instruções adicionais sobre como carregar os dados são especificados em marcador do RiskScape.
- ➔ **Funções:** os usuários podem escrever suas próprias funções no Python para avaliar o impacto de um perigo em um elemento em risco, como estimar danos, calcular custos ou amostrar uma curva probabilística. Os usuários avançados também podem usar funções para manipular ou transformar os dados em qualquer ponto do pipeline.
- ➔ **Tipos:** o RiskScape usa um sistema de tipos para representar a estrutura dos dados à medida que eles fluem pelo modelo. Os tipos definem como os dados de entrada podem ser manipulados e as funções que podem ser usadas. Os tipos compostos podem representar um conjunto de atributos, como um ativo de construção ou a consequência (perdas, danos etc.) do perigo.
- ➔ **Modelos:** o modelo é a combinação de dados de entrada, funções e outros parâmetros que são aplicados a um pipeline de processamento de dados para produzir resultados (consulte a **Figura 41**). Os modelos podem ser definidos a partir de respostas salvas do assistente ou diretamente no código do pipeline.

**Figure 41. Project components**

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

Os modelos do RiskScape são fluxos de trabalho predefinidos e personalizados (consulte a **Figura 42**) que processam dados geoespaciais para realizar análises de riscos. Ao executar um modelo, o risco dos dados fornecidos é analisado. O fluxo de trabalho de um modelo inclui várias fases importantes: carregamento de dados de entrada, geoprocessamento, amostragem espacial, análise de consequências, análise de riscos e geração de relatórios. Os dados de entrada incluem camadas de exposição, que contêm os elementos em risco, e camadas de ameaças. Opcionalmente, camadas adicionais podem ser acrescentadas para melhorar os resultados do modelo (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024d).

O geoprocessamento transforma os dados geométricos antes de qualquer análise de riscos. Posteriormente, a amostragem espacial combina geoespacialmente os dados de entrada para determinar a intensidade do perigo para cada elemento em risco. A análise de consequências calcula o impacto do perigo em cada elemento em risco, produzindo uma tabela de impacto do evento que resume os resultados. Os usuários avançados podem realizar cálculos de risco adicionais, como a probabilidade anual esperada, na fase de análise de riscos. Por fim, os resultados são filtrados e agregados para gerar relatórios personalizados, permitindo que um único modelo produza vários arquivos de saída (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024d).


**Figure 42. Workflow**


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

As funções de danos do RiskScape permitem que você analise o impacto de um perigo, além de simplesmente determinar se uma edificação está exposta ou não. O usuário pode definir sua própria função no Python para realizar qualquer tipo de análise de riscos que desejar. O RiskScape usa uma Função de Distribuição Acumulada (CDF) lognormal para calcular a probabilidade condicional (entre 0 e 1) de que uma edificação se encontre em um determinado estado de dano como resultado de uma inundação. Os cinco estados de dano usados no modelo são os seguintes (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024e):

- ➔ **Leve:** danos não estruturais.
- ➔ **Menor:** danos estruturais não significativos e danos estruturais menores.
- ➔ **Moderado:** danos estruturais e não estruturais significativos.
- ➔ **Grave:** danos estruturais irreparáveis que exigem demolição.
- ➔ **Colapso:** colapso estrutural completo.



A fragilidade da edificação (ou seja, a forma da curva CDF lognormal) varia de acordo com o seu material de construção. O modelo de danos atribui um estado geral de danos a cada edificação com base nas probabilidades calculadas, usando uma escolha aleatória ponderada para determinar o nível final de danos (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024e).

O RiskScape oferece uma variedade de formatos de entrada e saída, conforme mostrado na **Tabela 23** (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024d).

**Tabela 23. Formatos de dados aceitos pelo RiskScape**

Formato	Extensão de arquivo	Suporte
arcgrid	asc	dados de entrada
csv	csv	dados de entrada e saída
geojson	geojson, json	dados de entrada e saída
geopackage	gpkg	dados de entrada e saída
geotiff	tif, tiff	dados de entrada
kml	kml	dados de entrada e saída
postgis		dados de entrada
shapefile	shp	dados de entrada e saída
wfs		dados de entrada
NetCDF		dados de entrada
hdf5		dados de entrada

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

### A.3.3. Abordagem matemática

Na estrutura conceitual do RiskScape, os termos modelo probabilístico e modelo de cenário são usados para descrever dois tipos diferentes de modelagem probabilística<sup>25</sup> (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024c):

- **Modelo probabilístico:** um modelo no qual a perda é calculada para muitos eventos independentes a fim de obter resultados probabilísticos, como perdas anualizadas ou curvas de excedência.
- **Modelo de cenário:** esse tipo de modelo calcula a perda para um único evento teórico, em que há incerteza sobre como o evento se desenvolverá. Por exemplo, como o movimento do solo se propagará a partir do epicentro de um terremoto ou como as condições do solo no dia do evento afetarão a propagação de uma inundação após a ruptura de um dique.

Para criar um modelo probabilístico no RiskScape, há duas partes principais: a geração de uma tabela de perdas por evento e o cálculo dos resultados probabilísticos (por exemplo, a Probabilidade de Excedência

<sup>24</sup> O RiskScape define modelagem probabilística como um modelo de perdas que aborda certas incertezas presentes na análise.



Anual [AEP]). A estrutura do modelo dependerá em grande medida do conjunto de dados do evento de ameaça. A tabela de perdas por evento calcula a perda total para cada evento e sua construção varia de acordo com os dados de entrada (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024c).

O RiskScape considera as seguintes abordagens para análises probabilísticas:

- ➔ **Baseada em eventos:** cada evento no conjunto de dados de entrada é tratado como tendo a mesma probabilidade dentro do próprio modelo (simulação de Monte Carlo). O modelo depende da existência de eventos suficientes no conjunto de dados para modelar a incerteza e gerar uma curva de perdas. Um aspecto importante dos modelos probabilísticos baseados em eventos é o número de conjuntos de eventos hipotéticos aos quais os eventos pertencem. Normalmente, isso corresponde ao número de períodos de tempo, como anos, que são modelados e é necessário para calcular as perdas anualizadas. Esse conjunto é denominado Conjunto de Eventos Estocásticos (SES, na sigla em inglês).

Uma vez obtida a perda total para cada evento, cada evento é atribuído a um SES. Isso atribui cada evento ao ano civil em que ocorreu.

O SES é importante para o cálculo da Perda Média Anualizada (PMA), pois alguns anos civis podem conter vários eventos, enquanto outros podem não registrar nenhum. É importante destacar que, se não ocorrerem eventos em determinado SES (ano), atribui-se perda igual a zero.

Para gerar a curva de risco, as perdas são classificadas da maior para a menor, e a cada uma é atribuída uma probabilidade obtida pela divisão do intervalo pelo número total de conjuntos de eventos.

Para ilustrar esse método, e os demais apresentados nesta seção, serão usados os exemplos fornecidos na documentação online do RiskScape<sup>26</sup>.

A **Tabela 24** mostra um conjunto de dados de cinco eventos para os quais a perda foi calculada.

**Tabela 24. Exemplo de cinco eventos para os quais a perda foi calculada**

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

<sup>25</sup> <https://riskscape.org.nz/docs/advanced/probabilistic.html>



As perdas que excedem um determinado nível de perda são contabilizadas conforme mostrado na Tabela 25.

**Tabela 25. Contagem de eventos de perda que excedem um determinado nível de perdas**

Nível de perda	Contagem
100	4
250	3
500	2
750	1
1000	1

A taxa de excedência ( $\lambda$ ) é calculada para um período de tempo unitário (1).

**Tabela 26. Taxa de excedência**

Nível de perda	Contagem	Cálculo	$\lambda$
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

Supondo que os eventos sejam independentes, é possível usar uma distribuição de Poisson para calcular a Probabilidade de Excedência Anual (AEP) y substituindo a taxa ( $\lambda$ ) e o período de tempo (T) na fórmula  $1 - \exp(-\lambda * T)$ .

**Tabela 27. Cálculo de AEP**

Nível de perda	Contagem	$\lambda$	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

O período de retorno ou intervalo médio de recorrência (ARI) pode ser calculado a partir da taxa, conforme mostrado na Tabela 28.


**Tabela 28. Cálculo do período de retorno**

Nível de perda	contagem	$\lambda$	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

Esse método é equivalente ao explicado na **seção 4.4**.

- **Based on weighted events:** each event in the input dataset already has an associated probability or occurrence rate. This is the rate at which this event occurs during the defined period of time (usually annually). For example, a rate of 0.1 for a one-year period would mean that, on average, an event is likely to occur every ten years. A model based on weighted events provides good coverage of the range of possible events without requiring the large number of events needed for a Monte Carlo simulation.

For example, **Table 29** shows the losses for 5 events.

**Tabela 29. Tabela de perdas para cinco eventos**

Evento	Taxa de ocorrência	Perda
1	0.01	\$1100
2	0.035	\$500
3	0.04	\$600
4	0.1	\$200
5	0.05	\$800

Para calcular a Perda Média Anual (AAL), é realizada a soma do produto dos valores de taxa × perda, resultando em uma AAL de US\$ 112,50.


**Tabela 30. Cálculo da AAL**

Evento	Taxa de ocorrência	Perda	Taxa x perda
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
<b>Total</b>	<b>0.235</b>	<b>\$3200</b>	<b>\$112.50</b>

Para calcular o desvio padrão, é aplicada a fórmula taxa × perda<sup>2</sup>. A soma dos valores resulta em US\$ 71.250,00. A raiz quadrada desse valor dá um desvio padrão de US\$ 266,93.

**Tabela 31. Cálculo do desvio padrão**

Evento	Taxa de ocorrência	Perda	Taxa x perda <sup>2</sup>
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
<b>Total</b>			<b>71250</b>

Para calcular a AEP, é realizada a soma da taxa de ocorrência de cada evento que ultrapassa determinado nível de perda, resultando na taxa total de excedência.

**Tabela 32. Taxa total de excedência**

Nível de perda	Taxa de excedência
100	0.235
250	0.135
500	0.1
750	0.06
1000	0.01

Com a taxa de excedência, é possível calcular a AEP aplicando  $1 - \exp(-\lambda \times T)$ .


**Tabela 33. Cálculo da AEP**

Nível de perda	Taxa de excedência	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

O período de retorno, ou intervalo médio de recorrência (ARI), pode ser calculado a partir da taxa, conforme mostrado na **Tabela 34**.

**Tabela 34. Cálculo do ARI**

Nível de perda	Nível de perda	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

➔ **Baseada em perigos:** o conjunto de dados de entrada contém um número reduzido de eventos, e cada evento possui uma taxa de ocorrência (ou período de retorno). Por exemplo, os arquivos de entrada de perigo podem representar uma inundação com períodos de retorno de 10 anos, 50 anos, 100 anos etc. Isso difere de outros modelos probabilísticos, como os modelos baseados em eventos, em que a probabilidade de excedência é derivada da própria execução do modelo.

A principal vantagem da abordagem baseada em perigos é que apenas um pequeno número de eventos é necessário para criar um resultado probabilístico. Isso é útil quando não é viável produzir as milhares de camadas de ameaças necessárias para um modelo baseado em eventos.

Um modelo probabilístico baseado em perigos exige que cada evento no modelo tenha um intervalo de recorrência conhecido (ou período de retorno), que está presente nos dados (ou metadados) das camadas de ameaças. Além disso, a função de perdas do modelo deve gerar perdas que aumentem de forma monótona à medida que a frequência da ameaça diminui. Em outras palavras, eventos menos frequentes devem produzir perdas mais severas para cada elemento em risco exposto ao perigo.



A probabilidade de excedência é dada como um número decimal entre 0 e 1. Isso é interpretado como a probabilidade de ocorrência de um evento dessa intensidade ou maior em um determinado período (geralmente anos). Uma probabilidade de excedência pode ser relacionada a um período de retorno usando uma função de massa de probabilidade. Os exemplos fornecidos pelo RiskScape pressupõem que a função de distribuição de Poisson é adequada. Ao usar Poisson, o período de retorno é usado como a taxa, também conhecida como lambda ( $\lambda$ ). Um período de retorno pode ser convertido em uma probabilidade de excedência (EP) com a **Equação 11**.

### Equação 11

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

As probabilidades de excedência são frequentemente calculadas a partir de um período de retorno (RP) com uma aproximação simples, mostrada na **Equação 12**.

### Equation 12

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

Mas essa é uma aproximação mais pobre do que usar o cálculo baseado em Poisson. A **Tabela 35** mostra como o método de aproximação se torna menos preciso à medida que a probabilidade aumenta.

**Tabela 35. Comparação da probabilidade de excedência calculada com Poisson e com a aproximação recíproca**


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

Com um modelo probabilístico baseado em perigos, não há pontos de dados suficientes para usar o mesmo método numérico para calcular uma AAL como no caso de modelos baseados em eventos ou em eventos ponderados. Em vez disso, esse método se baseia na regra do trapézio para estimar a área sob a “curva” da probabilidade de excedência de cada evento e a perda calculada para esse evento.


**Tabela 36. Exemplo de probabilidade de excedência e perdas associadas**

Evento	Probabilidade de excedência	Perda
1	0.1	\$1000
2	0.01	\$10000
3	0.001	\$100000

Com base nos dados da **Tabela 36**, é possível traçar a curva e, usando o método do trapézio e estimar a área sob a curva, que representa a AAL.

**Figura 43. Curva de probabilidade de excedência e perdas**


A **Figura 43** mostra a área sombreada (em escala logarítmica) abaixo da curva traçada a partir dos pontos de dados da **Tabela 36**. Tomar uma “fatia” entre dois pontos na curva resulta em uma forma trapezoidal (veja a área azul na **Figura 43**). O método trapezoidal simplesmente pega várias partes entre a EP mínima (ou seja, 0,001) e a EP máxima (ou seja, 0,1) e as soma. Isso resulta na área sob a curva entre o primeiro e o último ponto de dados do evento. No entanto, ainda faltam duas partes da curva: o lado esquerdo entre a EP 0,0 e 0,001 e o lado direito entre a EP 0,1 e 1,0 (ou quando a perda se torna US\$ 0). Não é possível fazer nada em relação ao lado direito ausente da curva, pois isso depende da disponibilidade de dados de ameaça que se aproximem o máximo possível de um evento com perda zero. Quanto ao lado esquerdo ausente, sabemos que as perdas aumentam de forma monótona; portanto, as perdas entre 0,0 e 0,001 devem ser maiores ou iguais à perda máxima conhecida (US\$ 100 mil). Portanto, basicamente, podemos adicionar um ponto de dado extra (EP = 0,0; perda = US\$ 100 mil) à curva.



O método trapezoidal consiste simplesmente em calcular a diferença de valor (probabilidade de excedência) entre dois pontos de dados e multiplicá-la pelo valor médio (perda). A integração trapezoidal aplicada aos três eventos de exemplo, mais o ponto de dados extra EP=0,0, é mostrada na **Tabela 37**.

**Tabela 37. Cálculo da área sob a curva**

Diferença na EP	Perdas médias	Fatia 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

A soma das fatias trapezoidais é US\$ 495 + US\$ 495 + US\$ 100 = US\$ 1.090.

Como o corte “trapezoidal” EP = 0,0 é, na verdade, um retângulo, ele pode ser simplificado para apenas a perda máxima multiplicada pela EP mínima. Com esse termo adicional EP=0,0, o cálculo da AAL da área da curva de perda é igual a:

### Equação 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. Avanços recentes e inovações

As últimas atualizações do software RiskScape incluem mudanças e melhorias significativas que afetam tanto os usuários especializados quanto a experiência geral do software. Uma mudança notável é a atualização da biblioteca GeoTools, usada para processamento de geometria, que melhora a estabilidade e o desempenho. Novas funcionalidades foram implementadas para facilitar a personalização avançada pelos usuários. Além disso, foi adicionada uma função para trabalhar com funções bidimensionais e as funções de tratamento de erros foram aperfeiçoadas (National Institute of Water and Atmospheric Research Ltd e Institute of Geological and Nuclear Sciences Ltd 2024b).

## A.3.5. Comunidade de desenvolvimento

O RiskScape é mantido e desenvolvido pela GNS Science e pela NIWA, com apoio financeiro da Comissão de Terremotos da Nova Zelândia (EQC). A comunidade de usuários inclui cientistas, planejadores urbanos, seguradoras e entidades governamentais que usam a plataforma para modelar perdas e riscos associados a desastres.



## A.3.6. Limitações

A principal limitação do RiskScape é a necessidade de configuração e modelagem avançadas, que podem exigir conhecimento especializado, principalmente de programação no Python.

## A.3.7. Casos de uso

O RiskScape tem sido usado em toda a Nova Zelândia e no Pacífico Sul para ajudar planejadores, agências governamentais e companhias de seguros a modelar o risco e a perda por desastres. Isso é crucial para a tomada de decisões no planejamento do uso do solo, seguros e resposta a emergências. Por exemplo, ele tem sido usado para analisar a exposição de edifícios residenciais a terremotos e para o planejamento urbano de inundações e movimentos de massa. O Quadro 4 mostra um exemplo do uso do RiskScape no planejamento do uso do solo.



## Estudo de caso: gerenciamento de riscos por inundação no Te Auaunga (Oakley Creek), em Auckland



O Te Auaunga (Oakley Creek) é um rio que flui do Monte Roskill, atravessando diversos subúrbios do oeste de Auckland, e desagua no porto interior de Waitemātā, próximo a Point Chevalier. A área foi designada para redensificação urbana no âmbito do Plano de Uso do Solo de Auckland (AUP). Atualmente, as áreas imediatamente adjacentes ao corpo d'água são um misto de áreas residenciais: casas e prédios de apartamentos, moradias urbanas mistas e moradias suburbanas mistas. Existe a possibilidade de aumentar a densidade urbana com uma mudança no plano de uso do solo que poderia permitir um mínimo de três moradias de três andares.

O Departamento de Operações de Águas Pluviais do Conselho de Auckland desenvolveu o programa “Making Space for Water”, que foi apresentado ao Conselho em junho de 2023 e inclui nove iniciativas principais:



**Redes azul-verde em áreas críticas de risco de inundação:** soluções para águas pluviais, melhorias de parques ou espaços abertos, aquisição de propriedades.



**Propriedades em alto risco:** trabalho com proprietários de imóveis em soluções de engenharia, reassentamento e aquisição de propriedades.



**Melhorias em bueiros e pontes:** avaliação, substituição e melhoria de ativos vulneráveis.



**Gestão de trajetórias de escoamento superficial:** reparo, manutenção e manejo das trajetórias de escoamento superficial, bem como capacitação e orientação para proprietários de imóveis em suas áreas de influência.



**Assentamentos rurais:** atender às necessidades de água em comunidades afetadas por inundações, incluindo marae e papakāinga, e apoiar o planejamento de resiliência da comunidade.



**Inteligência em inundações:** investimento em ferramentas de planejamento e modelagem para melhorar a tomada de decisões do Conselho.



**Reabilitação dos corpos d'água:** gestão da vegetação, estabilização de taludes, modificação dos corpos d'água, orientação para proprietários de imóveis.



**Resiliência a inundações liderada pela comunidade:** orientação para proprietários de imóveis em áreas de alto risco, orientação específica para o setor, eventos públicos e campanhas de conscientização.



**Aumento da manutenção:** maximização da eficiência da rede de águas pluviais, incluindo varredura de ruas, limpeza de bueiros e remoção de ervas daninhas nos corpos d'água.

Este estudo de caso usa elementos dessas iniciativas para considerar quatro abordagens de gerenciamento de riscos por meio do planejamento do uso do solo: Proteger, Aceitar, Reduzir, Evitar (PARA, na sigla em inglês):



**Proteger:** estruturas de proteção rígidas. Esta abordagem não está incluída no estudo de caso, pois exige a modelagem do perigo com obras, o que está fora do escopo.



**Aceitar (Acomodar):** aumentar a altura dos edifícios. Os requisitos atuais são de 500 mm em um evento de inundação com Probabilidade de Excedência Anual (AEP) de 1%.



**Reduzir:** redes verde-azuladas, incluindo soluções para águas pluviais, melhoria de espaços verdes ou abertos e reassentamento.



**Evitar:** não permitir mais avanços ou intensificação.

O objetivo é usar o RiskScape™ para quantificar o benefício de várias opções de intervenção do modelo “PARA” para o risco futuro na planície de inundação. O processo seguido para criar o pipeline do RiskScape™ foi o seguinte:

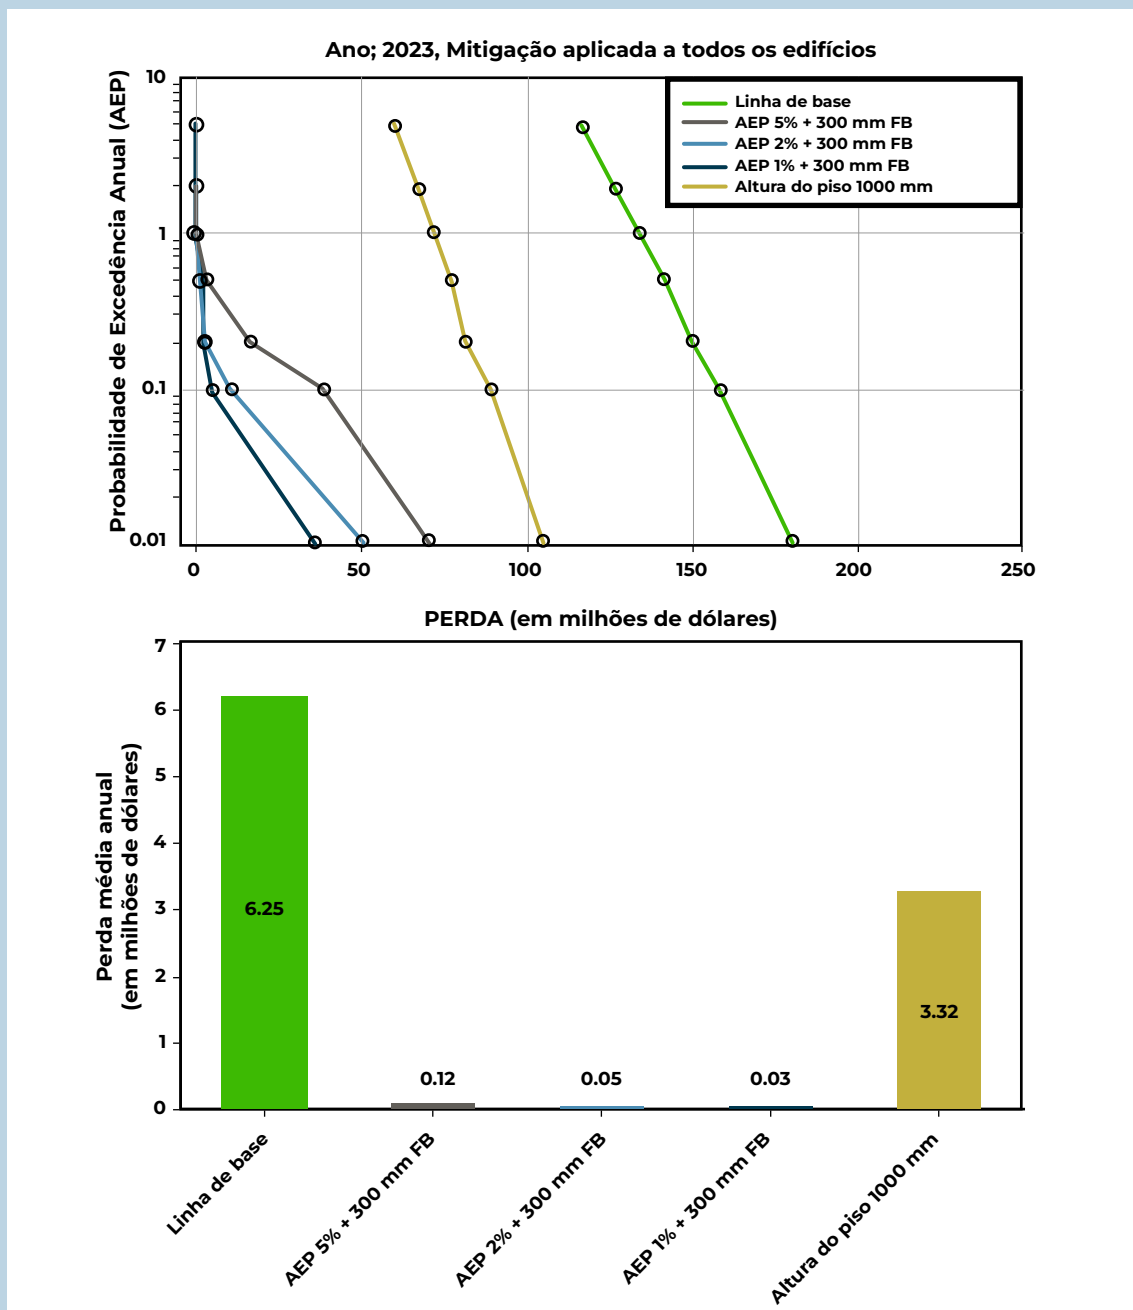
- ➔ Modelar o risco futuro de base (sem mudanças na política de uso do solo existente), em seguida modelar com as opções de intervenção política para demonstrar a diferença no risco futuro. A diferença no risco futuro é usada para mostrar a possível redução do risco ao implementar políticas e contribuir para a análise de custo-benefício.
- ➔ Modelar uma série de cenários com diferentes AEP para entender o risco de inundação em um espectro de possíveis cenários. Os cenários com AEP variando de 5%, 2%, 1%, 0,5%, 0,2%, 0,1% a 0,01% foram usados para considerar uma ampla gama de possíveis inundações.
- ➔ Definir um horizonte temporal de planejamento. Neste caso, foi escolhido o ano de 2120 como referência para o risco futuro, o que implica modificar os dados de exposição do presente até uma exposição potencial em 97 anos.
- ➔ Examinar os níveis de intensificação futura. As zonas do plano de uso do solo têm níveis variados de redensificação residencial que podem ocorrer como uma atividade permitida, mas devem atender aos padrões.
- ➔ Definir a intensificação máxima possível dentro do horizonte de planejamento.
- ➔ Gerar conjuntos de dados de exposição futura. Depois que o ritmo de desenvolvimento é definido, o RiskScape™ gera conjuntos de dados de exposição futura para cada ano entre o ano atual (2023) e o horizonte de planejamento futuro (2120).
- ➔ Calcular o risco ao longo do tempo. O RiskScape™ calcula o risco para cada ano usando as camadas de ameaças. Se houvesse uma mudança climática ou algum outro fator temporal nos dados de perigo, isso também poderia ser incorporado.

Os resultados obtidos com o RiskScape™ são definidos por duas métricas (veja a figura abaixo): curvas de risco e Perda Média Anual (AAL). As curvas de risco mostram a probabilidade de exceder um determinado nível de perda como uma função da AEP, com diferentes opções de mitigação.

A opção de elevar a altura dos pisos para um valor fixo de 1.000 mm reduz as perdas, mas não é tão eficaz como vincular essa elevação a um modelo de AEP acrescido de uma margem de segurança (freeboard). Também se observa uma redução nas perdas ao aplicar modelos de AEP de 5%, 2% ou 1% combinados com freeboard. A métrica de AAL evidencia a redução das perdas ao longo do tempo, o que é útil para a análise de custo-benefício. Com a

implementação de várias opções de mitigação, como o aumento das alturas dos edifícios ou a inclusão de freeboard, obtém-se uma redução significativa das perdas anuais.

Este estudo de caso demonstra como o RiskScape™ pode ser usado para quantificar os benefícios de diferentes intervenções de política pública no gerenciamento de riscos de inundação. Ao modelar diferentes cenários de risco e aplicar várias opções de mitigação, é possível otimizar a tomada de decisões sobre planejamento do uso do solo e resiliência frente a inundações, promovendo uma gestão mais informada e eficiente dos riscos para a comunidade.



Fonte: Bretherton et al. (2023).



## A.4. InaSAFE

### A.4.1. Descrição geral

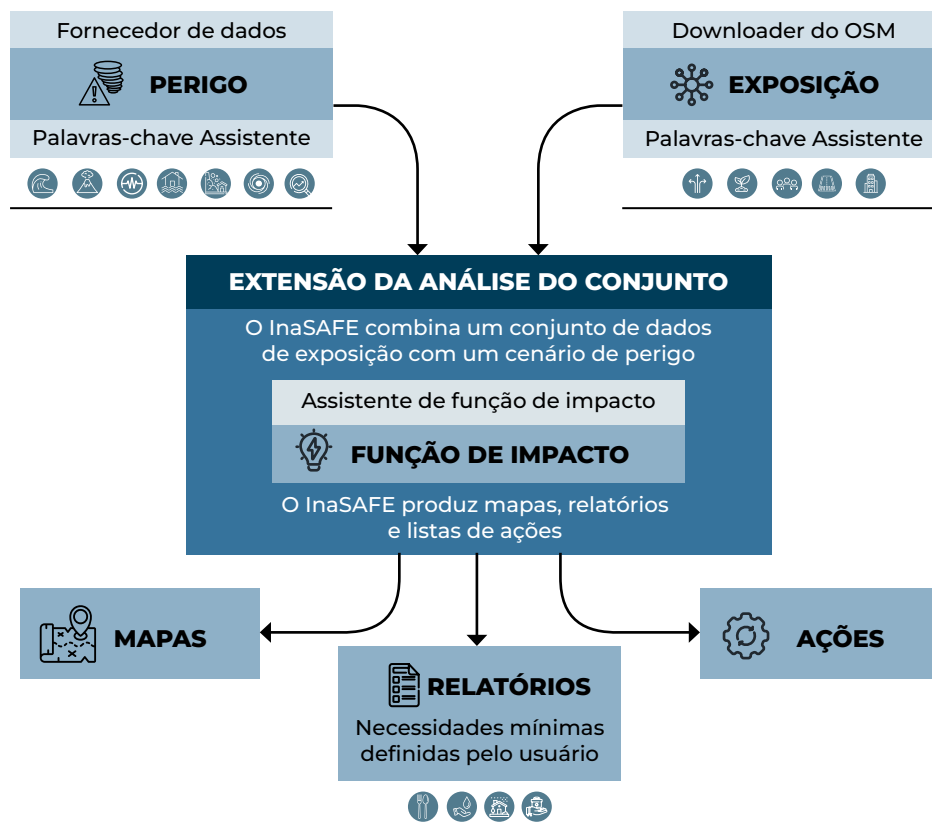
O **InaSAFE** (Indonesia Scenario Assessment for Emergencies) é uma ferramenta de software livre desenvolvida para a avaliação de impactos de desastres como terremotos, tsunamis e inundações. O sistema foi criado em colaboração entre a Agência Nacional de Gestão de Desastres da Indonésia, o Governo da Austrália e o GFDRR do Banco Mundial.

O InaSAFE é um software livre que gera cenários de impacto de ameaças naturais para melhorar as atividades de planejamento, preparação e resposta a desastres. Ele oferece uma forma simples, porém rigorosa, de combinar informações técnicas, governamentais e comunitárias para fornecer informações sobre os prováveis impactos de futuros desastres.

O projeto InaSAFE foi criado com o objetivo de fornecer uma ferramenta aos gestores de risco de desastres que buscam compreender os impactos potenciais de um desastre. Inicialmente, a atividade se concentrou na Indonésia, país altamente vulnerável a diferentes tipos de desastres, como inundações, tsunamis, erupções vulcânicas e terremotos, além de desastres localizados, como movimentos de massa e incêndios florestais. Desde então, o InaSAFE tem sido adotado em diversos outros países, não sendo mais uma ferramenta exclusiva da Indonésia (InaSAFE 2019b).

### A.4.2. Métodos aplicados

O InaSAFE combina uma camada de dados de exposição (por exemplo, a localização de edificações) com um cenário de ameaça (como a área de inundação) e gera uma camada espacial de impacto, acompanhada de um resumo estatístico e de questões orientadoras para a ação. A estrutura da ferramenta é apresentada na Figura 44, indicando como dados de entrada as camadas de ameaça e de exposição, às quais se aplica uma função de impacto para gerar mapas, relatórios e listas de ações. O InaSAFE foi concebido para responder a perguntas como: “Em caso de uma inundação semelhante à de Jacarta em 2013, quantas pessoas poderiam precisar ser evacuadas?” (InaSAFE 2019a).


**Figura 44. Estrutura do InaSAFE**


Fonte: InaSAFE (2019a).

O InaSAFE também pode dividir os resultados do impacto por limites administrativos e fornecer um detalhamento das informações sobre o gênero e a idade das pessoas afetadas dependendo dos dados de entrada usados (InaSAFE 2019a).

Os dados de perigo usados no InaSAFE podem representar um único evento ou vários eventos. As informações de um evento único são úteis quando você deseja estimar, por exemplo, “quantas pessoas seriam afetadas se ocorresse outra inundação como a de 2013”. Os dados de vários eventos são úteis quando se deseja planejar desastres que afetam repetidamente a mesma área.

O tipo de informação de ameaça usado pelo InaSAFE pode ser vetorial ou raster. No caso de informação vetorial, é necessário um campo que indique se o polígono é suscetível a inundações ou não. Já para a informação raster, é usada uma grade simples com valores de célula que representam a profundidade da água (InaSAFE 2019a).



Atualmente, o InaSAFE oferece suporte a quatro tipos de dados de exposição: rodovias, edificações, população e cobertura do solo. Com as funções de impacto de inundação em rodovias do InaSAFE, é possível calcular quais vias – e de que tipo – podem ser afetadas por uma inundação. Os dados de vias do OpenStreetMap podem ser baixados diretamente por meio da ferramenta de download do OSM disponibilizada pelo InaSAFE. No caso do inventário de edificações, o InaSAFE requer uma camada vetorial de polígonos que contenha um campo com o tipo de edificação. Atualmente, o InaSAFE só admite dados censitários em formato raster, mas está previsto, para versões futuras, a atribuição de estimativas populacionais a edificações com base em dados censitários. As informações de cobertura do solo devem ser fornecidas em formato vetorial de polígono com um campo contendo o tipo de cobertura do solo. Em geral, os dados de localização podem ser obtidos de agências nacionais de mapeamento ou usando várias fontes de dados online. Os dados de localização são úteis se você quiser avaliar o impacto de um evento em um determinado local. Para a avaliação dos locais, é usada uma camada vetorial de pontos, que deve ter um campo com o nome da localização (InaSAFE 2019a).

Uma Função de Impacto é um código de software no InaSAFE que implementa um algoritmo específico para determinar o impacto de uma ameaça sobre a exposição selecionada. A execução de uma Função de Impacto ocorre quando todos os dados de entrada foram preparados, a extensão da análise foi definida e se deseja visualizar os resultados de impacto. Cada Função de Impacto gera resultados que podem incluir: uma camada de mapa de impacto, um resumo do impacto, necessidades mínimas e listas de verificação de ações (InaSAFE 2019a).

Uma camada de impacto é um novo conjunto de dados SIG gerado como resultado da execução de uma Função de Impacto. Normalmente, ela representa a camada de exposição. Por exemplo, ao realizar uma análise de inundação em edificações, a camada de impacto gerada será uma camada de edificações, mas cada edificação será classificada conforme esteja seca ou inundada (o resultado produzido pelo InaSAFE é binário, indicando se a edificação foi afetada ou não). O InaSAFE aplica sua própria simbologia à camada de impacto gerada, tornando claros as edificações afetadas. É importante observar que a camada de impacto inclui apenas as entidades ou células localizadas dentro da extensão da análise (InaSAFE 2019a).

Enquanto a camada de impacto representa dados espaciais, o resumo de impacto contém dados tabulares e textuais. Esse resumo apresenta tabelas e informações descritivas com o número de edificações, vias ou pessoas afetadas, além de informações complementares, como desagregações de necessidades mínimas, listas de verificação de ações e sínteses resumidas. O resumo de impacto expressa os resultados da função de impacto em um formato fácil de usar (InaSAFE 2019c). Os resultados são limitados à exposição, ou seja, ao número de elementos incluídos em determinada categoria de ameaça, embora o sistema também possua funções de impacto capazes de estimar população deslocada e mortes (InaSAFE 2019a).



### A.4.3. Avanços recentes e inovações

O InaSAFE lançou várias versões, com melhorias significativas na interface do usuário e na compatibilidade com o QGIS. A última versão publicada é a 5.0.0.0, lançada em novembro de 2018. Essa versão inclui suporte para o QGIS 3.x. Ela é uma adaptação direta do código-base 4.4.0, com a incorporação de alguns recursos adicionais, como uma porta para o QGIS 3 com Python 3 e Qt 5 (InaSAFE 2019c).

### A.4.4. Comunidade de desenvolvimento

O InaSAFE foi desenvolvido inicialmente pela Agência Nacional de Gestão de Desastres da Indonésia (BNPB), pelo governo da Austrália e pelo Banco Mundial, por meio do Global Facility for Disaster Reduction and Recovery (GFDRR). O governo australiano, em coordenação com a BNPB, promove o desenvolvimento do InaSAFE mediante seu uso em seis províncias indonésias. Após o lançamento, em outubro de 2012, a Austrália–Indonésia Facility for Disaster Reduction (AIFDR) organizou formações em planejamento de contingência nessas províncias, com o apoio da Humanitarian OpenStreetMap Team (HOT) e da Universidade de Gadjah Mada (UGM) (InaSAFE 2019d).

O uso do InaSAFE gerou muitas solicitações de novas funcionalidades, priorizadas pela BNPB e pelo governo australiano e desenvolvidas pela Kartoza. O Banco Mundial, por meio do GFDRR, desenvolveu uma versão online do InaSAFE para facilitar as análises sem necessidade de baixar o software e também tem apoiado outros países na implementação do InaSAFE. O Grupo de Trabalho Técnico do InaSAFE, composto por representantes da BNPB, do governo australiano e do GFDRR, é responsável pelo desenvolvimento e pela manutenção do software (InaSAFE 2019d).

### A.4.5. Limitações

Uma das limitações mais relevantes é que o InaSAFE não realiza uma análise quantitativa econômica do risco. O software se limita à avaliação da exposição.

### A.4.6. Casos de uso

O InaSAFE tem sido usado em vários projetos de avaliação de riscos na Indonésia e em outros países. Ele tem sido usado para planejamento de emergência, preparação da comunidade e resposta a desastres, ajudando as autoridades locais a entender e mitigar os riscos de desastres.

# Estudo de caso: uso do InaSAFE durante a inundação de Jacarta de 2014

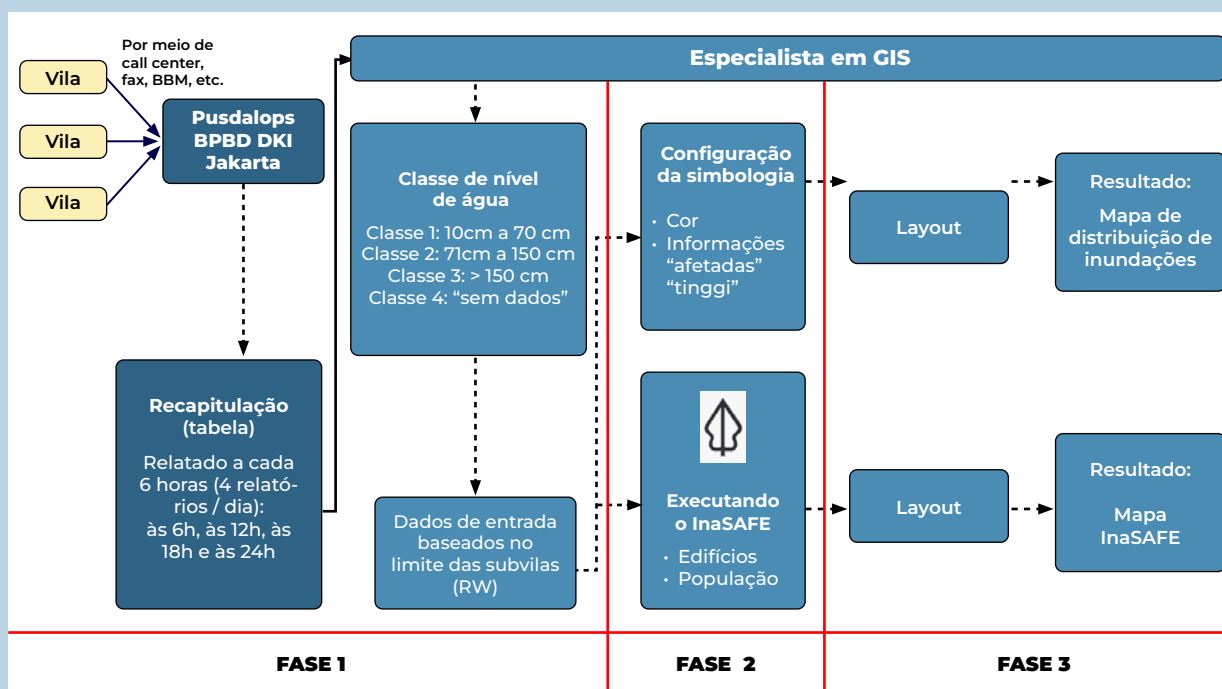
## Histórico

Jacarta sofre inundações sazonais quase todos os anos, entre dezembro e fevereiro, devido ao alto índice pluviométrico. Geograficamente, é uma planície de baixa altitude onde vários rios de Java Ocidental se encontram. As condições ruins de drenagem da cidade, juntamente com sua localização, contribuem para as inundações durante a estação chuvosa. Nessas circunstâncias, tanto o público quanto os funcionários do governo precisam de informações acessíveis e compreensíveis sobre as áreas afetadas pelas inundações.

Reconhecendo o papel fundamental dos mapas de perigo na gestão de desastres, a Austrália-Indonésia Facility for Disaster Reduction (AIFDR) financiou a Humanitarian OpenStreetMap Team (HOT) para apoiar a Agência de Gestão de Desastres de Jacarta (BPBD DKI Jakarta) no mapeamento das inundações em 2014. Dois especialistas em GIS da HOT trabalharam diariamente, durante dois meses, na Pusdalops BPBD DKI Jakarta, produzindo mapas de inundação com base nos relatórios das comunidades afetadas.

## Implementação

Os mapas foram desenvolvidos usando software livre, incluindo o InaSAFE, e software de código aberto, como o QGIS 2.0. O fluxo de trabalho envolveu várias fases mostradas na figura abaixo:



- ➔ **Coleta de dados:** representantes das comunidades afetadas reportaram informações à Pusdalops BPBD DKI Jakarta por meio de um centro de chamadas, fax ou BlackBerry Messenger, fornecendo dados sobre a altura e a extensão da inundação. Esses relatórios eram resumidos em uma tabela que era enviada ao chefe da Pusdalops e ao governador de Jacarta a cada seis horas.
- ➔ **Desenvolvimento de mapas:** os especialistas em GIS transformaram essas tabelas em mapas. As informações sobre o nível de inundação eram classificadas em quatro categorias e inseridas no QGIS 2.0, sendo sobrepostas aos dados de limites das comunidades provenientes do OpenStreetMap (OSM).
- ➔ **Distribuição e análise:** os mapas resultantes incluíam símbolos para mostrar a distribuição e o nível da inundação. Além disso, foram gerados mapas do InaSAFE, integrando dados de risco e exposição para calcular estimativas de impacto.

---

## Resultados

A colaboração entre a HOT e a BPBD DKI Jakarta resultou na elaboração de mapas de inundação referentes ao evento ocorrido entre 12 de janeiro e 10 de fevereiro de 2014. Esses mapas indicavam o nível da inundação nas áreas afetadas e apresentavam uma visualização complementar do número de edificações atingidas e da quantidade estimada de deslocados internos, calculada com o InaSAFE. Os mapas eram publicados diariamente e se mostraram úteis para a tomada de decisões oficiais e a distribuição de ajuda humanitária. Também estavam acessíveis ao público, beneficiando voluntários e jornalistas, e contribuindo para que a população de Jacarta pudesse lidar melhor com as inundações.



---

## Lições aprendidas

For optimal functionality, two areas for improvement were identified:

- ✓ **Infrastructure Data:** Improvement to the completeness of infrastructure data, especially regarding public buildings, since current OSM data are limited.
- ✓ **Geographic Detail:** Increase the geographic detail of the analysis, moving from the sub-village level to more detailed levels, to provide more accurate information on the affected areas.

Fonte: InaSAFE (2019a).



## A.5. OASIS LOSS MODELLING FRAMEWORK (OASIS LMF)

### A.5.1. Descrição geral

O projeto **H2020\_Insurance** da Comissão Europeia criou o Oasis Loss Modelling Framework (Oasis LMF) para a modelagem de riscos associados a catástrofes e eventos climáticos extremos. O principal resultado foi o desenvolvimento de uma plataforma colaborativa e de código aberto para avaliação de riscos climáticos múltiplos, projetada para melhorar as informações disponíveis no setor de (re)seguros e reduzir a discrepância entre as perdas relacionadas ao clima que estão seguradas e aquelas que não estão (Sheehan et al. 2023).

O Oasis LMF é um sistema de modelagem de catástrofes que inclui um conjunto de padrões de dados, uma API, além de ferramentas e componentes para construir e executar modelos (OASIS 2024a). Embora o Oasis seja de código aberto e qualquer pessoa possa instalá-lo e executá-lo gratuitamente, existem várias empresas que oferecem serviços e suporte comerciais em torno do Oasis. Algumas disponibilizam plataformas hospedadas para a execução de modelos do Oasis; outras o integraram em suas próprias plataformas; e algumas fornecem opções tradicionais de suporte para implementações internas do sistema (OASIS 2024b).

Os principais usuários do Oasis são (OASIS 2024a):

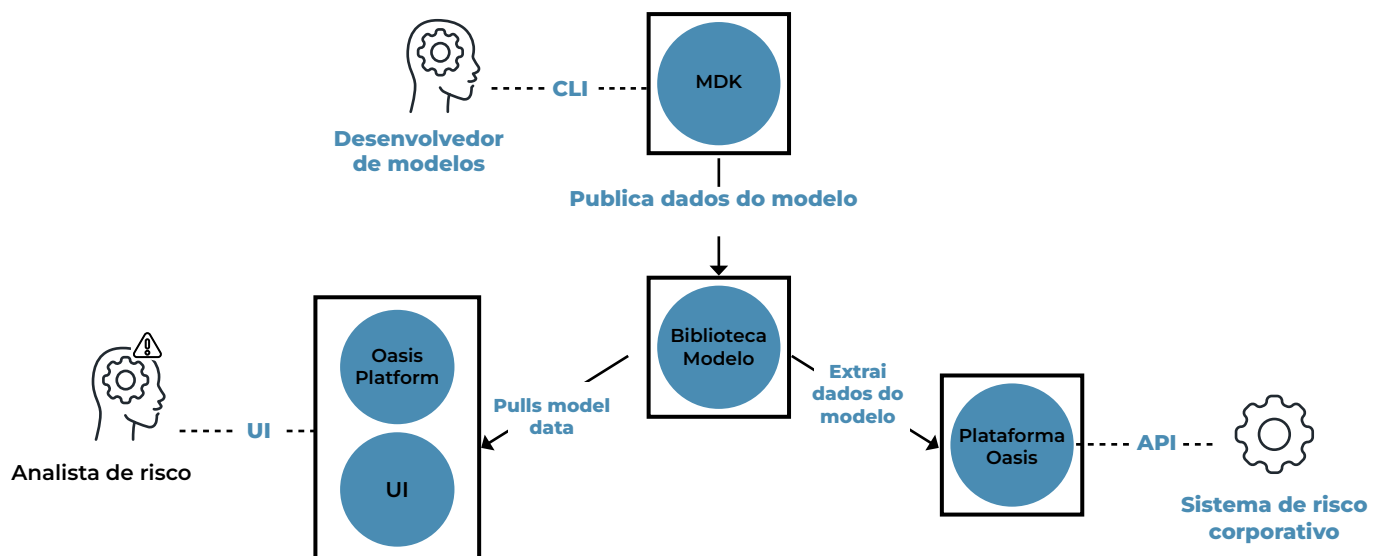
- 1 Desenvolvedores de modelos**, que criam, testam e publicam modelos de risco. Em geral, são cientistas ou desenvolvedores de software que trabalham em empresas de modelagem de risco ou instituições acadêmicas.
- 2 Analistas de risco**, que operam os modelos para apoiar a tomada de decisões. O principal grupo de usuários são analistas de organizações de seguros ou resseguros, que executam os modelos para dar suporte à precificação e ao gerenciamento de portfólio. Isso também inclui usuários de entidades governamentais.
- 3 Sistemas de risco corporativo em organizações de seguro ou resseguro**, em que os modelos de risco do Oasis são integrados usando APIs em fluxos de trabalho de precificação e gerenciamento de portfólio.



Os componentes de software são descritos abaixo e mostrados na **Figura 45** (OASIS 2024b).

- 1 Plataforma Oasis:** é um sistema de modelagem de catástrofes que inclui um conjunto de padrões de dados, uma API, além de ferramentas e componentes para criar e executar modelos. Constitui a base principal do Oasis, na qual é implementada a maior parte do código específico do domínio e realizada a otimização de desempenho.
- 2 Interface do Usuário do Oasis (UI):** é uma aplicação web usada para carregar dados de exposição, executar modelos implementados no Oasis e recuperar dados de saída. Ele é voltado para a operação de modelos em empresas de (re)seguros, em conjunto com ferramentas já existentes de gestão de exposição e relatórios. Também é útil para a avaliação de modelos e seu uso em contextos governamentais. A UI foi projetada principalmente para avaliação e teste de modelos, e não para agregações principais de carteiras de seguradoras/reasseguradoras.
- 3 Kit de Desenvolvimento de Modelos do Oasis (MDK):** é um conjunto de ferramentas para construir, calibrar e criar modelos prontos para implementação na Plataforma Oasis. Ele foi desenvolvido para desenvolvedores de modelos ou usuários acadêmicos, geralmente familiarizados com o trabalho direto com dados por meio da linha de comando ou de forma programática.
- 4 Biblioteca de Modelos do Oasis:** é um catálogo de modelos do Oasis hospedado na AWS. Ele permite realizar testes de regressão dos modelos após atualizações do código da Plataforma Oasis, bem como validar a operação e a escalabilidade dos modelos.

**Figura 45. Ecossistema do Oasis**






Fonte: OASIS (2024a).



A Plataforma Oasis pode ser acessada de várias maneiras, dependendo das necessidades do usuário. Os modelos podem ser executados por meio da Interface do Usuário do Oasis (UI) ou da Interface de Programação de Aplicações (API). A UI é uma aplicação baseada em navegador, enquanto a API permite executar os modelos diretamente a partir de outros sistemas. A Plataforma Oasis pode ser implementada em um servidor com contêineres Docker ou em servidores na nuvem, como AWS e Azure (OASIS 2024b).

Embora existam vários modelos disponíveis na Plataforma Oasis, o acesso a eles depende dos acordos estabelecidos entre o usuário e o fornecedor do modelo. É possível adicionar novos modelos à conta do usuário após a formalização desses acordos. No entanto, a maioria dos modelos está disponível por tempo limitado, para fins de avaliação, com um ambiente hospedado (OASIS 2024a).

O custo de uso do Oasis varia de acordo com os modelos, os dados usados, o tamanho da organização e o número de usuários. A seguir, apresenta-se uma estimativa aproximada dos custos de licença dos modelos mais relevantes (terremotos e furacões nos EU A, terremotos e tufões no Japão, tempestades de vento na Europa e inundações no Reino Unido) para um acordo de três anos, conforme publicado em (OASIS 2024a). Os preços indicados estão em dólares estadunidenses (US\$), não incluem gastos de hospedagem nem impostos, e devem ser considerados apenas como referência aproximada, pois estão sujeitos a variações.

 <b>Empresa de pequeno porte</b> cerca de <b>\$479,000</b>	 <b>Empresa de médio porte</b> cerca de <b>\$663,000</b>	 <b>Empresa de grande porte</b> cerca de <b>\$930,000</b>
---	---	--

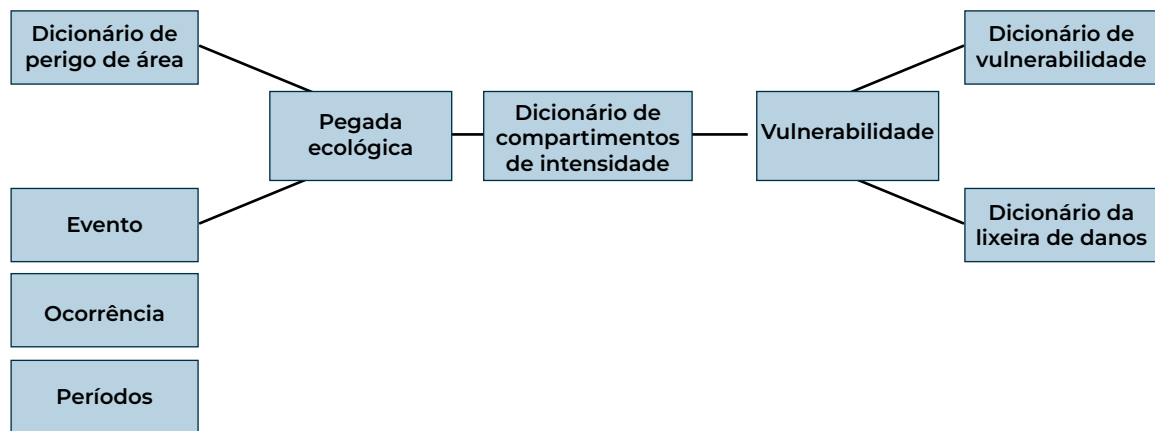
Os modelos podem ser usados gratuitamente como Modelos de Acesso Aberto quando hospedados internamente no servidor AWS do Oasis. A oferta de modelos disponíveis está em constante expansão, de acordo com a demanda e os requisitos. Os modelos iniciais disponíveis incluem os modelos de risco sísmico em nível nacional para Colômbia, África do Sul e China, desenvolvidos pela Fundação GEM (Global Earthquake Model), além do CHAZ (Modelo de Risco Climático), da Universidade de Columbia.

## A.5.2. Métodos aplicados

Um modelo no Oasis é composto pelos módulos de perigo e vulnerabilidade. Esses módulos são vinculados por uma métrica comum de intensidade e conectados aos dados de exposição usando um conjunto de identificadores abstratos: `areaperil_id` e `vulnerability_id`. A **Figura 46** mostra como os módulos de perigo e vulnerabilidade estão conectados a um modelo no Oasis (OASIS 2024b).



**Figura 46. Vinculação dos módulos de perigo e vulnerabilidade**



Fonte: OASIS (2024a)

O **Módulo de Perigo** do Oasis se baseia no arquivo “Footprint”, que descreve a interação entre os eventos e as áreas de ameaça, fornecendo uma distribuição de probabilidade de intensidade para cada combinação.

A **área de perigo** representa, de forma abstrata, uma área específica para uma determinada ameaça. Pode corresponder a qualquer tipo de área (células de uma grade, polígonos, regiões administrativas etc.). O `areaperil_id` é o identificador da área e deve ser um valor inteiro, embora o que ele representa não afete o cálculo no Oasis.

O **evento** é uma representação abstrata de um evento real ou sintético que afeta várias áreas de ameaça. Pode ser uma inundação, tempestade, terremoto etc. O `event_id` é o identificador do evento e é um valor inteiro.

A **Intensidade** representa um conjunto discretizado e abstrato de medidas de intensidade específicas para o perigo representado.

O **Módulo de Vulnerabilidade** do Oasis se baseia no arquivo “Vulnerability”, que descreve a interação entre as intensidades e os tipos de vulnerabilidade, fornecendo uma distribuição de probabilidade da taxa de dano para cada combinação.

O **Dicionário de Vulnerabilidade (Vulnerability Dictionary)** representa, de forma abstrata, diversas funções de vulnerabilidade. O `vulnerability_id` é o identificador dessa função e consiste simplesmente em um valor inteiro.

O **Dano (Damage)** representa um conjunto discretizado e abstrato de taxas de dano.



A parte final da definição de dados do modelo no Oasis é o arquivo de **Ocorrências**. Ele detalha as ocorrências de eventos ao longo do tempo e é usado em resultados baseados no tempo. Uma extensão opcional do arquivo de Ocorrências é o arquivo de **Períodos**, que permite atribuir um peso às ocorrências.

O módulo de perigo, o módulo de vulnerabilidade e as definições de ocorrências são combinados com uma definição comum de intervalos de intensidade, criando uma representação completa do modelo no Oasis.

A UI do Oasis permite ao usuário gerar vários relatórios de saída. O núcleo do Oasis usa uma simulação de Monte Carlo, que gera amostras aleatórias da distribuição de perdas. O número de amostras é definido pelo usuário e o nível de convergência alcançado nesse conjunto varia de acordo com o modelo, o portfólio e os resultados desejados.

O cálculo de perdas é composto por duas etapas: 1) cálculo das distribuições de probabilidade e 2) método de amostragem.

O termo *effective damageability* se refere ao método usado para construir as distribuições de probabilidade.

Os arquivos de entrada do modelo para esta etapa do cálculo são:

➔ *footprint*

➔ *vulnerability*

A incerteza da intensidade do perigo é representada nos dados de *footprint*, enquanto a incerteza de dano dada a intensidade do perigo é representada nos dados de *vulnerability*. Ambos os tipos de incerteza são expressos como distribuições de probabilidade discretas.

O dano efetivo é calculado durante a análise por meio da combinação (*convolving*) da distribuição de intensidade do perigo com a distribuição de dano condicional.

Em termos gerais, a distribuição de dano efetivo calculada representa tanto a incerteza na intensidade do perigo quanto o nível de dano associado a essa intensidade.

No entanto, é comum em alguns modelos que a distribuição de incerteza do perigo não esteja presente no arquivo *footprint*. Nesses casos, cada *areaperil* (que representa uma área ou célula geográfica) no *footprint* é atribuída a um único intervalo de intensidade do perigo, com probabilidade igual a 1. Nessa situação, a distribuição de dano efetivo ainda é gerada, mas idêntica à distribuição de probabilidade de dano condicional constante no arquivo *vulnerability* para um único intervalo de intensidade.



No método de *effective damageability*, sempre é feita uma amostragem da distribuição de dano efetivo; contudo, as fontes de incerteza representadas podem envolver apenas o dano ou uma combinação de incerteza na intensidade do perigo e no dano, dependendo dos arquivos do modelo.

Os métodos de Monte Carlo são uma ampla classe de algoritmos computacionais que se baseiam em amostragem aleatória repetida para obter resultados numéricos. O núcleo do Oasis (ktools) realiza a amostragem de Monte Carlo das perdas brutas a partir das distribuições de probabilidade de dano efetivo, gerando números aleatórios.

A distribuição de probabilidade é fornecida pelo cálculo de *effective damageability* descrito acima, e os intervalos de dano são especificados por um terceiro arquivo de entrada do modelo, o *damage bin dictionary*.

### A.5.3. Abordagem matemática

No processo de cálculo de risco no OASIS LMF, a primeira etapa é gerar um conjunto de eventos representativos de todos os possíveis eventos que podem ocorrer, juntamente com sua intensidade e probabilidade em um período de tempo suficientemente longo para cobrir uma distribuição completa, até mesmo dos eventos mais extremos. Costuma-se usar uma simulação de 10 mil anos. Cada evento tem uma probabilidade de ocorrer dentro do período simulado (Oasis LMF 2024).

Para cada evento, é gerada uma pegada de ameaça (*footprint*), que contém um indicador de ameaça – como intensidade, velocidade do vento, profundidade da inundação etc. – associado aos danos usando uma curva de vulnerabilidade (Oasis LMF 2024).

As curvas de vulnerabilidade relacionam o indicador de ameaça com um índice médio de dano (MDR, na sigla em inglês), que representa a proporção do valor total (por exemplo, o gasto de reposição) que se perderia para o ativo analisado. Na prática, os elementos expostos apresentam alta variabilidade nos danos provocados pela mesma ameaça, devido a fatores desconhecidos ou não modeláveis, mesmo quando se encontram muito próximos entre si. Essa variabilidade é considerada usando uma distribuição de incerteza em torno do índice médio de dano em cada ponto de ameaça, também conhecida como incerteza secundária (Oasis LMF 2024).

O cálculo de perdas constitui a parte central do núcleo de ferramentas *ktools* do Oasis LMF. Para esse cálculo, as probabilidades definidas nos arquivos de pegada de ameaça (*footprint*) e de vulnerabilidade são usadas em conjunto. Essas probabilidades são representadas pelos subíndices *i* e *d*, indicando que a incerteza está associada, respectivamente, à intensidade e ao dano (Blass 2021):

#### Equação 14

$$P_{id} = p_i^f * p_d^v$$



Em que:

$P_{id}$  é a probabilidade de que ocorra uma intensidade  $i$  e provoque um dano  $d$ .

$p_i^v$  é a massa de probabilidade correspondente ao intervalo de intensidade.

$p_d^v$  é a massa de probabilidade correspondente ao intervalo de dano.

O cálculo de  $p_{id}$  é realizado para cada combinação de evento, área de perigo (*peril*) e função de vulnerabilidade. Em seguida, o valor de  $p_{id}$  é somado ao longo dos intervalos de intensidade.

### Equação 15

$$P_d = \sum_i P_{id}$$

O resultado é  $p_d$ , que representa a probabilidade de um intervalo de dano  $d$  para cada evento, área de perigo e função de vulnerabilidade.

Como a distribuição de probabilidade é discreta, os valores podem ser somados para construir uma Função de Distribuição Acumulada (CDF), o que é feito no executável *getmodel*. Essa soma sobre os intervalos de intensidade e de dano gera uma CDF para cada combinação de evento, área de perigo e função de vulnerabilidade.

Há duas abordagens possíveis para calcular as perdas (Blass 2021):

#### 1. Integração determinística

Nesse método, a distribuição da probabilidade de dano calculada é integrada para obter o chamado fator de dano. Esse fator, multiplicado pelo valor total segurado, resulta na perda:

### Equação 16

$$\chi_{EY} = tiv_Y * d_{EY}$$

Em que:

$\chi_{EY}$  é a perda em um evento  $\epsilon$  e a cobertura  $Y$ .

$tiv_Y$  é o valor total segurado.

$d_{EY}$  é o fator de dano.

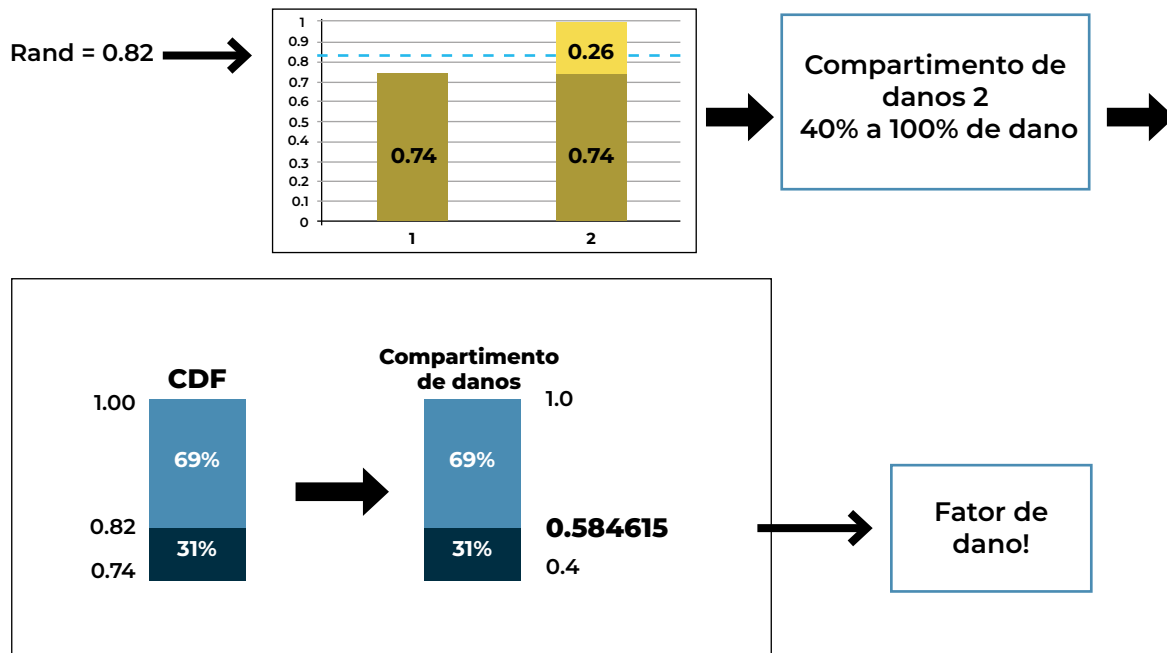
Esse método não fornece um desvio padrão, pois a integração não permite cálculos de incerteza.



## 2. Amostragem aleatória (Monte Carlo)

Nesse método, o mesmo processo é seguido até o cálculo da CDF. Em seguida, em vez de integrar, um gerador de números aleatórios é usado para selecionar um valor entre 0 e 1. Conforme ilustrado na **Figura 47**, se o número aleatório gerado for 0,82, ele estará localizado em um intervalo de dano específico (por exemplo, intervalo 2). Em seguida, dentro desse intervalo, é calculada uma proporção específica (por exemplo, 31%), resultando em um **fator de dano** (0,584615 no exemplo). Por meio desse processo, um valor de dano é selecionado em um intervalo de valores possíveis na amostra. Por fim, como na equação anterior, a multiplicação desse fator pelo valor total segurado fornece a perda correspondente a essa amostra.

**Figura 47. Ilustração gráfica da abordagem de amostragem para o cálculo de perdas**



Fonte: Blass (2021) Um número aleatório é selecionado e usado para amostrar a Função de Distribuição Acumulada (CDF). Isso permite determinar o intervalo de dano correspondente. Em seguida, aplicando a mesma proporção dentro desse intervalo de dano, obtém-se o fator de dano da amostra.



O módulo financeiro calcula as perdas após considerar o impacto das condições das apólices das companhias de seguros, a fim de determinar a perda líquida pela qual a entidade (re)seguradora será responsável. A companhia de (re)seguros insere uma lista de todas as apólices subscritas, contendo informações sobre a localização e as características do risco, como o tipo de ocupação, a antiguidade, o material de construção, a altura do edifício e o gasto de reposição, bem como os termos e condições da apólice. O modelo de catástrofe executa então todo o conjunto de eventos sobre o portfólio, calculando a perda de cada evento no modelo para cada apólice. Isso gera uma tabela de perdas por evento. Essas perdas por evento são posteriormente ordenadas por magnitude, do maior para o menor, para gerar a Curva de Excedência de Perdas para os anos simulados pelo modelo (Oasis LMF, 2024).

#### A.5.4. Avanços recentes e inovações

Nos últimos anos, o Oasis trabalhou na padronização de dados abertos para melhorar a interoperabilidade e a eficiência no setor de seguros. Também foi lançado o **Oasis Risk Explorer**, uma ferramenta de modelagem de riscos para produtos de seguros paramétricos, especialmente projetada para países vulneráveis e de baixa renda. Além disso, o software **Enterprise Oasis** está nas fases finais de teste. Essa ferramenta permitirá a distribuição do trabalho entre várias máquinas na nuvem, reduzindo significativamente os tempos de execução de modelos complexos.

#### A.5.5. Comunidade de desenvolvimento

O Oasis é apoiado por uma comunidade diversa, que inclui desenvolvedores de modelos independentes, seguradoras, resseguradoras, corretoras e governos. A plataforma é financiada com taxas de associação de membros e comissões sobre os modelos licenciados. Além disso, colabora com diversas organizações, como o Insurance Development Forum (IDF) e o Escritório das Nações Unidas para a Redução do Risco de Desastres (UNDRR), em iniciativas de interoperabilidade e projetos de exposição mundial (OASIS 2024b). O repositório no GitHub é: <https://github.com/OasisLMF>.

#### A.5.6. Limitações

Embora o Oasis ofereça grande flexibilidade e acesso a modelos de catástrofes, há custos associados decorrentes do uso dos modelos fornecidos por diferentes empresas.

#### A.5.7. Casos de uso

O Oasis é amplamente usado no setor de seguros e resseguros para avaliar riscos de catástrofes e desenvolver produtos de seguros paramétricos. Um caso notável é o uso de modelos condicionados pelo clima, como o modelo do Danúbio, desenvolvido pelo Instituto de Potsdam, e outros modelos semelhantes criados pelas empresas JBA e Fathom. Esses modelos ajudam as seguradoras a compreender melhor o impacto das mudanças climáticas sobre os riscos catastróficos. O **Quadro 5** mostra um estudo de caso em que o CLIMADA e o Oasis foram usados.

## Estudo de caso: furacão Matthew



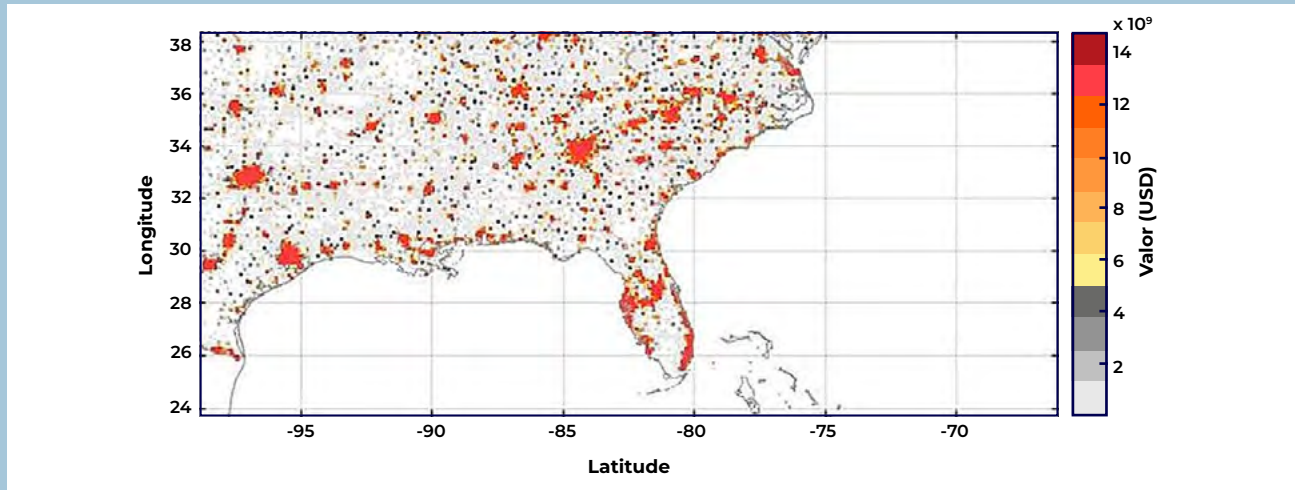
Este estudo de caso examina os impactos de diferentes parâmetros usados em modelos de perda aplicados ao furacão Matthew, usando dados de previsão do ECMWF e as ferramentas de código aberto CLIMADA e Oasis LMF. A análise avalia a influência de variáveis como o raio de ventos máximos (RMW), valores de ativos e curva de vulnerabilidade nas estimativas de perda.

A avaliação usou previsões do furacão Matthew para três datas diferentes (29 de setembro, 4 de outubro e 7 de outubro de 2016), analisando a trajetória e a intensidade em relação aos danos estimados. Os testes foram realizados variando o RMW, redistribuindo os valores dos ativos e alterando a forma da curva de vulnerabilidade. A implementação de uma distribuição beta para modelar incertezas secundárias também foi considerada.

A modificação do RMW levou a resultados semelhantes aos da função original, mas com um leve aumento nos valores. Para a previsão de 4 de outubro, o impacto do aumento do raio para 370 km foi menor do que o observado nas previsões anteriores. Para a previsão de 7 de outubro, a influência de um RMW fixo de 3 km foi significativamente maior, reduzindo as perdas em três ordens de magnitude, enquanto um RMW de 370 km aumentou as perdas em duas ordens de magnitude. A análise revelou que a proximidade das trajetórias à costa dos EUA, onde os ativos estão concentrados, amplifica as perdas.

Os resultados confirmam que o RMW está diretamente relacionado à intensidade dos ciclones tropicais. Estudos anteriores (Emanuel 1989; Carrasco et al. 2014) corroboram a correlação negativa entre o tamanho do olho do ciclone e sua intensificação. Por exemplo, ciclones compactos, como o furacão Matthew em seus estágios iniciais, apresentam maior intensificação devido à redução do RMW.

Os valores de ativos no CLIMADA são baseados em imagens de satélite de luz noturna ajustadas ao PIB e redistribuídas de acordo com a densidade populacional (veja a figura abaixo). Quando testadas com valores médios redistribuídos, as perdas diminuíram ligeiramente devido à redução dos valores em regiões de alta densidade e ao aumento dos valores em áreas menos densas. Esse efeito foi particularmente evidente ao implementar um RMW de 3 km, diminuindo ainda mais as perdas devido à menor probabilidade de impactar áreas densamente povoadas.



A curva padrão do CLIMADA é uma função logística com um máximo de 40%. Os testes com funções lineares e escalonadas apresentaram resultados com alta variabilidade. A função linear aumentou as perdas devido à inclusão de danos em velocidades mais baixas, enquanto a função escalonada reduziu as perdas, restringindo os danos a velocidades acima de 80 m/s. Para as previsões de 29 de setembro e 4 de outubro, a função escalonada não resultou em perdas, dada a baixa intensidade do furacão.

Entre os parâmetros testados, o RMW teve o maior impacto sobre as perdas. As trajetórias influenciam significativamente os resultados, principalmente em previsões como a de 29 de setembro, em que a maioria dos ciclones afeta o Caribe, resultando em perdas menores. O aumento do RMW aumenta a probabilidade de impacto em áreas de maior valor, amplificando as perdas. Por outro lado, a realocação de ativos reduz as perdas totais ao redistribuir os valores de forma mais uniforme.

O estudo confirma que o RMW é a variável mais importante na previsão de perdas, diretamente correlacionada com a intensidade do ciclone. A integração dos modelos CLIMADA e Oasis LMF provou ser eficaz, com uma forte correlação entre os resultados. Melhorias nas previsões de intensidade e tamanho dos ciclones podem refinar as estimativas de perda, principalmente com a maior inclusão de fatores ambientais que influenciam o RMW, como a estabilidade inercial e os fluxos de entropia na superfície. Além disso, a inclusão de fatores como o tamanho do núcleo externo dos ciclones ampliaria a compreensão dos impactos associados, oferecendo previsões mais abrangentes e úteis para a mitigação e o planejamento de riscos.

Fonte: König (2017)



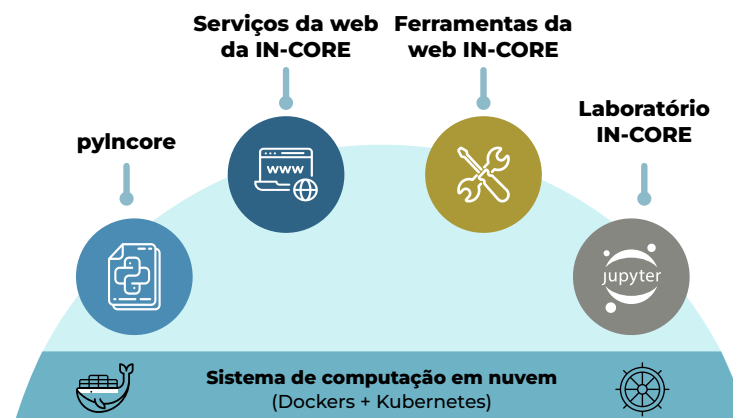
## A.6. INTERDEPENDENT NETWORKED COMMUNITY RESILIENCE MODELING ENVIRONMENT IN-CORE

### A.6.1. Descrição geral

O Interdependent Networked Community Resilience Modeling Environment (IN-CORE) é um software desenvolvido pela Universidade Estadual do Colorado para avaliar e melhorar a resiliência de infraestruturas e comunidades diante de desastres. Qualquer ameaça pode ser analisada, desde que possa ser representada como um objeto de perigo e seja possível associar curvas de fragilidade aos elementos expostos. Na ferramenta web Hazard Viewer, é possível visualizar exemplos de objetos de perigo para terremotos, tornados, furacões e inundações. O IN-CORE integra modelos de simulação e análise de dados para fornecer uma compreensão abrangente de como diferentes tipos de infraestrutura respondem às ameaças. A plataforma IN-CORE é executada em um cluster Kubernetes com tecnologia de contêineres Docker (IN-CORE, 2024).

Na plataforma IN-CORE, os usuários podem realizar análises que modelam o impacto dos desastres e avaliar a resiliência e a recuperação das comunidades. A plataforma é composta por IN-CORE Lab, PyIncore, ferramentas web e serviços web (consulte a **Figura 48**). Os recursos – como conjuntos de dados de exposição, curvas de fragilidade, arquivos de ameaças, entre outros – fornecidos pela comunidade científica, são armazenados nos servidores do IN-CORE, no National Center for Supercomputing Applications (NCSA), e podem ser integrados de forma fluida para permitir que os usuários otimizem o planejamento da resiliência a desastres e as estratégias de recuperação pós-desastre (IN-CORE, 2024). O usuário deve ter uma conta do IN-CORE registrada no serviço da plataforma. Essa conta permite acessar todos os dados públicos do sistema e criar dados privados, acessíveis apenas a ele.

**Figura 48. Componentes do IN-CORE**



Fonte: IN-CORE (2024).



O **PyIncore** é um pacote no Python composto por três componentes principais: 1) um conjunto de classes de serviço para interagir com os serviços web do IN-CORE, descritos a seguir, 2) análise IN-CORE e 3) visualização. O PyIncore permite aos usuários analisar os riscos para a infraestrutura em áreas selecionadas, propagando os efeitos dos danos físicos e da perda de funcionalidade para estimar impactos sociais e econômicos.

Os **serviços web do IN-CORE** são desenvolvidos em Java, com base na especificação JAX-RS, e incluem: um serviço de ameaças, um serviço DFR3 (danos, funcionalidade, reparação, recuperação e restauração), um serviço de dados, um serviço de visualização geoespacial, um serviço semântico, e um serviço espacial. Esses serviços permitem aos usuários criar e acessar ameaças, fragilidades e dados. Os usuários podem acessá-los e usá-los por meio do PyIncore e das ferramentas web do IN-CORE.

O **IN-CORE Web Tools** é um conjunto de visualizadores web para interagir com os diferentes serviços web do IN-CORE. Esses visualizadores permitem aos usuários navegar e pesquisar conjuntos de dados, ameaças, curvas de fragilidade, curvas de reparação, entre outros; além de visualizar metadados e baixar elementos permitidos.

O **IN-CORE Lab** é um ambiente Jupyter personalizado, com o PyIncore instalado e hospedado em um sistema de nuvem do NCSA. Ele permite que os usuários desenvolvam, executem e testem seus modelos científicos com o PyIncore em seu próprio espaço de trabalho.

A plataforma IN-CORE pode incorporar dados gerados pela comunidade, permitindo que os usuários otimizem o planejamento da resiliência comunitária a desastres e as estratégias de recuperação pós-desastre, de forma inteligente, usando modelos de sistemas físicos interdependentes combinados com sistemas socioeconômicos.

Os recursos – como conjuntos de dados de inventário, fragilidades e arquivos de ameaças – fornecidos pela comunidade científica, são armazenados nos servidores do IN-CORE, no NCSA, e podem ser integrados sem interrupções, possibilitando a otimização da resiliência a desastres e recuperação comunitária pós-desastre.

Para usar o IN-CORE e o PyIncore, é necessário instalar o Miniconda, ferramenta de gerenciamento de ambientes Python, e em seguida instalar o Jupyter Notebook e a biblioteca PyIncore.

O pacote de visualização associado ao PyIncore é o pyIncore-viz. Ele contém módulos avançados do Python e os métodos necessários para visualizar e divulgar os resultados do IN-CORE, principalmente por meio do Jupyter Notebook. A biblioteca Matplotlib, usada para criar visualizações estáticas no Python, já está incluída no PyIncore como padrão.



## A.6.2. Métodos aplicados

O IN-CORE usa as seguintes etapas nas análises de resiliência: (1) caracterizar o estado atual de uma comunidade, incluindo suas vulnerabilidades; (2) simular cenários de perigo e os impactos resultantes sobre os sistemas comunitários – como danos, deslocamento populacional, perda de funções e recuperação funcional – a fim de explorar opções de políticas que fortaleçam a resiliência; e (3) realizar o cálculo da estabilidade comunitária (CSA, na sigla em inglês), com base em métricas de resiliência comunitária (CRM, na sigla em inglês), referentes às funções físicas, sociais e econômicas de uma comunidade, que fornecem indicadores de resiliência em determinado momento, em relação aos objetivos de resiliência (van de Lindt et al. 2023).

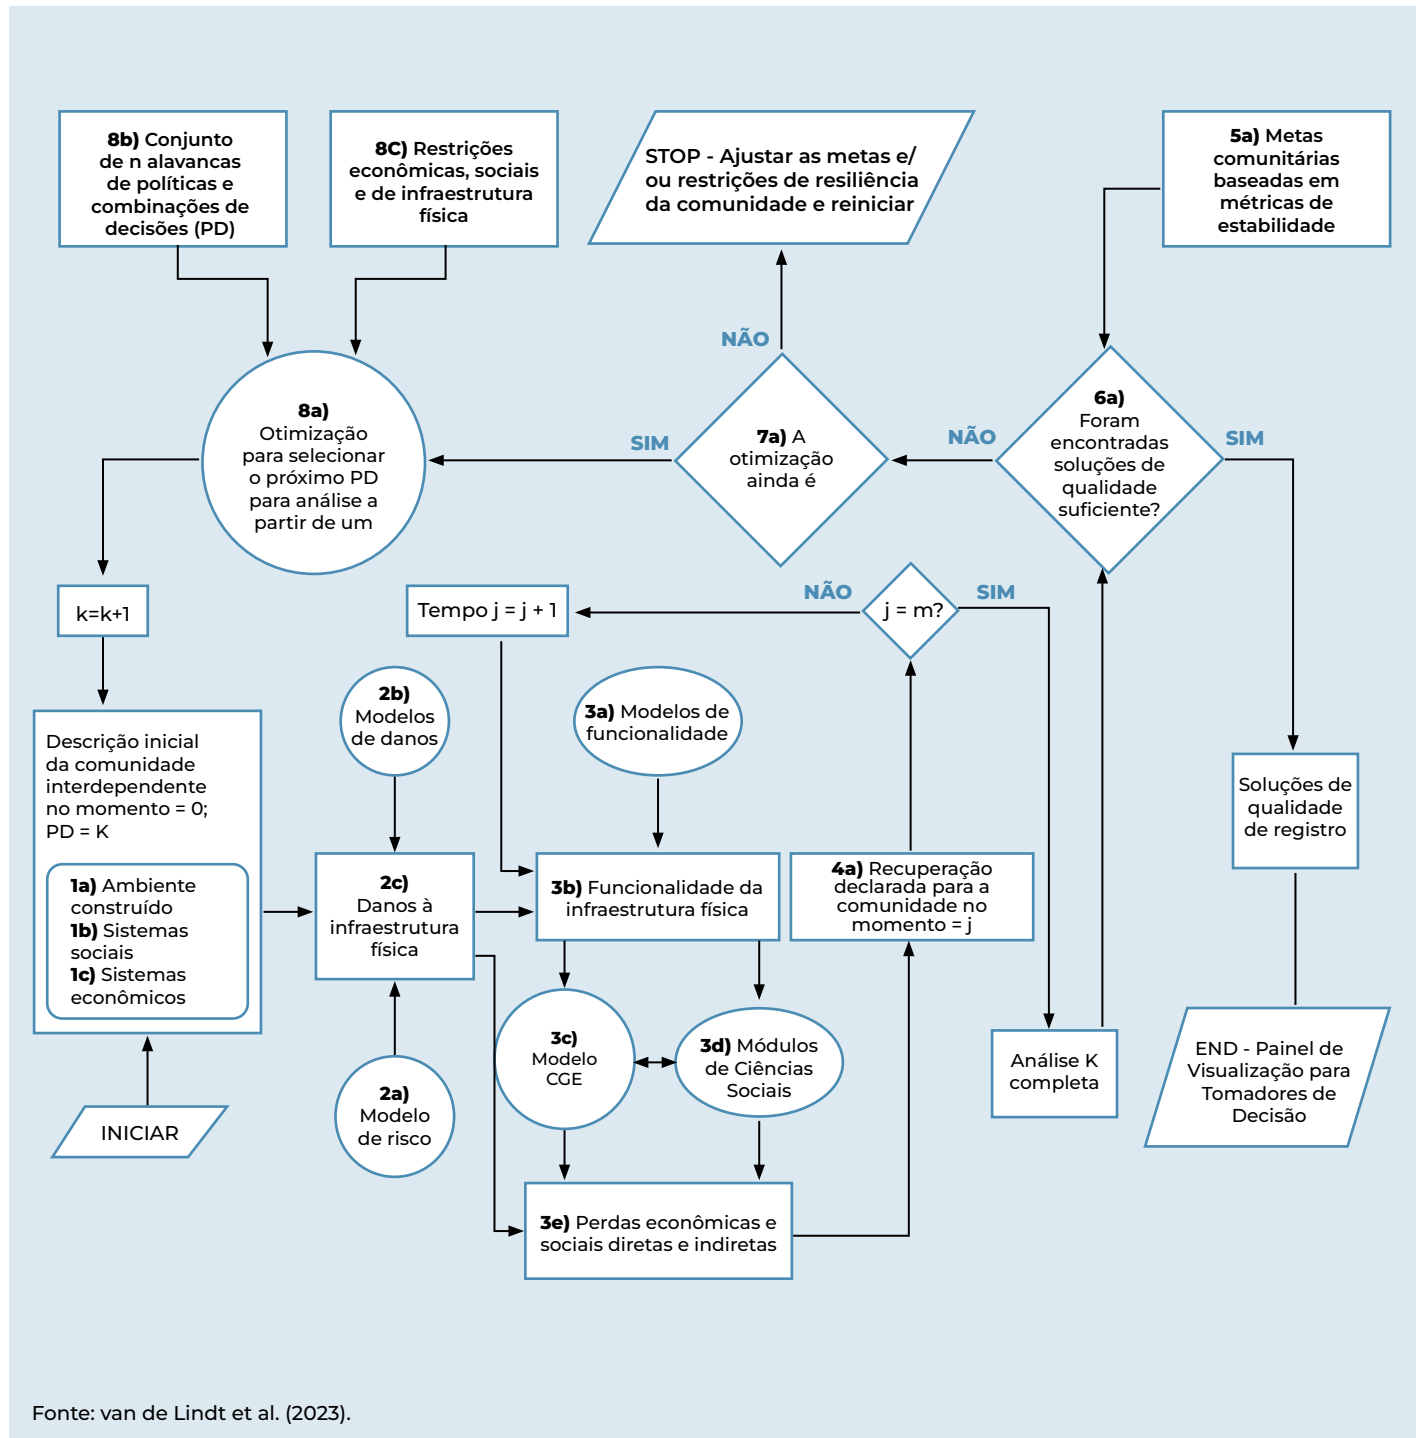
Os algoritmos científicos implementados no IN-CORE são mostrados no fluxograma conceitual da **Figura 49**, grande parte dos quais foi concluída durante os primeiros cinco anos de desenvolvimento (van de Lindt et al. 2023).



Imagem: Flickr - BID Ciudades sostenibles / Santa Marta, Colombia



**Figura 49. Fluxograma conceitual dos algoritmos do IN-CORE**





O sistema IN-CORE é organizado em diversos módulos interdependentes que permitem descrever, analisar e planejar a resiliência de uma comunidade, integrando informações de infraestrutura, sistemas sociais e sistemas econômicos. O módulo de Descrição da Comunidade Interdependente, localizado na parte inferior esquerda do esquema **Figura 49**, é composto por três componentes principais: o ambiente construído, os sistemas sociais e os sistemas econômicos. O componente de ambiente construído reúne dados espaciais, geralmente em formato de sistemas de informação geográfica (GIS), que incluem pegadas de edificações, infraestruturas como redes de eletricidade, água e gás, além da rede de transporte. Esse módulo descreve como essas infraestruturas se inter-relacionam com as edificações, facilitando a conexão entre os diferentes sistemas comunitários. Os sistemas sociais incluem dados sobre a população e os domicílios, que são associados a edificações específicas, oferecendo informações detalhadas sobre características demográficas (como idade, sexo, educação e ocupação) e vinculando as pessoas a instituições sociais e locais de trabalho. Esses dados provêm de fontes públicas, como o Censo dos Estados Unidos e o American Community Survey. O componente de Sistemas Econômicos descreve a distribuição espacial dos empregos e das indústrias e usa modelos de Equilíbrio Geral Computável (CGE) para simular as interações entre famílias, empresas e governo local na geração da atividade econômica. Esse modelo considera dados sobre renda, estrutura ocupacional e indicadores da força de trabalho, oferecendo uma visão integrada da economia local.

Já o módulo de Dano à Infraestrutura Física combina dados do ambiente construído com modelos de perigo e modelos de dano para avaliar como os desastres afetam as infraestruturas. Os modelos de perigos podem ser de dois tipos: Nível 1, que simulam ameaças como terremotos, furacões, inundações e tornados, usando conjuntos de dados internos do IN-CORE; e Nível 2, que permitem simulações mais avançadas, nas quais as ameaças são fornecidas pelo usuário. Esses modelos usam funções de fragilidade para estimar o dano esperado em função da intensidade da ameaça. O processo também pode considerar danos causados por fenômenos em cascata, como a interação entre vento e maré de tempestade em furacões ou o dano combinado de terremoto e tsunami.

O módulo de Funcionalidade da Infraestrutura Física avalia a capacidade das edificações e de outros componentes de infraestrutura de manter suas funções após um desastre, conforme o nível de dano observado. Essa avaliação é realizada com modelos de funcionalidade, que determinam se uma infraestrutura pode continuar operando conforme sua função original. Esses modelos podem ser definidos pelo usuário e consideram a disponibilidade de serviços essenciais, como água e eletricidade. Os resultados dessa análise são usados no modelo CGE para estimar os impactos econômicos dos danos, com base na condição das edificações e da infraestrutura funcional, além de dados sociais e econômicos.

O módulo de Recuperação Comunitária analisa como a comunidade se recupera ao longo do tempo, avaliando tanto a recuperação física das edificações quanto a restauração da estabilidade social e econômica. Esse módulo usa modelos de recuperação de moradias e outras infraestruturas, que consideram políticas de financiamento e estatísticas de reconstrução. Essa análise permite acompanhar a evolução da recuperação em diferentes áreas e ajustar estratégias de intervenção conforme o progresso.



Por fim, o módulo de Soluções e Otimização avalia a efetividade de diferentes políticas de resiliência. Este módulo compara várias estratégias de mitigação e resposta a desastres, levando em conta as restrições financeiras e sociais da comunidade. Por meio dessa análise, o IN-CORE auxilia tomadores de decisão a identificar as melhores opções para aumentar a resiliência comunitária, seja pela redução de riscos, seja pela melhoria da capacidade de resposta a desastres. Os resultados do sistema fornecem informações estratégicas para otimizar o uso de recursos e desenvolver estratégias eficazes de resiliência.

Além disso, o IN-CORE é capaz de propagar a incerteza nas previsões sobre as características dos domicílios em nível de edificação, bem como nas projeções de estabilidade populacional. A incerteza é propagada usando simulação de Monte Carlo (MCS), o que permite ao analista gerar amostras de ameaças, alocações de população sintética ou outros cenários, desde que as estatísticas subjacentes sejam conhecidas (van de Lindt et al. 2023).

As análises incorporadas na plataforma estão resumidas na **Tabela 38**.


**Tabela 38. Análises incorporadas na plataforma IN-CORE**

Tipo de análise	Descrição
<b>Dano em pontes</b>	<p>Essa análise calcula o dano em pontes com base em um tipo específico de perigo. Atualmente, são considerados os terremotos, tsunamis, tornados e furacões.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras infraestruturas. Primeiro, obtém-se uma curva de fragilidade de acordo com o tipo de perigo e as características da ponte. Com base nessa curva, calcula-se a intensidade da ameaça na localização da estrutura. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de terremotos, se o conjunto de dados da ponte incluir informações sobre o solo, o valor médio da fragilidade pode ser ajustado para considerar os efeitos de liquefação no dano.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>
<b>Recuperação de conjuntos de edificações</b>	<p>O código gera dois arquivos de saída: <i>building-recovery.csv</i> e <i>cluster-recovery.csv</i>.</p>
<b>Dano em edificações</b>	<p>Essa análise calcula o dano em edificações com base em um tipo específico de perigo. Atualmente, são considerados os terremotos, tsunamis, tornados, furacões e inundações.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras infraestruturas. Primeiro, obtém-se uma curva de fragilidade de acordo com o tipo de perigo e as características da edificação. Com base nessa curva, calcula-se a intensidade da ameaça na localização da estrutura. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de um terremoto, podem ser usadas as informações sobre o solo para ajustar as probabilidades de dano e considerar os efeitos da liquefação.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>
<b>Perda econômica em edificações</b>	<p>Essa análise calcula a perda econômica em edificações com base no valor de avaliação da edificação, no dano médio e em um multiplicador de inflação. O usuário deve informar a taxa de inflação (em percentual) entre o ano de avaliação e o ano de referência (atual, data do evento etc.), além de um multiplicador opcional de ocupação. A análise pode ser aplicada aos resultados de dano médio da edificação em componentes estruturais, não estruturais sensíveis ao deslocamento, não estruturais sensíveis à aceleração ou danos em conteúdos.</p> <p>O resultado dessa análise é um arquivo CSV contendo as perdas estruturais baseadas no dano.</p>
<b>Funcionalidade de edificações</b>	<p>A análise de funcionalidade de edificações calcula as probabilidades de funcionalidade considerando duas situações: que as edificações se encontram em um estado de dano igual ou superior ao nível 2; ou que as edificações não estão danificadas, mas não têm acesso à energia elétrica. Presume-se que a disponibilidade de energia elétrica dependa da interdependência entre edificações e subestações, e entre edificações e postes próximos.</p> <p>Se tanto o poste mais próximo da edificação quanto a subestação da qual ela depende estiverem funcionais, considera-se que a edificação pode receber energia elétrica.</p> <p>Os resultados dessa análise são: 1) um arquivo CSV com amostras de probabilidades de funcionalidade para comparação direta com saídas de probabilidade de estado-limite de Monte Carlo; e 2) um arquivo CSV adicional com as probabilidades de funcionalidade consolidadas.</p>



Tipo de análise	Descrição
<b>Dano não estrutural em edificações</b>	<p>Essa análise calcula o dano não estrutural em edificações com base em um tipo específico de perigo. Atualmente, são considerados os terremotos, inundações e furacões.</p> <p>O processo é semelhante ao da avaliação de outros danos estruturais. As probabilidades de dano são obtidas a partir de curvas de fragilidade e de uma definição de perigo. Cada local de edificação possui um PGA (aceleração máxima do solo), que representa a medida da ameaça sísmica para cada cenário. Também é possível considerar o efeito da liquefação, definido como uma alteração nas condições de tensão que faz com que um material normalmente sólido se comporte como líquido. Os valores do Fator de Modificação de Liquefação (LMF) são aplicados como fatores multiplicativos aos valores médios de fragilidade e devem constar no conjunto de dados. Essa análise pode incluir diferentes tipos de curvas de fragilidade atribuídas à edificação: sensíveis à aceleração (AS) e sensíveis ao deslocamento (DS).</p> <p>O código abrange fragilidades normais e lognormais com três estados-limite, gerando um arquivo CSV com os estados de dano correspondentes. O segundo arquivo de saída é um JSON com</p>
<b>Dano estrutural em edificações</b>	<p>Essa análise calcula o dano estrutural em edificações com base em um tipo específico de perigo. Atualmente, são considerados os terremotos, tsunamis, tornados, furacões e inundações.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras infraestruturas. Primeiro, obtém-se uma curva de fragilidade de acordo com o tipo de perigo e as características da edificação. Com base nessa curva, calcula-se a intensidade da ameaça na localização da estrutura. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de um terremoto, podem ser usadas as informações sobre o solo para ajustar as probabilidades de dano e considerar os efeitos da liquefação.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>
<b>Decisão de compra de propriedades</b>	<p>Essa análise auxilia na identificação de propriedades candidatas à compra e permite que profissionais e pesquisadores avaliem os possíveis resultados de equidade de sua seleção sob diferentes cenários.</p> <p>O resultado dessa análise é um arquivo CSV com as edificações que devem ser consideradas para compra, conforme os critérios estabelecidos. Isso pode ajudar profissionais locais a identificar propriedades candidatas para aquisição e permite que especialistas e pesquisadores avaliem os possíveis resultados de equidade de suas escolhas.</p>
<b>Choques de capital</b>	<p>Essa análise agrega os estados de funcionalidade das edificações e calcula as perdas totais de capital por setor.</p> <p>O choque do estoque de capital para uma edificação individual é igual à probabilidade de funcionalidade multiplicada pelo valor da edificação. Isso representa a perda do estoque de capital imediatamente após um desastre. A análise agrupa cada uma dessas perdas individuais de acordo com seu setor econômico associado e calcula a perda total do estoque de capital para esse setor específico.</p> <p>O resultado dessa análise é um arquivo CSV com as perdas de edificações agregadas por setor e a perda total calculada do estoque de capital.</p>
<b>Dano combinado de edificações por vento, ondas e maré de tempestade</b>	<p>Essa análise determina o estado máximo de dano geral das edificações resultante de ventos, inundações e ondas.</p> <p>Os resultados dessa análise são um arquivo CSV com o estado máximo de dano de cada ameaça e o dano máximo geral, além de um arquivo CSV com as probabilidades de dano combinadas das três ameaças.</p>



Tipo de análise	Descrição
<b>Perda combinada de edificações por vento, ondas e maré de tempestade</b>	<p>Essa análise determina a perda total de edificações devido aos danos causados por vento, inundação e ondas.</p> <p>O resultado é um arquivo CSV com os componentes individuais de perda estrutural e de conteúdo, bem como a perda total.</p>
<b>Recuperação de edificações comerciais</b>	<p>Essa análise calcula o tempo de recuperação necessário para cada edificação comercial, desde qualquer estado de dano até a restauração completa. Atualmente, os perigos considerados são os tornados.</p> <p>A metodologia adota uma abordagem de simulação de Monte Carlo em várias camadas e determina o tempo de recuperação em duas etapas, que incluem tanto o período de atraso quanto o período de reparo. O modelo de atraso foi adaptado com base na estrutura REDi e calcula os resultados finais a partir de fatores que dificultam a recuperação, como inspeção pós-desastre, solicitações de seguro, financiamento e licenças governamentais. O modelo de reparo segue a abordagem FEMA P-58 e é controlado por funções de fragilidade.</p> <p>O resultado dessa análise é um arquivo CSV com as probabilidades de recuperação por etapas no nível de edificação.</p>
<b>Dano acumulado em edificações</b>	<p>Essa análise calcula o dano em edificações com base em um tipo específico de perigo. O processo de cálculo do dano estrutural é realizado externamente e os resultados para terremotos e tsunamis são importados para a análise. Em seguida, são calculados os intervalos de dano a partir dos estados-limite combinados.</p> <p>O resultado dessa análise é um arquivo CSV com as probabilidades de danos.</p>
<b>Dano em instalações de energia elétrica</b>	<p>Essa análise calcula o dano em instalações de energia elétrica dependendo de um tipo específico de perigo. Atualmente, os perigos considerados são os terremotos, tsunamis, tornados e furacões.</p> <p>O processo de cálculo do dano estrutural é semelhante ao aplicado a outras infraestruturas. Primeiro, obtém-se uma fragilidade de acordo com o tipo de perigo e as características da instalação elétrica. Com base nessa fragilidade, calcula-se a intensidade da ameaça na localização da instalação. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de um terremoto, podem ser usados dados geotécnicos do solo para ajustar as probabilidades de dano e incorporar os efeitos de liquefação.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>
<b>Custo de reparo das instalações de energia elétrica</b>	<p>Essa análise estima os custos de reparo das instalações elétricas para diferentes cenários de simulação, com base em seus estados de dano, custos de substituição e taxas de dano.</p>
<b>Restauração de instalações de energia elétrica</b>	<p>Essa análise calcula o tempo de reparo e a variação percentual na funcionalidade de uma instalação de energia elétrica ao longo do tempo, com base em curvas de restauração de entrada.</p> <p>As curvas de restauração são determinadas conforme o tipo de perigo e a categoria da instalação elétrica (por exemplo, subestações de baixa tensão, grandes usinas de energia etc.). Com base na curva de restauração aplicável, obtém-se o percentual de variação da funcionalidade ao longo do tempo. Também é possível calcular o tempo de reparo em diferentes níveis de variação percentual da funcionalidade, invertendo a função de restauração.</p>



Tipo de análise	Descrição
<b>Análise da funcionalidade das redes de energia elétrica (EPN)</b>	<p>Essa análise calcula a funcionalidade das redes de energia elétrica.</p> <p>O cálculo usa entradas de uma análise de falhas Monte Carlo, considerando informações sobre danos às instalações de energia elétrica, bem como a topologia da rede elétrica, para determinar a probabilidade de funcionalidade e os estados de falha da rede com um análise de acessibilidade.</p> <p>O resultado dessa análise é um arquivo CSV com as probabilidades de funcionalidade das instalações elétricas e outro com os estados de falha de funcionalidade.</p>
<b>Métrica de equidade</b>	<p>O algoritmo calcula métricas de equidade para caracterizar a desigualdade na provisão de serviços de infraestrutura entre dois grupos de interesse (por exemplo, população de baixa renda versus não baixa renda; minorias versus não minorias etc.). Essas métricas se baseiam no índice T de Theil, indicador amplamente usado para medir a desigualdade na distribuição de recursos escassos (por exemplo, a renda). As métricas também podem ser aplicadas para avaliar a inequidade em diferentes cenários, considerando outros recursos de interesse.</p> <p>Para seu cálculo, define-se e quantifica-se um recurso escasso dentro de uma aplicação de infraestrutura. Esse recurso pode ser qualquer valor relevante definido pelo usuário, como uma pontuação de resiliência (isto é, a probabilidade de provisão de serviços) ou o tempo de recuperação. Foi incluída uma classe auxiliar que define e prepara o tempo de recuperação como recurso escasso. Outros recursos também podem ser explorados, desde que fornecidos pelo usuário.</p> <p>A métrica de equidade permite avaliar a equidade na provisão atual de serviços de infraestrutura e estimar os benefícios de equidade de um plano específico de reabilitação, podendo ser integrada a um processo mais amplo de tomada de decisão. As métricas de saída fornecem as seguintes informações: (1) Índice T de Theil – mede a desigualdade total na distribuição de um recurso escasso em uma comunidade (desigualdade distributiva); (2) Desigualdade entre Zonas (BZI) – quantifica a desigualdade decorrente das diferenças de recursos entre grupos (inequidade interzonal); e (3) Desigualdade dentro de Zonas (WZI) – mede a desigualdade resultante das diferenças de recursos dentro de grupos individuais (inequidade intrazonal).</p>
<b>Modelo de Equilíbrio Geral Computável (CGE) de Galveston</b>	<p>Um modelo de Equilíbrio Geral Computável (CGE) é baseado em princípios econômicos fundamentais. Esse modelo usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. O modelo está estruturado da seguinte forma: (1) domicílios que maximizam sua utilidade, oferecendo mão de obra e capital, e usando sua renda para pagar bens e serviços (tanto produzidos localmente quanto importados) e para pagar impostos; (2) o setor de produção, composto por empresas competitivas que maximizam lucros, usando insumos intermediários, capital, terra e mão de obra para produzir bens e serviços destinados ao consumo interno e à exportação; (3) o setor governamental, responsável por arrecadar impostos e financiar serviços públicos; e (4) o restante do mundo.</p> <p>O resultado dessa análise consiste em arquivos CSV com informações sobre a oferta doméstica, o rendimento bruto, a demanda de fatores antes e depois de um desastre e o número de domicílios.</p>
<b>Dano em instalações de gás</b>	<p>Essa análise calcula o dano em instalações de gás com base em um perigo específico. Atualmente, os perigos considerados são os terremotos.</p> <p>O processo de cálculo do dano estrutural é semelhante ao aplicado a outras infraestruturas do ambiente construído. Primeiro, obtém-se uma fragilidade com base no tipo de perigo e nos atributos da instalação de gás. Em seguida, é calculada a intensidade da ameaça na localização da instalação. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de terremotos, podem ser usados dados geotécnicos do solo para ajustar as probabilidades de dano e incorporar os efeitos de liquefação.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>



Tipo de análise	Descrição
<b>Recuperação sequencial de moradias em nível domiciliar</b>	<p>Essa análise calcula a sequência de estados de recuperação de moradias para cada domicílio, usando um conjunto de dados de deslocamento populacional, uma matriz de probabilidade de transição (TPM) e um vetor de estado inicial.</p> <p>O processamento classifica as unidades familiares em cinco zonas, às quais se atribuem diferentes níveis de vulnerabilidade social. Com base nessa vulnerabilidade, na TPM e no vetor de estado inicial, uma cadeia de Markov simula os estados mais prováveis, gerando um histórico de mudanças na recuperação de moradias para cada domicílio.</p> <p>O resultado é um arquivo CSV contendo o histórico de recuperação de cada unidade familiar.</p>
<b>Recuperação de moradias</b>	<p>Essa análise prevê os valores de edificações e suas variações ao longo do tempo após um evento de desastre. O modelo é calibrado com base em dados demo-gráficos, informações de parcelas e trajetórias de valor de edificações após o furacão Ike (2008) em Galveston, Texas. O modelo estima o valor das edificações em nível de parcela durante um período de oito anos de observação. Os modelos se baseiam em dados censitários (Censo Decenal ou American Community Survey – ACS) e em dados de parcelas anteriores ao evento de desastre (ano -1), usados como insumos para a previsão.</p> <p>O exemplo de Galveston (Texas) usa dados do Censo Decenal de 2010, informações do Distrito de Avaliação do Condado de Galveston (GCAD) e resultados de outras análises – ou seja, Dano em edificações, Atribuição de unidades habitacionais e Deslocamento populacional. Os resultados, em formato CSV, contêm os valores estimados das edificações para os seis anos posteriores ao evento de desastre, considerando o ano 0 como o ano do impacto.</p>
<b>Atribuição de unidades habitacionais</b>	<p>Essa análise configura um inventário detalhado de infraestrutura crítica, com características em nível de unidade habitacional. O processo alinha o inventário das unidades habitacionais a sistemas físicos, como o inventário de edificações e os nós de demanda de uma rede de abastecimento de água potável. A atribuição das unidades habitacionais aos pontos de endereço (edificações) fornece uma estrutura que permite contabilizar a incerteza na configuração da comunidade, possibilitando a análise estatística dos impactos de diferentes ameaças.</p> <p>O resultado dessa análise é um arquivo CSV com características detalhadas dos domicílios e unidades habitacionais (número de pessoas, raça, tipo de posse, vacância), associadas a unidades vinculadas a edificações específicos.</p>
<b>Problema de Projeto de Redes Interdependentes (INDP)</b>	<p>Essa análise adota uma abordagem descentralizada para resolver o Problema de Projeto de Redes Interdependentes (INDP), uma família de modelos de Programação Inteira Mista (MIP) que busca a estratégia ótima de restauração de sistemas de redes interdependentes danificados, respeitando restrições orçamentárias e operacionais.</p>
<b>Modelo de Equilíbrio Geral Computável (CGE) de Joplin</b>	<p>Um modelo de Equilíbrio Geral Computável (CGE) se baseia em princípios econômicos fundamentais e usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. O modelo considera: (1) domicílios que maximizam sua utilidade, oferecendo mão de obra e capital para pagar bens e serviços (tanto produzidos localmente quanto importados) e impostos; (2) o setor de produção, com empresas competitivas que maximizam lucros e usam insumos intermediários, capital, terra e mão de obra para produzir bens e serviços destinados ao consumo interno e à exportação; (3) o setor governamental, que arrecada impostos e financia serviços públicos; e (4) o restante do mundo.</p> <p>O resultado dessa análise consiste em arquivos CSV com a oferta doméstica, o rendimento bruto, a demanda de fatores antes e depois do desastre e o número de domicílios.</p>



Tipo de análise	Descrição
<b>Modelo empírico de restauração de edificações de Joplin</b>	<p>Esse modelo gera uma realização aleatória do tempo de restauração de uma edificação danificada por um tornado, estimando o tempo necessário para alcançar um nível específico de funcionalidade. Os níveis de funcionalidade são definidos conforme Koliou e van de Lindt (2020), variando do Nível de Funcionalidade 4 (FL4) – o mais baixo – até o Nível de Funcionalidade 0 (FLO), de funcionalidade completa. As distribuições usadas nesse modelo foram geradas a partir de um conjunto de dados empírico coletado em um estudo longitudinal de campo após o tornado de 2011 em Joplin (Missouri, EUA). Essas distribuições representam o tempo de recuperação de uma edificação desde um nível inicial até um nível superior de funcionalidade (por exemplo, de FL3 para FLO). O modelo se aplica exclusivamente aos arquetipos T1 a T5, que incluem apenas edificações residenciais, conforme Memari et al. (2018).</p> <p>O resultado do modelo é um arquivo CSV com os tempos previstos de restauração para cada edificação.</p>
<b>Modelo de Equilíbrio Geral Computável (CGE) com aprendizado de máquina – Joplin</b>	<p>A análise “Modelo de Equilíbrio Geral Computável (CGE) com aprendizado de máquina – Joplin” combina técnicas avançadas de aprendizado de máquina com modelos tradicionais de CGE, oferecendo perspectivas mais refinadas sobre os impactos econômicos de cenários de desastre em Joplin. Treinado com um conjunto abrangente de dados simulados sobre desastres e seus efeitos econômicos, esse modelo híbrido se destaca por prever as dinâmicas complexas da economia urbana em diferentes contextos de crise.</p> <p>Um modelo de Equilíbrio Geral Computável (CGE) se baseia em princípios econômicos fundamentais e usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. Esse modelo está estruturado da seguinte forma: (1) domicílios que maximizam sua utilidade, oferecendo mão de obra e capital, e usando sua renda para pagar bens e serviços (tanto produzidos localmente quanto importados) e para pagar impostos; (2) o setor de produção, composto por empresas competitivas que maximizam lucros, usando insumos intermediários, capital, terra e mão de obra para produzir bens e serviços destinados ao consumo interno e à exportação; (3) o setor governamental, responsável por arrecadar impostos e financiar serviços públicos; e (4) o restante do mundo.</p> <p>Os resultados dessa análise são arquivos CSV com dados sobre oferta doméstica, rendimento bruto, demanda de fatores antes e depois do desastre e o número de domicílios.</p>
<b>Modelo de Equilíbrio Geral Computável (CGE) com aprendizado de máquina – Salt Lake City</b>	<p>A análise “Modelo de Equilíbrio Geral Computável (CGE) com aprendizado de máquina – Salt Lake City” integra aprendizado de máquina e modelagem econômica clássica para oferecer uma visão detalhada dos impactos econômicos de desastres em Salt Lake City. Treinado com um conjunto de dados extenso de desastres simulados e seus efeitos econômicos, esse modelo permite prever de forma precisa as dinâmicas da economia local sob diversos cenários de crise.</p> <p>Um modelo de Equilíbrio Geral Computável (CGE) é baseado em princípios econômicos fundamentais. Ele usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. O modelo inclui quatro componentes principais:</p> <ul style="list-style-type: none"> <li>• Famílias, que maximizam sua utilidade e oferecem trabalho e capital, usando a renda para pagar bens e serviços (locais e importados) e impostos;</li> <li>• O setor de produção, composto por empresas em concorrência perfeita, que maximizam os lucros usando insumos intermediários, capital, terra e trabalho para produzir bens e serviços destinados ao consumo interno e à exportação;</li> <li>• O setor governamental, responsável por arrecadar impostos e usar esses recursos para financiar serviços públicos essenciais;</li> <li>• O resto do mundo, que interage com a economia local.</li> <li>• O resultado dessa análise são arquivos CSV com dados sobre oferta doméstica, rendimento bruto, demanda de fatores antes e depois do desastre e o número de domicílios.</li> </ul>



Tipo de análise	Descrição
<b>Mean Damage</b>	<p>O processo de cálculo do dano estrutural usa valores médios de dano e desvio padrão das tabelas de proporção de dano. As quatro probabilidades de estado de dano são multiplicadas pelo dano médio e agregadas para calcular o dano médio de cada estrutura individual (edificação, ponte, instalação de água etc.).</p> <p>O resultado dessa análise é um arquivo CSV com as probabilidades de danos.</p>
<b>Probabilidade de estado-limite de Monte Carlo</b>	<p>Essa análise calcula uma probabilidade de estado-limite usando um processo estocástico. A probabilidade de estado-limite e o estado de dano são derivados usando o dicionário de estado de dano no conjunto de dados de infraestrutura de entrada. A probabilidade do estado-limite é calculada a partir de todas as execuções estocásticas, e o estado-limite mostra todas as posições da infraestrutura como uma sequência de estados com falha (0) e sem falha (1) de cada execução individual.</p> <p>O resultado dessa análise são dois arquivos CSV: <code>base_name_failure_probability.csv</code>, com a probabilidade de estado-limite associada às unidades habitacionais; e <code>base_name_failure_state.csv</code>, com o estado de falha, ambos gerados por um processo estocástico. A probabilidade de estado-limite e o estado de dano são derivados usando o dicionário de estado de dano no conjunto de dados de infraestrutura de entrada. A probabilidade do estado-limite é calculada a partir de todas as execuções estocásticas, e o estado-limite mostra todas as posições da infraestrutura como uma sequência de estados com falha (0) e sem falha (1) de cada execução individual.</p> <p>O resultado dessa análise são dois arquivos CSV: <code>base_name_failure_probability.csv</code>, com a probabilidade de estado-limite associada às unidades habitacionais; e <code>base_name_failure_state.csv</code>, com o estado de falha, ambos gerados por um processo estocástico.</p>
<b>Modelo de otimização para retrofit com múltiplos objetivos</b>	<p>Essa análise calcula uma série de modelos de programação linear para a otimização de objetivos únicos e múltiplos relacionados ao impacto do clima extremo sobre comunidades, considerando três funções-objetivo: minimizar perdas econômicas, minimizar a realocação populacional e maximizar a funcionalidade das edificações.</p> <p>A análise usa um conjunto de estratégias de mitigação determinado pelo tipo de perigo, como o reforço sísmico em edificações existentes ou a realocação em casos de tsunamis ou inundações. Os parâmetros incluem o nível inicial e final de desempenho de uma edificação, o custo do retrofit e um coeficiente de objetivo que mede a resiliência da comunidade. O modelo de otimização implementado no PyIncore possui três objetivos: perda econômica, deslocamento populacional e funcionalidade das edificações.</p> <p>O processo de cálculo é realizado resolvendo iterativamente modelos lineares com restrições, usando passos epsilon. Os resultados, em formato CSV, contêm coleções de alocações ótimas de recursos.</p>
<b>Funcionalidade de interdependência em cascata de redes</b>	<p>Essa análise calcula a funcionalidade em cascata, com base nas interdependências entre redes de instalações de energia elétrica (EPF) e redes de distribuição de água (WDS).</p> <p>A análise usa a equação de Leontief para calcular as dependências funcionais entre duas redes interdependentes, considerando a funcionalidade de cada nó. Essas dependências capturam os efeitos em cascata sobre a funcionalidade da infraestrutura, expressos em termos de tempos discretizados.</p> <p>O resultado do cálculo consiste em um conjunto de dados com a funcionalidade em cascata da EPN, acompanhado dos valores discretos originais.</p>



Tipo de análise	Descrição
<b>Dano em tubulações</b>	<p>Essa análise calcula o dano em tubulações com base em um perigo específico. Atualmente, os perigos considerados são os terremotos e tsunamis.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras partes do ambiente construído. Primeiro, obtém-se uma fragilidade com base no tipo de perigo e nos atributos da tubulação. Em seguida, é calculada a intensidade do perigo na localização da tubulação. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. Se o conjunto de dados da tubulação contiver informações sobre o solo, o valor médio da fragilidade associada pode ser ajustado para levar em conta a liquefação no dano.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo</p>
<b>Danos em tubulações com taxa de reparo</b>	<p>Essa análise calcula o dano em tubulações de água com base em um perigo específico. Atualmente, os perigos considerados são os terremotos.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras partes do ambiente construído. Primeiro, obtém-se uma fragilidade com base no tipo de perigo e nos atributos da tubulação. Em seguida, é calculada a intensidade do perigo na localização da tubulação. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. Se o conjunto de dados da tubulação contiver informações sobre o solo, o valor médio da fragilidade associada pode ser ajustado para levar em conta a liquefação no dano.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo</p>
<b>Análise de funcionalidade de tubulações</b>	<p>Essa análise calcula a funcionalidade das tubulações, usando as taxas de reparo derivadas da análise de dano em tubulações. O cálculo é realizado por meio da geração de amostras de Monte Carlo, a partir de desvios de amostras de Poisson da análise de danos, usadas como entrada em experimentos de Bernoulli para determinar posteriormente a funcionalidade média.</p> <p>O resultado dessa análise são dois arquivos CSV: <code>base_name_failure_probability.csv</code>, com a probabilidade de falha; e <code>base_name_failure_state.csv</code>, com os estados de falha.</p>
<b>Custo de reparo de tubulações de água</b>	<p>Essa análise estima os custos de reparo das tubulações de água para diferentes cenários de simulação, com base em seus estados de dano, custos de substituição e taxas de dano.</p>
<b>Restauração de tubulações</b>	<p>Essa análise calcula o tempo de restauração das tubulações de água após um perigo específico. A análise é independente do tipo de perigo, pois usa os resultados da análise de dano em tubulações com taxa de reparo e as curvas de restauração.</p> <p>As curvas de restauração são definidas de acordo com o tipo de perigo e a classe específica do diâmetro da tubulação. Com base na curva de restauração aplicável, é determinado o tempo necessário para reparar cada tubulação. São considerados a taxa de vazamentos, a taxa de rupturas, o comprimento da tubulação e o número de trabalhadores disponíveis para calcular os tempos de reparo. Um dos insumos dessa análise é o resultado da análise de dano em tubulações com taxa de reparo.</p> <p>O resultado é um arquivo CSV com o tempo estimado para o reparo de cada tubulação.</p>



Tipo de análise	Descrição
<b>Deslocamento populacional</b>	<p>Essa análise calcula o deslocamento populacional para um perigo específico. Primeiro, as unidades habitacionais – com características detalhadas (regime de posse, tamanho do domicílio, ocupação ou vacância) – são atribuídas aos pontos de endereço (edificações). Isso é feito por meio da análise de alocação de unidades habitacionais. Após a atribuição das unidades, o evento de ameaça, definido pelos serviços de Fragilidade e Perigo, determina a perda de valor de cada estrutura, servindo como insumo para o cálculo do deslocamento.</p> <p>O deslocamento é calculado a partir de quatro probabilidades, baseadas em uma distribuição beta aleatória dos quatro fatores de dano apresentados por Bai et al. 2009, os quais correspondem à perda de valor. A soma dessas probabilidades, multiplicada pelas probabilidades dos estados de dano, é usada como probabilidade de deslocamento. Como o processo para determinar quais domicílios se deslocam é probabilístico, importa-se um valor inteiro para iniciar o gerador de números aleatórios, o que define se um domicílio será deslocado.</p> <p>Além disso, são consideradas as características do grupo de blocos, como os percentuais de população afrodescendente e hispânica.</p> <p>O resultado dessa análise é um arquivo CSV contendo os domicílios deslocados e as variáveis associadas.</p>
<b>Recuperação de edificações residenciais</b>	<p>Essa análise calcula o tempo de recuperação necessário para cada edificação residencial, desde qualquer estado de dano até alcançar a restauração completa. Atualmente, os perigos considerados são os tornados.</p> <p>A metodologia adota uma abordagem de simulação de Monte Carlo em várias camadas e determina o tempo de recuperação em duas etapas, que incluem tanto o período de atraso quanto o período de reparo. O modelo de atraso foi adaptado com base na estrutura REDI e calcula os resultados finais a partir de fatores que retardam a recuperação, como inspeção pós-desastre, solicitações de seguro e emissão de licenças de construção. O modelo de reparo segue a metodologia FEMA P-58 e usa funções de fragilidade de Koliou e van de Lindt (2020).</p> <p>O resultado dessa análise é um arquivo CSV com as probabilidades de recuperação em intervalos de tempo no nível de edificação.</p>
<b>Dano em rodovias</b>	<p>Essa análise calcula o dano em rodovias com base em um perigo específico. Atualmente, os perigos considerados são os terremotos e tsunamis.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras partes do ambiente construído. Primeiro, obtém-se uma fragilidade com base no tipo de perigo e nos atributos das rodovias. Em seguida, é calculada a intensidade do perigo. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. Se o conjunto de dados da rodovia contiver informações sobre o solo, o valor médio da fragilidade associada pode ser ajustado para levar em conta a liquefação no dano.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>



Tipo de análise	Descrição
<b>Modelo de Equilíbrio Geral Computável (CGE) – Salt Lake City</b>	<p>Um modelo de Equilíbrio Geral Computável (CGE) é baseado em princípios econômicos fundamentais. Este modelo usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. O modelo se baseia em: (1) domicílios que maximizam a utilidade, oferecendo mão de obra e capital, usando a renda para pagar por bens e serviços (tanto produzidos localmente quanto importados) e para pagar impostos; (2) o setor de produção, composto por empresas perfeitamente competitivas que maximizam seus lucros usando insumos intermediários, capital, terra e mão de obra para produzir bens e serviços destinados ao consumo interno e à exportação; (3) o setor público, que arrecada impostos e usa a receita fiscal para financiar a prestação de serviços públicos; e (4) o resto do mundo.</p> <p>O resultado dessa análise é um conjunto de arquivos CSV com dados sobre oferta doméstica, rendimento bruto, demanda de fatores antes e depois do desastre e número de domicílios.</p>
<b>Modelo de Equilíbrio Geral Computável (CGE) – Seaside</b>	<p>Um modelo de Equilíbrio Geral Computável (CGE) é baseado em princípios econômicos fundamentais. Este modelo usa várias fontes de dados para representar as interações entre os domicílios, as empresas e as entidades governamentais pertinentes que contribuem para a atividade econômica. O modelo se baseia em: (1) domicílios que maximizam sua utilidade, oferecendo mão de obra e capital, e usando sua renda para pagar bens e serviços (tanto produzidos localmente quanto importados) e para pagar impostos; (2) o setor de produção, composto por empresas competitivas que maximizam lucros, usando insumos intermediários, capital, terra e mão de obra para produzir bens e serviços destinados ao consumo interno e à exportação; (3) o setor governamental, responsável por arrecadar impostos e financiar serviços públicos; e (4) o restante do mundo.</p> <p>O resultado dessa análise é um conjunto de arquivos CSV com simulações CGE, oferta doméstica e emprego.</p>
<b>Vulnerabilidade social</b>	<p>Essa análise calcula o dano na rede elétrica (EPN) com base em um perigo específico. O cálculo combina o zoneamento com um índice de vulnerabilidade social obtido pela comparação de características demográficas de interesse com os valores médios nacionais.</p> <p>O resultado do cálculo é um conjunto de dados em formato CSV.</p>
<b>Índice de vulnerabilidade social</b>	<p>Essa análise calcula o dano na rede elétrica (EPN) com base em um perigo específico. O cálculo combina o zoneamento com um índice de vulnerabilidade social obtido pela comparação de características demográficas de interesse com os valores médios nacionais.</p> <p>O resultado do cálculo é um conjunto de dados em formato CSV.</p>
<b>Danos à rede elétrica por tornado (EPN)</b>	<p>Essa análise calcula o dano na rede elétrica (EPN) com base em um perigo específico. Atualmente, os perigos considerados são os tornados.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras partes do ambiente construído. Primeiro, obtêm-se as fragilidades com base no tipo de perigo e nos atributos das torres e postes da rede elétrica. Com base nessas fragilidades, calcula-se a intensidade da ameaça na localização da infraestrutura. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades. De acordo com os dados de entrada, essa análise também fornece informações sobre o número de postes danificados em cada nó, o custo de reparo por nó, o custo total de reparo da rede e o tempo total estimado de reparo.</p>



Tipo de análise	Descrição
<b>Recuperação do fluxo de tráfego</b>	<p>Esta análise estima o dano a pontes, primeiramente executando o módulo de análise de danos a pontes. Em seguida, são usados os nós e enlaces do caminho do fluxo de tráfego e os dados de Tráfego Médio Diário (ADT) das pontes para calcular a recuperação da rede de tráfego pós-desastre. Além disso, a análise pode ser usada em cálculos estocásticos, com um valor inteiro importado para inicializar o gerador de números aleatórios.</p> <p>O resultado dessa análise é um arquivo CSV contendo as linhas do tempo da trajetória de recuperação e os dados correspondentes.</p>
<b>Recuperação do transporte</b>	<p>Esta análise estima o dano a pontes, primeiramente executando o módulo de análise de danos a pontes. Em seguida, são usados os nós e enlaces do caminho de transporte e os dados de Tráfego Médio Diário (ADT) das pontes para estimar a recuperação da rede de transporte pós-desastre. Além disso, a análise pode ser usada em cálculos estocásticos, com um valor inteiro importado para inicializar o gerador de números aleatórios.</p> <p>O resultado dessa análise é um arquivo CSV contendo as linhas do tempo da trajetória de recuperação e os dados correspondentes.</p>
<b>Dano em instalações de água</b>	<p>Essa análise calcula o dano em instalações de água com base em um perigo específico. Atualmente, os perigos considerados são os terremotos e tsunamis.</p> <p>O processo de cálculo dos danos estruturais é semelhante ao de outras partes do ambiente construído. Primeiro, obtém-se uma curva de fragilidade de acordo com o tipo de perigo e as características da edificação. Com base na fragilidade, calcula-se a intensidade da ameaça na localização da estrutura. Com essas informações, é determinada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de perigo por terremoto, podem ser usados dados geotécnicos do solo para ajustar as probabilidades de dano e incorporar os efeitos de liquefação.</p> <p>Os resultados dessa análise são um arquivo CSV com as probabilidades de danos e um arquivo JSON com informações sobre o perigo e as fragilidades.</p>
<b>Funcionalidade da rede de água</b>	<p>Essa análise calcula a funcionalidade das redes de água.</p> <p>O cálculo usa entradas da análise de falhas de Monte Carlo, incorporando informações sobre danos nas instalações de água e dados de funcionalidade das tubulações, para determinar a probabilidade de funcionalidade e os estados de falha da rede de instalações de água correspondente, com uma análise de acessibilidade.</p> <p>O resultado da análise é um arquivo CSV com as probabilidades de funcionalidade das instalações de água e um arquivo CSV adicional com os estados de falha de funcionalidade.</p>
<b>Análise de custos de reparo de instalações de água</b>	<p>Essa análise estima os custos de reparo das instalações de água para diferentes cenários de simulação, com base em seus estados de dano, custos de substituição e taxas de dano.</p>
<b>Restauração de instalações de água</b>	<p>Essa análise calcula o tempo de reparo e a variação percentual da funcionalidade ao longo do tempo para a restauração de instalações de água, com base nas curvas de restauração mapeadas.</p> <p>As curvas de restauração são obtidas conforme o tipo de perigo e a categoria da instalação de água (por exemplo, estação de tratamento, estação de bombeamento, reservatório de armazenamento etc.). Com base na curva de restauração aplicável, obtém-se o percentual de variação da funcionalidade ao longo do tempo. Também é possível calcular o tempo de reparo em diferentes níveis de variação da funcionalidade, invertendo a função de restauração.</p>

Fonte: van de Lindt et al. (2023).




### A.6.3. Abordagem matemática

O IN-CORE usa curvas de fragilidade para realizar os cálculos de dano. Primeiro, obtém-se a fragilidade com base no tipo de perigo e nos atributos do edificação (ou de qualquer outro elemento exposto). Com base na fragilidade, calcula-se a intensidade da ameaça na localização do edifício. Com essas informações, é calculada a probabilidade de exceder cada estado-limite e a probabilidade de danos. No caso de perigo sísmico, podem ser usados dados geotécnicos do solo para ajustar as probabilidades de dano e incorporar os efeitos de liquefação (IN-CORE 2024).


A **Figura 50** mostra um exemplo de curva de risco obtida pelo IN-CORE. O perigo sísmico-tsunami na Zona de Subducção de Cascadia (CSZ) é usado nesse exemplo para demonstrar as capacidades multiameaça do software. A análise probabilística de perigo sísmico-tsunami (PSTHA; Park et al. 2017) resultou em mapas de perigo tanto para terremotos quanto para tsunamis, considerando sete intervalos de recorrência (100, 250, 500, 1 mil, 2,5 mil, 5 mil e 10 mil anos). Os danos às edificações são calculados no IN-CORE por meio da sobreposição dos mapas de perigo sobre as edificações e da determinação das medidas de intensidade específicas de cada local. As medidas de intensidade de deslocamento espectral e fluxo de momento são usadas, respectivamente, para o terremoto e o tsunami. Em seguida, aplicam-se as curvas de fragilidade para determinar a probabilidade de cada edificação sofrer: (1) danos insignificantes, (2) moderados, (3) graves ou (4) completos. Essas probabilidades são então usadas em uma simulação de Monte Carlo, na qual é calculada a probabilidade de falha estrutural das edificações. A documentação do IN-CORE não apresenta referência a uma função específica para o cálculo do EAD, mas, como o IN-CORE opera em ambiente Python, o usuário pode obter a área sob a curva usando as funções disponíveis no Python.

**Figura 50. Exemplo de curva de risco obtida pelo IN-CORE**



Fonte: IN-CORE (2024).

**Obs.:** a linha azul representa as perdas econômicas por terremoto; a linha vermelha representa as perdas econômicas por tsunami; e a linha preta representa as perdas multiameaça.

**Figura 51. Mapas de perigo para tsunami e terremoto**

Fonte: IN-CORE (2024).

## A.6.4. Avanços recentes e inovações

A versão mais recente é o IN-CORE v5.3.0, publicada em 12 de abril de 2024.

## A.6.5. Comunidade de desenvolvimento

O IN-CORE é desenvolvido por uma equipe interdisciplinar de pesquisadores da Universidade Estadual do Colorado, em colaboração com outras instituições acadêmicas, agências governamentais e o setor privado. Essa comunidade atua de forma conjunta para atualizar e melhorar continuamente o software, garantindo que ele se mantenha na vanguarda da pesquisa em resiliência de infraestruturas.

## A.6.6. Limitações

Uma das principais limitações do IN-CORE é exigir que o usuário possua conhecimentos de programação no Python.

## A.6.7. Casos de uso

Até o momento, o IN-CORE tem sido usado exclusivamente nos Estados Unidos. O **Quadro 6** mostra exemplos que usam o software como tutorial, conforme descrito por van de Lindt et al. (2023).

## **Estudo de caso: Seaside, Oregon (terremoto e tsunami sucessivos)**

---




Seaside, uma pequena cidade costeira no noroeste do Pacífico dos Estados Unidos, foi selecionada como caso de estudo para aplicação do sistema IN-CORE, devido à sua vulnerabilidade a terremotos e tsunamis originados na Zona de Subducção de Cascadia (CSZ). O estudo gerou camadas de ameaça associadas a terremoto e tsunami, com foco em cinco medidas de intensidade do tsunami: profundidade do fluxo, velocidade, fluxo de momento, tempo de chegada e duração da inundação.

Posteriormente, foi realizada uma análise de danos multirrisco para avaliar os impactos combinados do terremoto e do tsunami, usando uma abordagem estocástica que considera os danos acumulados pelo terremoto e pela subsequente inundação por tsunami. A análise probabilística de danos por terremoto e tsunami foi integrada como uma etapa dentro de um sistema de apoio à decisão voltado à resiliência, incluindo a avaliação de perdas econômicas diretas e indiretas.

O estudo também considerou diversos componentes do ambiente construído, abrangendo os setores de transporte, energia e abastecimento de água, bem como as características demográficas da população. Os danos, as perdas econômicas e a conectividade com instalações críticas foram analisados para identificar as perdas econômicas por tipo de perigo e por tipo de infraestrutura.

Durante a análise, foram estabelecidas metas de desempenho: 1) robustez – por exemplo, um nível aceitável de dano; e 2) rapidez – por exemplo, um tempo aceitável de recuperação. Um aspecto central desse marco foi a definição das metas com base no intervalo médio de recorrência (MRI) das ameaças. Os resultados destacaram o impacto de considerar diferentes metas de desempenho, a adoção de medidas ex-ante e ex-post, e as interdependências entre diversos sistemas de infraestrutura sobre a resiliência das redes. O estudo também mostrou que o volume de escombros aumenta conforme o MRI e que a localização do perfil máximo de acúmulo de escombros ao longo da costa está relacionada ao limite máximo de elevação do tsunami.

A figura apresentada a seguir ilustra o risco econômico médio anualizado para (a) edificações e (b) a rede de transporte (rodovias e pontes) em função do MRI. O risco é desagregado por tipo de perigo: terremoto (azul), tsunami (vermelho) e combinado (preto). No painel esquerdo (A), o risco máximo para edificações ocorre no evento de 250 anos, devido principalmente ao movimento do solo. No painel direito (B), o risco máximo para rodovias e pontes ocorre no evento de 1 mil anos, predominantemente em razão do tsunami. Essa comparação reforça a importância de avaliar o risco considerando tanto o tipo de perigo quanto o tipo de infraestrutura, como subsídio à tomada de decisão sobre a resiliência comunitária.



Esse estudo de caso demonstra a relevância de integrar análises multirrisco e de avaliar a infraestrutura local em termos de vulnerabilidade frente a terremotos e tsunamis. Os resultados obtidos não só ampliam a compreensão dos riscos e perdas econômicas potenciais, como também orientam estratégias para o fortalecimento da resiliência comunitária diante de eventos de grande magnitude.



## A.7. CLIMADA (CLIMATE ADAPTATION)

### A.7.1. Descrição geral

O CLIMADA é uma ferramenta de modelagem quantitativa de riscos climáticos desenvolvida para avaliar o risco socioeconômico de eventos climáticos extremos. Trata-se de uma plataforma de código aberto, disponível no GitHub<sup>26</sup>, desenvolvida principalmente no Python, MATLAB e Octave. A ferramenta permite analisar riscos de diversos tipos de ameaças climáticas – como ciclones tropicais, inundações e secas – em escalas globais, regionais e locais, fornecendo estimativas espaciais explícitas de risco tanto para o presente quanto para projeções futuras. O CLIMADA implementa um modelo de avaliação de risco totalmente probabilístico (Aznar-Siguan e Bresch, 2019).

Ele fornece uma estrutura que permite aos usuários combinar dados de exposição, ameaça e vulnerabilidade para calcular o risco. Os usuários podem gerar dados probabilísticos de impacto a partir de conjuntos de eventos, observar como a mudança climática afeta esses impactos e avaliar como medidas de adaptação podem modificá-los de forma eficaz. O CLIMADA também permite estudos de eventos individuais, séries históricas de eventos e projeções futuras (ETH Zurich, 2017c).

Além disso, há esforços contínuos para garantir a interoperabilidade e integração do CLIMADA com outras ferramentas, como OASIS LMF (Blass 2021) e OpenQuake<sup>27</sup>.

### A.7.2. Métodos aplicados

O CLIMADA implementa um modelo probabilístico de avaliação de riscos usando técnicas de última geração, como a simulação de Monte Carlo. Essa abordagem permite integrar diferentes cenários de desenvolvimento econômico e impacto climático, usando dados históricos e de sensoriamento remoto para gerar mapas de perigo, vulnerabilidade e risco. O modelo combina três componentes fundamentais – ameaça, exposição (ativos e pessoas) e vulnerabilidade – para calcular o risco. Além disso, inclui funções de dano que relacionam a intensidade de um evento às suas consequências econômicas sobre ativos como pessoas, edificações e infraestruturas públicas. O CLIMADA opera de forma coerente em escala global, com alta resolução (10 km), bem como em aplicações locais com resoluções mais detalhadas (100 m). No entanto, o usuário pode usar as informações no nível de detalhe que tiver disponível. A ferramenta fornece estimativas espacialmente explícitas de risco para várias ameaças, tanto no presente quanto em projeções futuras (Munich Climate Insurance Initiative, 2020). O CLIMADA também permite avaliar portfólios completos de medidas de adaptação, quantificando o potencial de redução de danos e a relação custo-benefício de cada medida (Munich Climate Insurance Initiative, 2020). Essas medidas de adaptação incluem, por exemplo: construção de obras de proteção, planejamento territorial e urbano, soluções baseadas em ecossistemas, regulamentações de construção e mecanismos de transferência

---

<sup>26</sup> O código está hospedado no GitHub ([https://github.com/CLIMADA-project/climada\\_python](https://github.com/CLIMADA-project/climada_python)) sob a licença GNU GPL (GNU Operating System, 2007) (Aznar-Siguan & Bresch, 2019).

<sup>27</sup> Comunicação verbal com a Universidade das Nações Unidas.



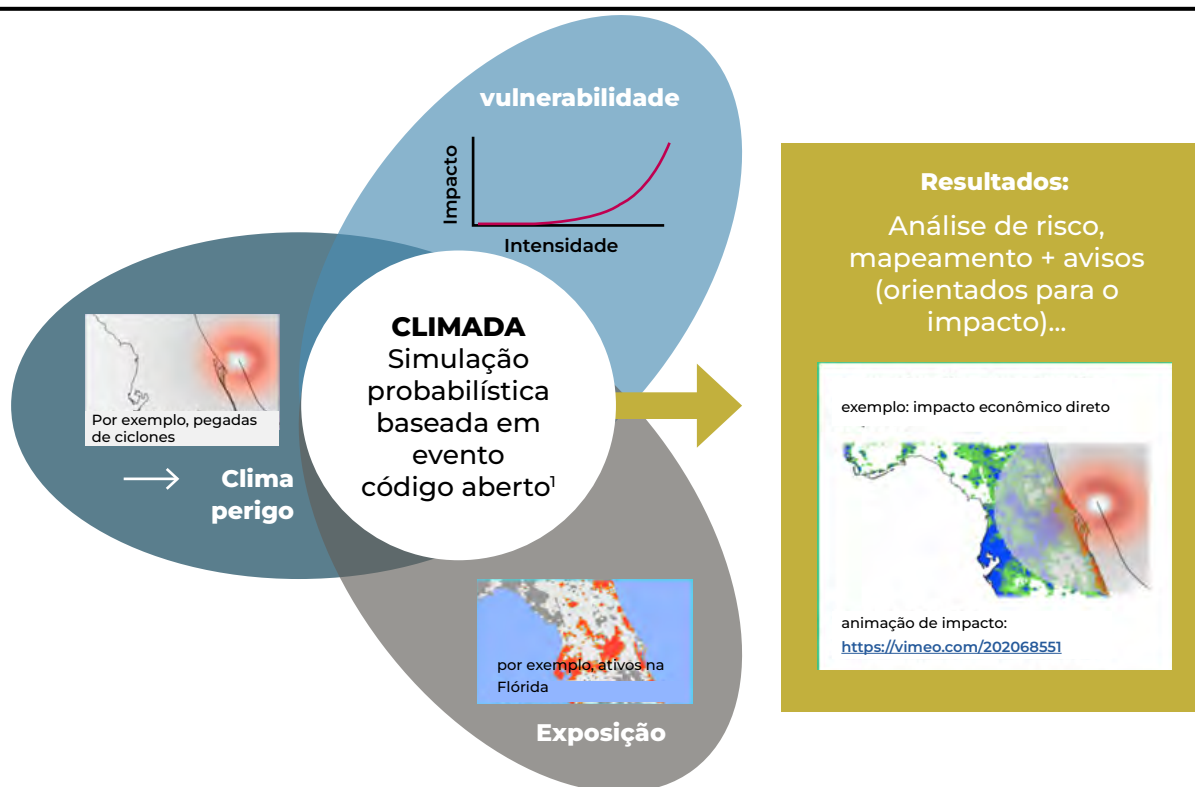
de risco (seguros) frente a eventos climáticos extremos. Nesse contexto, o CLIMADA implementa a metodologia de Economia da Adaptação Climática (Economics of Climate Adaptation, Aznar-Siguan e Bresch 2019).

O software possui arquitetura modular e orientação a objetos, oferecendo uma estrutura colaborativa simples e estratégia de paralelização que possibilita cálculos escaláveis em clusters computacionais (Aznar-Siguan e Bresch 2019).

O primeiro passo na análise custo-benefício é determinar o risco atual (consulte a **Figura 52**). Na essência, o CLIMADA adota o conceito de risco conforme o IPCC (2014). Ele combina a ameaça (por exemplo, a pegada de vento de um ciclone tropical), a exposição (como a distribuição de ativos) e a vulnerabilidade (função que relaciona intensidade da ameaça e impacto) para calcular o risco (Aznar-Siguan e Bresch 2019).

Além disso, com o CLIMADA é possível realizar análises globais de incerteza, incluindo a incerteza relacionada à ameaça, à exposição e à função de impacto, por meio dos métodos implementados no módulo Unsequa (Kropf et al. 2022).

**Figura 52. Conceitualização do CLIMADA**



Fonte: Aznar-Siguan e Bresch (2019).



### A.7.3. Abordagem matemática

O CLIMADA oferece uma abordagem probabilística baseada em eventos, sem depender de hipóteses prévias sobre distribuições de probabilidade. Seu modelo de dano pode ser usado para várias aplicações: de forma determinística, para avaliar o dano de um evento único, ou probabilística, para quantificar o risco com base em grandes conjuntos de eventos (Aznar-Siguan and Bresch 2019). A exposição pode ser expressa em valores não necessariamente monetários (por exemplo, em número de pessoas afetadas).

O motor de cálculo do CLIMADA aplica as funções de dano ou vulnerabilidade para estimar os danos de uma ameaça sobre os elementos expostos e armazena todas as métricas resultantes de avaliação de risco. A arquitetura usada pela ferramenta para o cálculo de risco é mostrada na **Figura 53**. O valor da ameaça é atribuído à coordenada do centroide de cada elemento exposto, e a relação de dano, derivada das funções de dano, é convertida em dano direto multiplicando-a pelo valor exposto **Equação 17** (Aznar-Siguan and Bresch 2019):

#### Equação 17

$$x_{ij} = val_j f_{imp}(h_{ij} | \gamma_j)$$

Em que  $x_{ij}$  e  $h_{ij}$  representam, respectivamente, o dano e a intensidade da ameaça para o evento  $i$  na localização  $j$ ;  $val_j$  é o valor de exposição na localização  $j$ ;  $\gamma_j$  são os parâmetros que caracterizam a vulnerabilidade e  $f_{imp}$  é a função de dano. O dano é obtido para cada elemento exposto e cada evento (histórico ou estocástico) que o afete. Com base no dano e na frequência de cada evento, podem ser calculadas diversas métricas de risco. A seguir, são apresentadas as equações usadas pela ferramenta, derivadas de (Cardona et al. 2012).

Dano anual esperado (EAI) na exposição  $j$ , contido no atributo  $eai\_exp$ .

#### Equação 18

$$EAI_j = \sum_{\hat{i}}^{N_{hist}} E[X|E_{ij}] F(E_i)$$

#### Equação 19

$$EAI_j = \sum_{\hat{i}=1}^{N_{hist}} \sum_{\hat{i}} x_i F(E_i) = \sum_{i=1}^{N_{ev}} x_{ij} F(E_i)$$

Onde  $X$  é a variável aleatória de dano,  $E$  sua expectativa,  $E_i$  é um evento e  $F$  sua frequência anual.  $N_{hist}$  é o número de eventos históricos,  $\hat{i}$  representa um evento histórico,  $\hat{i}$  representa todos os membros do conjunto do evento  $i$ ; e  $N_{ev}$  representa o número total de eventos. Assume-se a independência dos eventos.



- O dano anual médio (AAI) está contido no atributo *aaI\_agg* e corresponde à soma dos EAI para todas as exposições:

### Equação 20

$$AAI = \sum_{j=1}^{Nexp} EAI_j$$

Em que *Nexp* é o número de elementos expostos.

- Dano máximo provável (PMI): o PMI representa o dano que é excedido em uma frequência anual baixa e fixa (normalmente entre 1/1.500 e 1/250). Esse valor é obtido a partir da curva de excedência de dano, calculada pelo método *calc\_freq\_curve*. Com base no teorema da probabilidade total, essa curva é aproximada por meio da discretização da **Equação 21**.

### Equação 21

$$v(x) = \frac{1}{T(x)} = P(X > x) = \sum_i^{Nhist} \int P(X > x|h) p(h|E_i) dh F(E_i)$$

Em que  $v(x)$  é a frequência de excedência do dano  $x$ ,  $T(x)$  é o período de retorno equivalente e  $h$  é a intensidade da ameaça.  $p(h|E_i)$  é a função de densidade de probabilidade de  $h$ , dado que o evento histórico  $E_i$  ocorreu, e é calculada usando os membros do conjunto do evento. A probabilidade de exceder um valor de dano dado um nível de intensidade  $h$ ,  $P(X > x|h)$ , é calculada com base nos valores de exposição e em suas funções de dano. O CLIMADA assume que os danos de um evento em diferentes exposições são independentes.

O CLIMADA também inclui um módulo para quantificação de incerteza e análise de sensibilidade (Kropf et al. 2022). O módulo Unsequa usa uma abordagem baseada em Monte Carlo e aplica metodologias padrão de análise de incerteza e sensibilidade. Seu fluxo de trabalho começa com a definição das variáveis de entrada e parâmetros, estabelecendo distribuições de probabilidade para os parâmetros que afetam as principais variáveis do modelo – perigo, exposição, função de vulnerabilidade e medidas de adaptação – com base nas quais são geradas amostras segundo suas distribuições probabilísticas.

Em seguida, o motor do CLIMADA executa o modelo para cada amostra, gerando métricas de risco ou avaliações de opções de adaptação. Os resultados podem ser analisados e visualizados para compreender a distribuição dos resultados do modelo. Também é possível calcular índices de sensibilidade para avaliar a influência de cada parâmetro de entrada sobre as métricas do modelo (Kropf et al. 2022).



As distribuições dos parâmetros podem ser de qualquer tipo – incluindo uniformes, gaussianas, enviesadas ou discretas. O CLIMADA permite o uso de qualquer distribuição disponível na biblioteca *SciPy.stats* do Python.

Para definir a incerteza de cada variável, o usuário deve especificar um método que determine seu valor com base nos parâmetros incertos. O módulo *Unsequa* oferece métodos auxiliares para apoiar essa parametrização, permitindo duas abordagens principais: a perturbação direta de uma variável usando métodos estatísticos ou a incorporação de parâmetros incertos no modelo subjacente que gera a variável. Como cada variável é independente, é possível usar ambas as abordagens simultaneamente no mesmo estudo.

A análise de incerteza e sensibilidade é computacionalmente intensiva: o tempo de cálculo cresce conforme o número de amostras e a complexidade do modelo. Fatores como resolução espacial da exposição e número de eventos da ameaça afetam diretamente a duração do processamento. Em modelos externos, como os hidrológicos, o tempo de simulação do modelo-base também influencia. Se os cálculos se tornarem excessivamente longos, é possível pré-computar amostras ou empregar modelos substitutos.

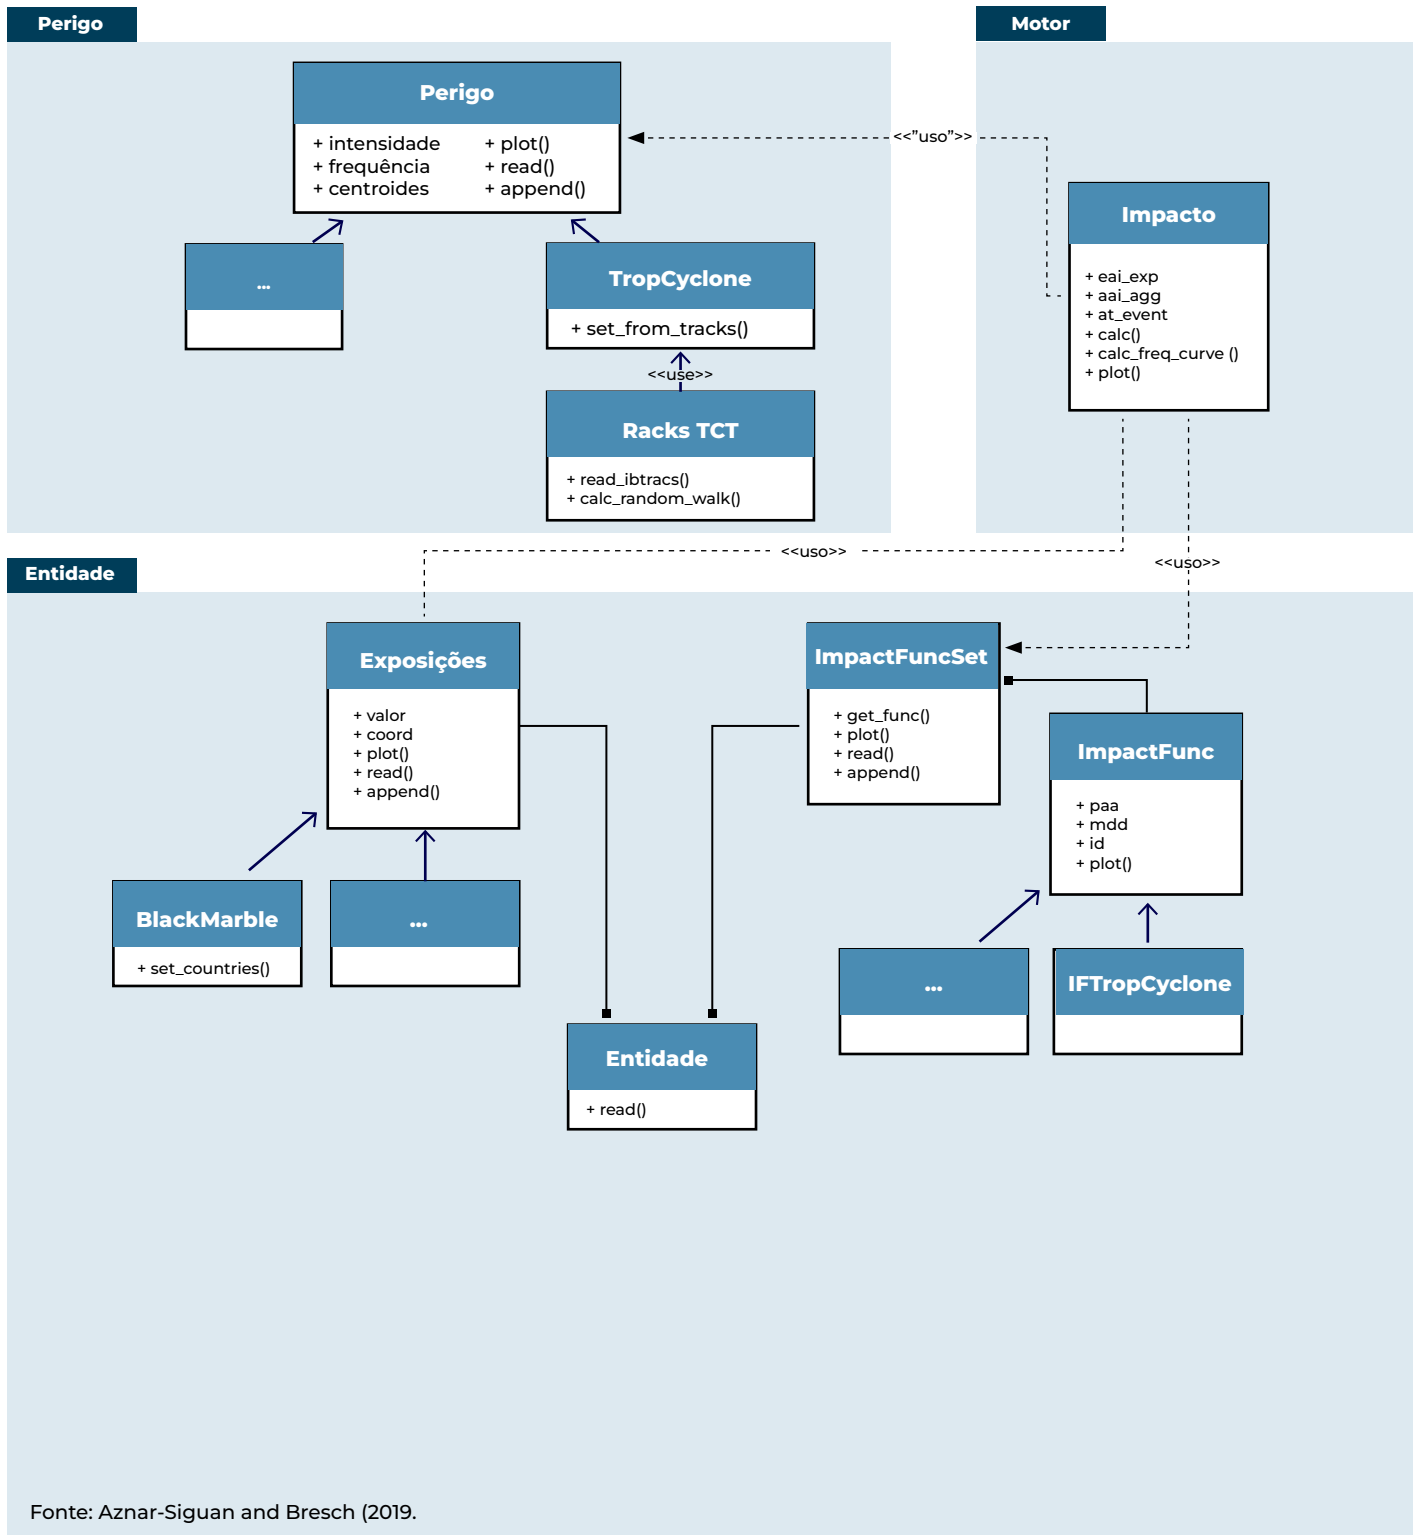
Na etapa final, os resultados são caracterizados e visualizados com ferramentas gráficas e estatísticas, permitindo compreender as incertezas além de médias e desvios padrão. Os índices de sensibilidade quantificam a influência de cada parâmetro incerto sobre os resultados do modelo. Como o CLIMADA é não linear, são considerados apenas índices de sensibilidade globais, calculados com algoritmos disponíveis na biblioteca *SALib* do Python, como Sobol, efeitos elementares de Morris e FAST (Kropf et al. 2022). Cada método possui requisitos específicos de amostragem e pode produzir resultados diferentes, embora, em geral, concordem na identificação dos parâmetros mais influentes.



Imagem: Adobe Stock



**Figura 53. Arquitetura simplificada de avaliação de riscos do CLIMADA**



Fonte: Aznar-Siguan and Bresch (2019).



## A.7.4. Avanços recentes e inovações

Recentemente, o CLIMADA melhorou seu desempenho, escalabilidade e capacidade de manutenção. A ferramenta inclui coberturas globais de ameaças climáticas, como ciclones tropicais, inundações fluviais, secas agrícolas e tempestades de inverno europeias, com conjuntos de eventos históricos e probabilísticos disponíveis sob diferentes cenários de forçamento climático.

## A.7.5. Comunidade de desenvolvimento

O CLIMADA é desenvolvido e mantido pelo grupo de pesquisa Weather and Climate Risks (WCR) da ETH Zurich. A comunidade de desenvolvimento é ativa e incentiva o uso interdisciplinar da plataforma, promovendo a colaboração internacional. A disponibilidade do CLIMADA como software de código aberto, sob a licença GNU GPL3, tem sido fundamental para fortalecer a confiança nos resultados.

## A.7.6. Limitações

Uma das principais limitações do CLIMADA é exigir que o usuário possua conhecimentos de programação no Python. Por outro lado, embora o CLIMADA tenha sido originalmente concebido para analisar ameaças climáticas, ele também pode realizar cálculos de risco para qualquer tipo de perigo, desde que esta seja representada como um objeto do tipo Hazard e possa ser associada a uma curva de dano dos elementos expostos.

## A.7.7. Casos de uso

O CLIMADA já foi aplicado em mais de 20 estudos de adaptação climática no mundo todo, servindo como base sólida para a avaliação de riscos e para comunicar e tratar incertezas (Munich Climate Insurance Initiative 2020).



## Estudo de caso: O furacão Irma e seu impacto nos territórios não autônomos do Caribe

---



Image: Adobe Stock

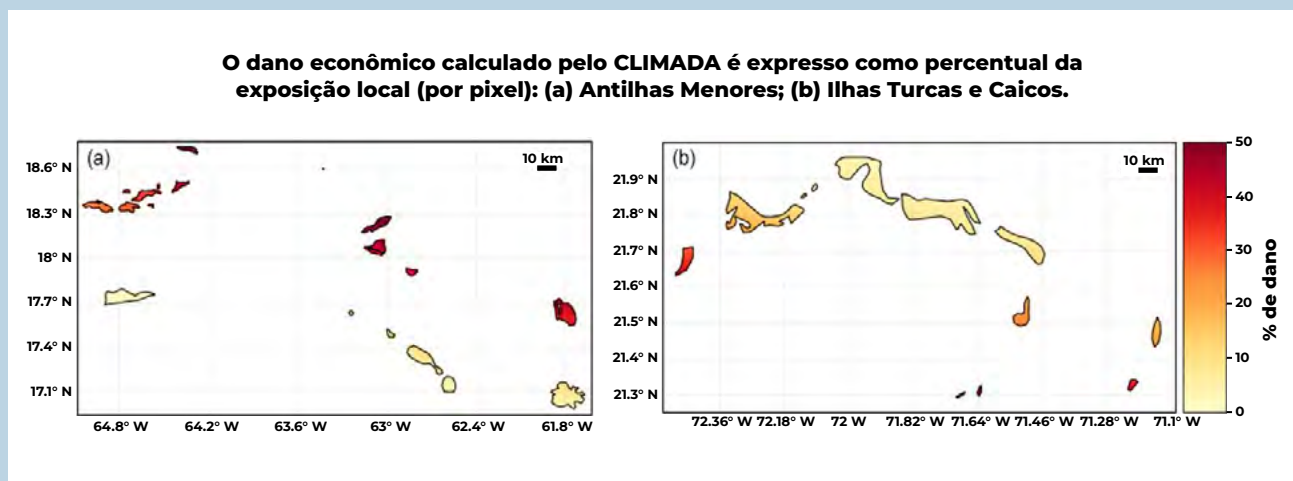
A região do Caribe compreende 19 territórios não autônomos. A passagem do furacão Irma, em setembro de 2017 – um evento de categoria 5 – oferece um estudo de caso comparativo sobre as respostas governamentais e os impactos socioeconômicos nesses territórios. A trajetória do furacão afetou diversas ilhas, incluindo nações soberanas como Antígua e Barbuda e São Cristóvão e Névis, bem como territórios dependentes como São Bartolomeu, Sint Maarten, Anguila e as Ilhas Virgens dos EUA.

Historicamente, essas ilhas dependiam de setores primários, como a agricultura, mas migraram para turismo e finanças offshore. Essa mudança econômica tem implicações para o impacto financeiro dos desastres, considerando o papel significativo do turismo e das finanças em suas economias.

Para estimar o valor econômico exposto, usou-se o conjunto de dados Black Marble, que emprega imagens noturnas de satélite da NASA para estimar a distribuição espacial do valor econômico nas ilhas afetadas. O método envolve a desagregação do PIB nacional para uma resolução de 500 metros, ajustada por vieses de distribuição urbana e suburbana usando uma transformação quadrática.

O dano por ciclone tropical foi modelado com a classe TropCyclone do CLIMADA, incorporando trajetórias históricas de ciclones e velocidades de vento após o impacto na terra. A função de dano usada se baseia nas velocidades de vento, com ajustes para áreas urbanas e níveis diferenciados de renda.

O estudo avaliou o risco combinando a ameaça de ciclones tropicais com a exposição econômica. Os modelos probabilísticos estimaram os níveis de dano para vários períodos de retorno, revelando que todas as ilhas enfrentam riscos significativos associados a ciclones intensos. A análise indicou que o dano causado por um evento com período de retorno de 100 anos pode ultrapassar US\$ 1 bilhão, com ilhas individuais, como as Ilhas Virgens dos EUA, exigindo preparo financeiro substancial.



As estimativas de dano foram comparadas com outras fontes, como o EM-DAT, o Centro Nacional de Furacões e a CEPAL. Os resultados do modelo CLIMADA se mostraram consistentes com essas fontes, demonstrando estimativas confiáveis dentro do intervalo esperado. A variabilidade observada nas estimativas de dano se deve às diferenças nas fontes de dados e metodologias, mas as simulações foram robustas.

A análise de incerteza indicou que fatores socioeconômicos são os principais determinantes da variabilidade nas estimativas de dano. As simulações de Monte Carlo revelaram que eventos extremos podem gerar danos substanciais, variando entre US\$ 12,5 bilhões e US\$ 21 bilhões nos cenários mais severos.

Ao aplicar técnicas avançadas de modelagem e usar dados de satélite, o estudo fornece informações valiosas sobre o impacto financeiro do furacão Irma e propõe um marco para melhorar a preparação e a resposta a desastres. Os resultados podem apoiar governos centrais e administrações territoriais na formulação de estratégias eficazes para mitigar riscos futuros e fortalecer a resiliência.



## A.8. CATSIM (CATASTROPHE SIMULATION TOOL)

### A.8.1. Descrição geral

O CATSIM (Catastrophe Simulation Tool) é um modelo desenvolvido pelo International Institute for Applied Systems Analysis (IIASA), criado para apoiar tomadores de decisão, especialmente em países em desenvolvimento, na elaboração de estratégias de financiamento público pré e pós-desastre. O modelo permite a entrada de dados nacionais e a realização de análises de cenários hipotéticos (“e se...”), identificando as melhores combinações de estratégias financeiras de acordo com as condições econômicas e fiscais do país (IIASA 2024b).

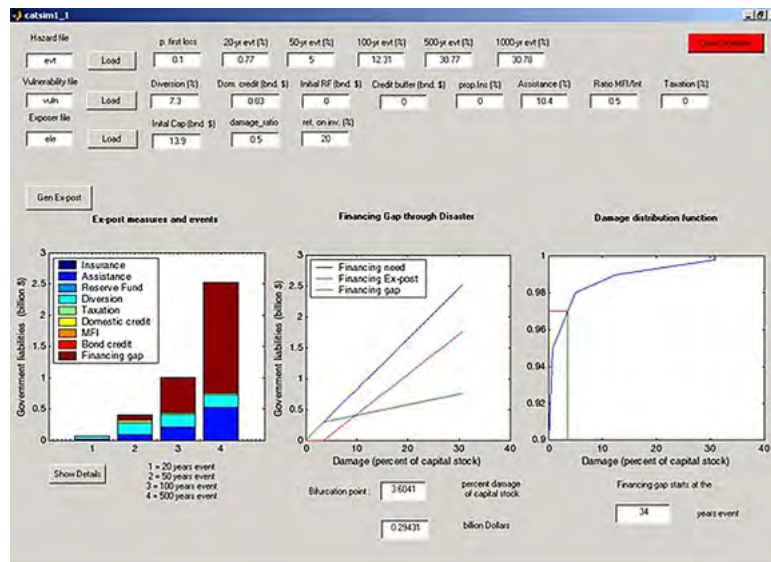
O CATSIM fornece uma estrutura econômica baseada em risco para avaliar os impactos econômicos de desastres e analisar os custos e benefícios de medidas destinadas a reduzir esses impactos (Hochrainer-Stigler et al., 2013). Ele usa simulações estocásticas de riscos em uma região específica e examina a capacidade dos governos e do setor privado de financiar atividades de resposta e recuperação. O modelo também avalia obrigações contingentes do governo, lacunas financeiras após desastres e opções de redução da vulnerabilidade, incluindo estratégias de gestão financeira. Além disso, o CATSIM incorpora um modelo simplificado de crescimento econômico para avaliar os impactos macroeconômicos de desastres e os custos e benefícios de políticas de mitigação (Hochrainer-Stigler et al. 2015).

Os resultados fornecidos incluem (Hochrainer-Stigler et al. 2013):

- ➔ **Avaliação de obrigações contingentes e déficits de financiamento:** identifica possíveis brechas de financiamento que um país pode enfrentar em caso de desastre.
- ➔ **Análise custo-benefício de opções de redução de vulnerabilidade e risco:** avalia a eficácia econômica de diferentes estratégias de gerenciamento de riscos, como prevenção, fundos nacionais de reserva ou seguros soberanos.
- ➔ **Apoio à formulação de políticas públicas:** auxilia governos a decidir sobre a alocação de recursos entre medidas preventivas (gasto ex-ante) e ações de resposta pós-desastre (gasto ex-post), considerando seus efeitos na resiliência econômica.

O CATSIM é uma aplicação independente com interface gráfica de fácil uso, que permite ao usuário definir parâmetros para ameaça, vulnerabilidade e elementos expostos. A interface do software é mostrada na **Figura 54**.

Como o CATSIM se concentra na tomada de decisões em nível nacional, seus dados de entrada e resultados não possuem natureza geoespacial. Os resultados são exibidos em gráficos interativos, que permitem ajustar parâmetros e realizar análises de sensibilidade (Hochrainer-Stigler et al. 2015).


**Figura 54. Interface gráfica do CatSim**


Interface de usuário do CATSIM para avaliar as opções de gerenciamento de riscos financeiros

Fonte: IIASA (2024b)

## A.8.2. Métodos aplicados

O CATSIM adota uma abordagem modular, composta por:

- ➔ **Módulo 1 – Avaliação de risco:** define os parâmetros relacionados às ameaças, à vulnerabilidade e aos elementos expostos.
- ➔ **Módulo 2 – Análise de estratégias financeiras:** avalia os custos e benefícios de diferentes estratégias de financiamento do risco, incluindo seus impactos em indicadores macroeconômicos, como crescimento econômico e níveis de endividamento.

O CATSIM usa simulações estocásticas de desastres em uma região específica para analisar a capacidade dos governos e do setor privado de financiar ações de resposta e recuperação após eventos severos. Por meio de simulações de Monte Carlo, o modelo avalia riscos de desastres e permite ao usuário testar diferentes suposições sobre ameaças, exposição, vulnerabilidade, condições econômicas e capacidade de resposta governamental. Como ferramenta interativa de capacitação, o CATSIM ilustra as compensações e decisões enfrentadas por autoridades na busca por maior resiliência frente aos riscos de desastres (Hochrainer-Stigler 2014; Hochrainer-Stigler et al. 2013).



Do ponto de vista metodológico, o CATSIM aborda o problema de decisão e modelagem como um problema decisório em duas etapas sob incerteza. O objetivo central é garantir financiamento suficiente e oportuno para que os governos possam cumprir suas obrigações pós-desastre, incluindo apoio ao setor privado e reconstrução de ativos públicos (Hochrainer-Stigler et al. 2013). As etapas são as seguintes:

- ➔ **Primeira etapa (ex-ante):** o governo pode destinar parte do orçamento a medidas de redução de risco (como construção de diques) ou à aquisição de seguros e instrumentos financeiros de proteção para ativos públicos (infraestruturas, edificações públicos) e apoio ao setor privado. Essas medidas, no entanto, reduzem o orçamento disponível para as atividades regulares de desenvolvimento, gerando custos de oportunidade.
- ➔ **Segunda etapa (ex-post):** após um desastre, são tomadas decisões orçamentárias emergenciais para financiar as necessidades de recuperação. No entanto, o financiamento exclusivamente ex-post afeta o orçamento destinado a investimentos de longo prazo.

O déficit de recursos que não pode ser coberto nem por opções ex-ante nem ex-post é denominado “brecha de recursos”. Essa brecha afeta negativamente variáveis macroeconômicas como o PIB, as receitas públicas e a posição fiscal, aumentando a vulnerabilidade financeira e os riscos futuros (Hochrainer-Stigler et al. 2013).

O CATSIM é implementado em cinco etapas principais (Hochrainer-Stigler et al. 2013):

- 1 Modelagem do risco de perdas diretas de ativos:** são calculadas as probabilidades de perda monetária em função da frequência e intensidade das ameaças, dos ativos expostos e de sua vulnerabilidade física.
- 2 Resiliência financeira e econômica:** é medida a capacidade do governo e do estado de mobilizar recursos financeiros para reconstrução da infraestrutura pública e apoio ao setor privado. A resiliência depende das condições econômicas gerais do país.
- 3 Vulnerabilidade financeira:** é avaliada por meio da simulação dos riscos para o setor público e da capacidade financeira do governo de cobrir suas responsabilidades pós-desastre em diferentes cenários de magnitude.
- 4 Impacto da brecha de recursos:** é analisado como essa brecha afeta variáveis macroeconômicas, como crescimento econômico e dívida externa, que refletem os impactos nos fluxos econômicos, complementando a estimativa de riscos sobre ativos físicos.
- 5 Desenvolvimento de estratégias de gerenciamento de riscos:** são desenhadas estratégias para fortalecer a resiliência fiscal e melhorar o portfólio de gerenciamento de riscos. Essas estratégias são revisadas periodicamente, considerando sua eficácia na redução da vulnerabilidade financeira dentro da estrutura de modelagem.



Na primeira etapa do CATSIM, é avaliado o risco de perdas diretas em termos da probabilidade de perdas nos ativos de um país ou região específicos. Seguindo as práticas gerais, o risco é modelado como uma função da ameaça, dos elementos expostos a essas ameaças e de sua vulnerabilidade física (Hochrainer-Stigler et al. 2013):

- ➔ **Ameaças naturais:** eventos como terremotos, furacões ou inundações são descritos por sua intensidade (por exemplo, vazões máximas para inundações) e recorrência (como eventos de 1 em 100 anos, ou seja, com 1% de probabilidade).
- ➔ **Exposição:** a exposição dos elementos em risco é estimada como o capital total público e privado suscetível a danos.
- ➔ **Vulnerabilidade física:** descreve o grau de dano que o capital pode sofrer em decorrência da ameaça. O método padrão consiste em estimar curvas de vulnerabilidade ou de fragilidade, que relacionam o grau de perdas à intensidade da ameaça.

Com base nessas informações, é possível estimar as perdas potenciais causadas por eventos destrutivos em termos do percentual de capital perdido em um país, estado ou região. Os dados sobre os períodos de retorno e as perdas servem como insumos para o CATSIM, gerando distribuições de frequência de perdas que relacionam probabilidades aos ativos destruídos.

### A.8.3. Avanços recentes e inovações

Está em desenvolvimento uma versão baseada na web para disponibilizar dados personalizados a países participantes de workshops, permitindo uma avaliação interativa de riscos de eventos extremos.

Além disso, a equipe de Risco e Resiliência do IIASA desenvolveu um módulo do CATSIM que quantifica o impacto interindustrial dos desastres. Esse modelo estima os custos econômicos dos desastres em diversos setores, levando em conta as estruturas produtivas existentes na economia e o tempo estimado de recuperação após o desastre. O modelo pode ser calibrado usando conjuntos de dados amplamente disponíveis, como tabelas de insumo-produto, e permite aos usuários visualizar o benefício econômico de uma melhor preparação fiscal (recuperação mais rápida diante de desastres). Esse módulo de software foi criado como parte do marco CATSIM e pode ser usado em avaliações de políticas públicas e em atividades de fortalecimento de capacidades. Estão sendo planejados novos desenvolvimentos de software, que incluirão ferramentas de interface e outros recursos de visualização (IIASA 2024a).

Nos últimos oito anos, a interface do usuário e a estrutura do modelo subjacente do CATSIM foram testadas, ajustadas e melhoradas em diferentes níveis. Esses avanços resultaram de mais de 20 workshops de alto nível com atores-chave realizados em países como Turquia, Filipinas, Índia, Nepal, México, várias nações do Caribe e, mais recentemente, Madagascar, em 2012 e 2015 (Hochrainer-Stigler et al. 2015).



## A.8.4. Comunidade de desenvolvimento

O IIASA tem trabalhado amplamente com diversas organizações internacionais, como o Banco Mundial e o Banco Interamericano de Desenvolvimento (BID). Além disso, tem colaborado com países específicos, como o México e várias nações do Caribe, para aplicar e otimizar o uso do CATSIM na gestão do risco de desastres.

## A.8.5. Limitações

O modelo foi projetado para análises em nível nacional, com foco na avaliação de impactos macroeconômicos e na formulação de estratégias financeiras para gerenciamento de riscos de desastres. Não se destina à avaliação de riscos em escalas locais. A versão atual do CATSIM é uma aplicação independente, o que pode limitar sua integração com outras ferramentas e sistemas usados na gerenciamento de riscos de desastres. Além disso, o modelo requer dados nacionais detalhados, o que representa um desafio para países com restrições de disponibilidade ou qualidade de dados.

## A.8.6. Casos de uso

O CATSIM foi usado em diversos projetos do Banco Mundial e em seu Relatório sobre o Desenvolvimento Mundial para estimar riscos de desastres em mais de 80 países. Também contribuiu para uma iniciativa do Banco Interamericano de Desenvolvimento (BID) voltada à criação do Regional Insurance Facility para a América Central, que apoia pequenos países na agregação de riscos e no acesso a capital externo para cobertura financeira. O CATSIM foi igualmente instrumental na concepção da Caribbean Catastrophe Risk Insurance Facility (CCRIF) em 2007 – o primeiro fundo regional de gerenciamento de riscos de desastres, apoiado pelo Banco Mundial e por doadores como o Departamento de Desenvolvimento Internacional do Reino Unido (DFID). Nesse mesmo ano, foi realizado um workshop em Barbados com países do Caribe para discutir estratégias de gerenciamento de riscos, o que contribuiu para identificar mecanismos mais eficientes de enfrentamento de desastres (IIASA 2024c).

Entre 2011 e 2012, o IIASA usou o CATSIM para apoiar um estudo do governo de Madagascar sobre a integração da gerenciamento de riscos de desastres e das mudanças climáticas no desenvolvimento econômico, após o impacto do ciclone Gafilo, que causou 363 mortes e danos equivalentes a 5% do PIB (consulte o **Quadro 8** para obter mais detalhes sobre esse estudo de caso).

Por fim, a análise CATSIM tem contribuído para as deliberações sobre o Mecanismo de Perdas e Danos da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC), incluindo a criação de um fundo global para absorver diferentes níveis de risco e apoiar o financiamento e a redução de riscos em países vulneráveis (IIASA 2024c).



## Quadro 9. Implementação do modelo CATSIM em Madagascar



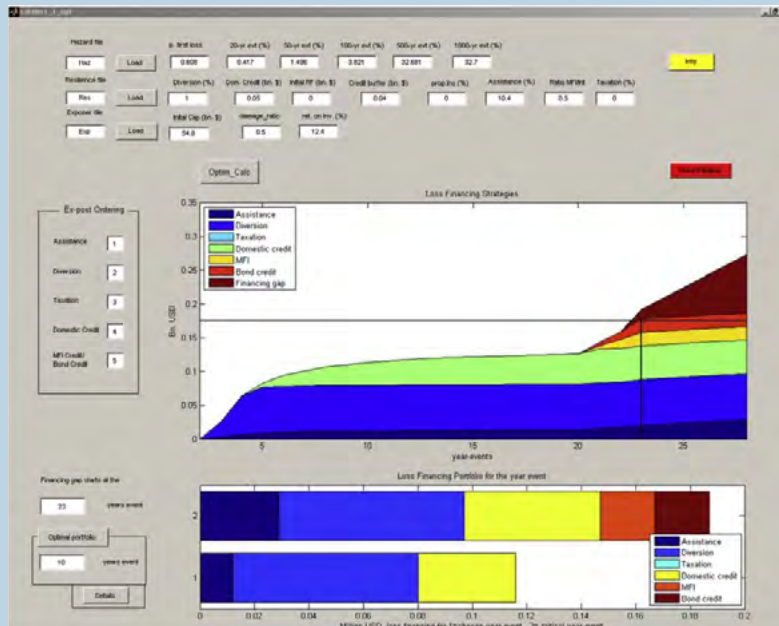
Em maio de 2012, Madagascar implementou o modelo CATSIM para integrar a gerenciamento de riscos de desastres ao planejamento fiscal e de desenvolvimento, com apoio do Banco Mundial e do GFDRR. O objetivo foi avaliar estratégias financeiras e de gerenciamento de riscos frente a eventos como ciclones, que causam perdas econômicas substanciais.

### **Workshop de 2012: avaliação preliminar de riscos**

O modelo CATSIM foi apresentado em um workshop com mais de 30 representantes ministeriais (finanças, educação e infraestrutura). Foram analisadas perdas históricas, estimativas preliminares de risco e possíveis lacunas financeiras diante de desastres.

Resultados da análise probabilística:

- ➔ Evento com período de retorno de 100 anos: perdas estimadas em US\$ 1,047 bilhão.
- ➔ Perdas anuais esperadas: média de US\$ 55 milhões.
- ➔ Recursos internos disponíveis: até US\$ 50 milhões, insuficientes para cobrir eventos com retorno superior a 23 anos.



Vulnerabilidade financeira e brecha de recursos em Madagascar, com base nas estimativas iniciais de risco direto. Nota: A figura central apresenta os períodos de retorno no eixo x e os recursos necessários/disponíveis no eixo y. A figura inferior é um gráfico interativo que permite aos usuários explorar os detalhes da alocação fiscal alternativa de recursos em diferentes períodos de retorno.

➔ **Principais conclusões:** foram identificadas brechas significativas nos dados de exposição e vulnerabilidade física, cuja melhoria foi priorizada para análises futuras.

## Workshop de 2015: avaliação atualizada

Com dados mais detalhados, o governo revisou suas estratégias financeiras, destacando opções como seguros e fundos de reserva. Também foram discutidos modelos internacionais, como o FONDEN e o CCRIF, com o objetivo de adaptar mecanismos de proteção financeira.

## Desafios e recomendações

**Fortalecimento institucional e integração de dados:** é fundamental melhorar a coleta e troca de informações interministeriais.

**Financiamento sustentável:** implementar instrumentos financeiros mistos para cobrir eventos frequentes e extremos.

**Planejamento integral:** integrar o gerenciamento de riscos às prioridades nacionais, como educação e saúde.

O uso do CATSIM em Madagascar evidencia a importância de equilibrar crescimento econômico e resiliência, promovendo cooperação interinstitucional e preparo proativo frente a eventos futuros.



## A.9. RISKCHANGES

### A.9.1. Descrição geral

Desenvolvido em colaboração pela Universidade de Twente e pelo Centro de Geoinformática do Instituto Asiático de Tecnologia (UN-SPIDER Regional Support Office), o RiskChanges funciona como um sistema de apoio à decisão espacial de código aberto, baseado na nuvem (RiskChanges 2021).

O RiskChanges oferece um conjunto de funcionalidades voltadas à realização de avaliações de risco. Sua capacidade multiusuário facilita a colaboração entre diferentes partes interessadas, permitindo o intercâmbio de dados e a geração coletiva de conhecimento. Além disso, a plataforma suporta avaliações multiameaça, considerando interações e efeitos cumulativos. Entre suas principais funções estão: análise de vários ativos, avaliação de vulnerabilidades, modelagem de cenários de risco, comparação de riscos e análise espacial avançada com recursos de visualização (PreventionWeb 2023).

### A.9.2. Métodos aplicados

A plataforma permite aos usuários analisar riscos associados a vários perigos naturais e antropogênicos, considerando suas interações; avaliar riscos para diferentes tipos de ativos com características espaciais variáveis; acessar e compartilhar uma base de dados de curvas de vulnerabilidade física; comparar riscos atuais e projeções futuras sob diferentes alternativas de redução de risco; e realizar análises espaciais de risco usando uma interface web baseada em mapas (RiskChanges 2021).

A seção de exposição do RiskChanges permite calcular a interação entre elementos expostos e ameaças previamente carregadas na plataforma. Para realizar esse cálculo, é necessário combinar uma camada de elementos em risco (EAR) com uma camada de ameaça, selecionando ambas a partir das opções disponíveis nas seções correspondentes do sistema de gestão de dados. Também é possível agregar os resultados a níveis administrativos específicos usando camadas previamente definidas. Se essa agregação não for desejada, o cálculo é feito no nível da camada EAR. Após a configuração dessas opções, o sistema calcula a exposição e os resultados podem ser visualizados ou baixados em formato tabular.

Com base na exposição calculada, é possível estimar as perdas totais, de acordo com o tipo de elemento em risco (EAR). Antes de prosseguir, é essencial definir previamente as relações entre valores e populações na seção EAR. Os usuários podem selecionar o tipo de cálculo desejado e, a partir de uma lista de exposições pré-calculadas, gerar estimativas de perda. Os resultados são apresentados em formatos visual e tabular, oferecendo informações detalhadas para a avaliação dos impactos de diferentes eventos (RiskChanges 2021).

O cálculo do risco no RiskChanges se baseia nas perdas previamente estimadas. Os usuários podem optar por realizar uma análise de risco para uma ameaça única ou para várias ameaças. No caso da análise multiameaça, o processo inclui etapas adicionais para integrar as combinações de perdas



associadas a diferentes períodos de retorno. Os resultados finais incluem métricas como a perda anual média (AAL) e são apresentados em formatos visual e tabular.

A interface de visualização do RiskChanges contém uma janela de camadas no canto superior esquerdo, na qual os usuários podem navegar entre os dados calculados ou agregados anteriormente – incluindo ameaças, elementos em risco, exposição, perdas e riscos. Os mapas interativos permitem aplicar filtros, editar estilos (como paletas de cores e opacidade) e realizar comparações lado a lado entre camadas.

### **A.9.3. Avanços recentes e inovações**

O RiskChanges permite visualizar e comparar resultados de diversas formas, proporcionando uma análise abrangente e flexível de cenários de risco. A plataforma integra dados diretamente a partir de servidores de mapas e aceita o carregamento de informações personalizadas em formatos GIS. Além disso, sua infraestrutura baseada na nuvem facilita o acesso, o processamento de dados e a colaboração em tempo real entre vários usuários, otimizando a gestão e a tomada de decisões em ambientes multiameaça (RiskChanges 2021). A versão mais recente é a 2.1.0, de junho de 2022.

### **A.9.4. Comunidade de desenvolvimento**

O RiskChanges foi desenvolvido pela Universidade de Twente e pelo Centro de Geoinformática do Instituto Asiático de Tecnologia (UN-SPIDER Regional Support Office). No entanto, não está claro se seu desenvolvimento continua ativo até o momento.

### **A.9.5. Limitações**










A plataforma requer que os usuários possuam conhecimentos básicos em sistemas de informação geográfica (GIS) e na interpretação de dados de risco. Além disso, a documentação disponível é bastante limitada, o que impede a plena compreensão dos métodos empregados.

### **A.9.6. Casos de uso**

O RiskChanges apresenta aplicações em diversas áreas, como avaliação e mapeamento de riscos, planejamento da redução de riscos, preparação e resposta a desastres e adaptação à mudança climática. Segundo o PreventionWeb (2023), há registros de uso da ferramenta no Nepal, Índia, Caribe e países da Comunidade de Desenvolvimento da África Austral (SADC), embora tenha sido encontrada pouca informação sobre essas aplicações. As informações disponíveis na plataforma CMINE são apresentadas no **Quadro 9**.

## Box 10. Exemplos de uso do RiskChanges

No site da plataforma CMINE, são apresentados três casos de aplicação do RiskChanges, embora com informações limitadas. Os exemplos mostram apenas os dados de ameaça usados, que não são gerados diretamente pela plataforma, e não apresentam exemplos de resultados analíticos ou visuais produzidos pelo RiskChanges. Não foi possível localizar informações adicionais sobre os estudos.

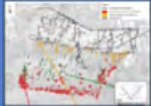
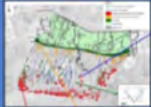

Risco de fluxo de detritos (DF) Pressão de impacto (IP)	Risco de inundação repentina (FL) Profundidade da água (DE)	Risco de tsunami (TS) Profundidade da água (DE)
 Período de devolução: 20 anos <b>DF_IP_20_A0</b>	 Período de devolução: 20 anos <b>FL_DE_20_A0</b>	 Período de devolução: 20 anos <b>TS_DE_20_A0</b>
 Período de devolução: 50 anos <b>DF_IP_50_A0</b>	 Período de devolução: 50 anos <b>FL_DE_50_A0</b>	 Período de devolução: 50 anos <b>TS_DE_100_A0</b>
 Período de devolução: 100 anos <b>DF_IP_100_A0</b>	 Período de devolução: 100 anos <b>FL_DE_100_A0</b>	 Período de devolução: 100 anos <b>TS_DE_200_A0</b>


**Situação atual**

Simulação de uma inundação fluvial no rio Koshi, no norte do Nepal. O modelo digital de elevação usado é uma estimativa satelital WorldDEM Neo, com resolução de 5 m, disponível comercialmente no mundo todo. Foi aplicada uma condição de contorno de vazão para simular um evento de fluxo extremo. Os coeficientes de rugosidade da superfície são estimados com base no uso integrado do WorldCover (10 m).

### Alternativa de redução de riscos

Simulação de inundações repentinas na área de Grande-Bay, em Dominica. Essa região foi gravemente afetada pelo furacão Maria em 2017. Um modelo de elevação personalizado com resolução de 10 metros foi carregado aqui, embora seja possível obter um resultado semelhante usando o conjunto de dados de elevação de 30 metros do Copernicus. O uso do solo e a precipitação foram carregadas pelas ferramentas integradas do FastFlood. As edificações e rodovias foram mapeadas automaticamente com dados do OpenStreetMap.

<b>Alternative 1:</b> <b>engineering solutions</b>	Storage basins Slope stabilization Expropriation of land and existing buildings where construction will take place	
<b>Alternative 2:</b> <b>ecological solutions</b>	Expropriation of land and existing buildings where construction will take place Slope stabilization Water tank construction	
<b>Alternative 3:</b> <b>relocation</b>	Compensation of owners of buildings Expropriation of existing buildings Lawsuits	

Possible future scenario:	Land use	
	2020	2050
S1 Business as usual	 LP_2020_A0_S1	 LP_2050_A0_S1
S2 Risk informed planning	 LP_2020_A0_S2	 LP_2050_A0_S2
S3 Worst case (Rapid growth + climate change)	 LP_2020_A0_S3	 LP_2050_A0_S3
S4 Climate resilience (informed planning under climate change)	 LP_2020_A0_S4	 LP_2050_A0_S4

### Cenários futuros

O rio Geul é um pequeno sistema fluvial localizado no sul dos Países Baixos, com uma pequena extensão na Bélgica e na Alemanha. Ele foi gravemente afetado pelas chuvas extremas de 2021 que atingiram o noroeste da Europa, causando danos severos em cidades como Valkenburg.

Essa simulação usa estimativas automáticas de infiltração, canal e elevação. Uma segunda área de modelo é definida para Valkenburg usando o algoritmo de aumento de escala. A extensão observada da inundação, publicada pelo Ministério Nacional da Água e Infraestrutura, é mostrada como uma sobreposição.

Fonte: RiskChanges (2021)



## A.10. FLOODRISK - QGIS PLUGIN

### A.10.1. Descrição geral

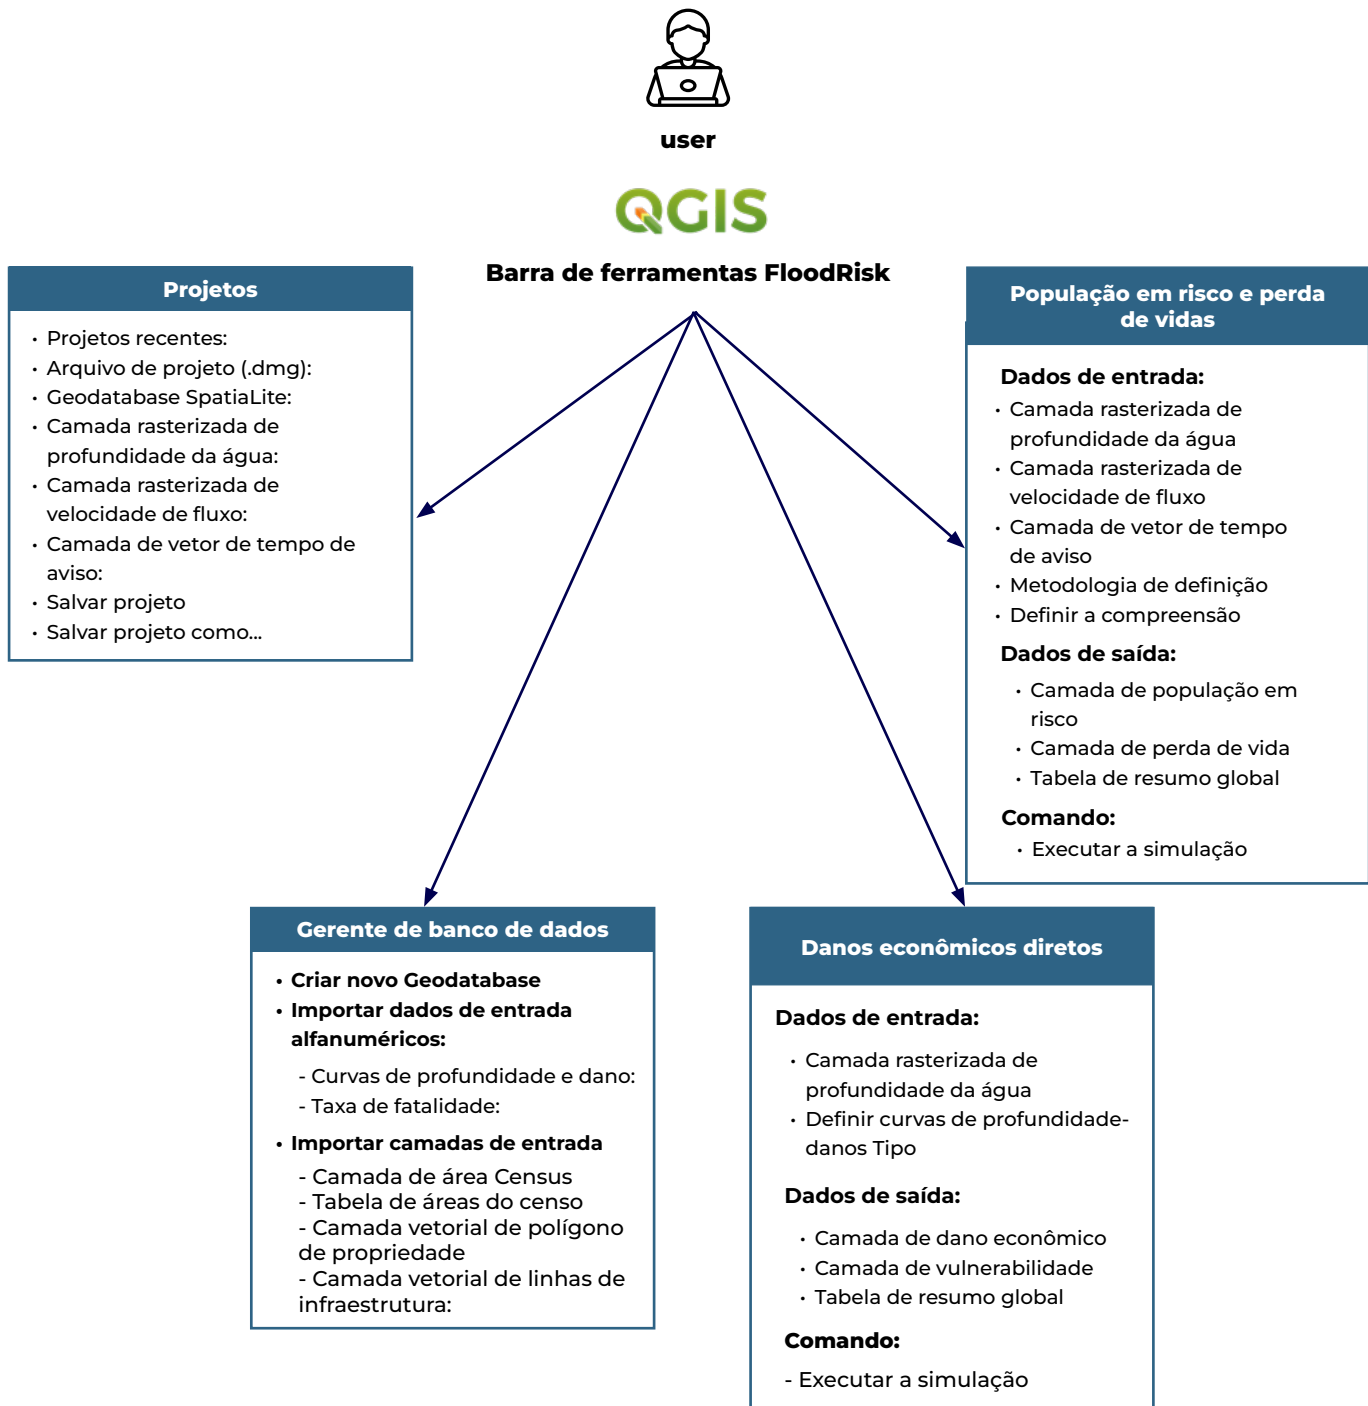
O FloodRisk é um plug-in gratuito e de código aberto para QGIS que fornece uma avaliação das consequências das inundações, incluindo a perda de vidas humanas e danos econômicos diretos. O plug-in permite que os usuários realizem uma avaliação de risco simples, considerando eventos fixos em que a probabilidade de cada evento é estimada separadamente e as consequências são calculadas de forma determinística.

Ele inclui tipos de custos diretos tangíveis e intangíveis, contempla estratégias de mitigação estruturais e não estruturais, pode ser usado para a análise de dinâmicas futuras (considerando a dinâmica dos riscos) e promove a colaboração e a comunicação com uma abordagem de código aberto (Albano et al. 2017c). A interface do usuário do FloodRisk é composta por cinco formulários principais (**Figura 55**). Esses formulários orientam o usuário no preenchimento da base de dados com informações próprias, permitindo criar ou modificar arquivos de projeto do FloodRisk e realizar análises de risco, ou seja, avaliar danos econômicos causados por inundações e estimar perdas de vidas humanas. A barra de ferramentas possibilita a ativação dos formulários principais. Além disso, o FloodRisk inclui diversos outros formulários – acessíveis a partir dos principais – que permitem representar dados de entrada e saída usando gráficos, tabelas e mapas.





**Figura 55. Interface gráfica do usuário do FloodRisk**



Fonte: Albano et al. (2017c).



## A.10.2. Métodos aplicados

O FloodRisk usa curvas de dano em função da profundidade para estimar danos econômicos diretos em propriedades residenciais, comerciais e industriais. Para a estimativa de perdas de vidas humanas, o sistema sobrepõe o mapa de inundação ao mapa de densidade populacional, gerando um mapa de população em risco. Em seguida, a perda de vidas é calculada multiplicando-se a população exposta pela taxa de fatalidade definida pelo usuário. Os resultados são apresentados em tabelas, gráficos (histogramas) e mapas (Albano et al. 2017c).

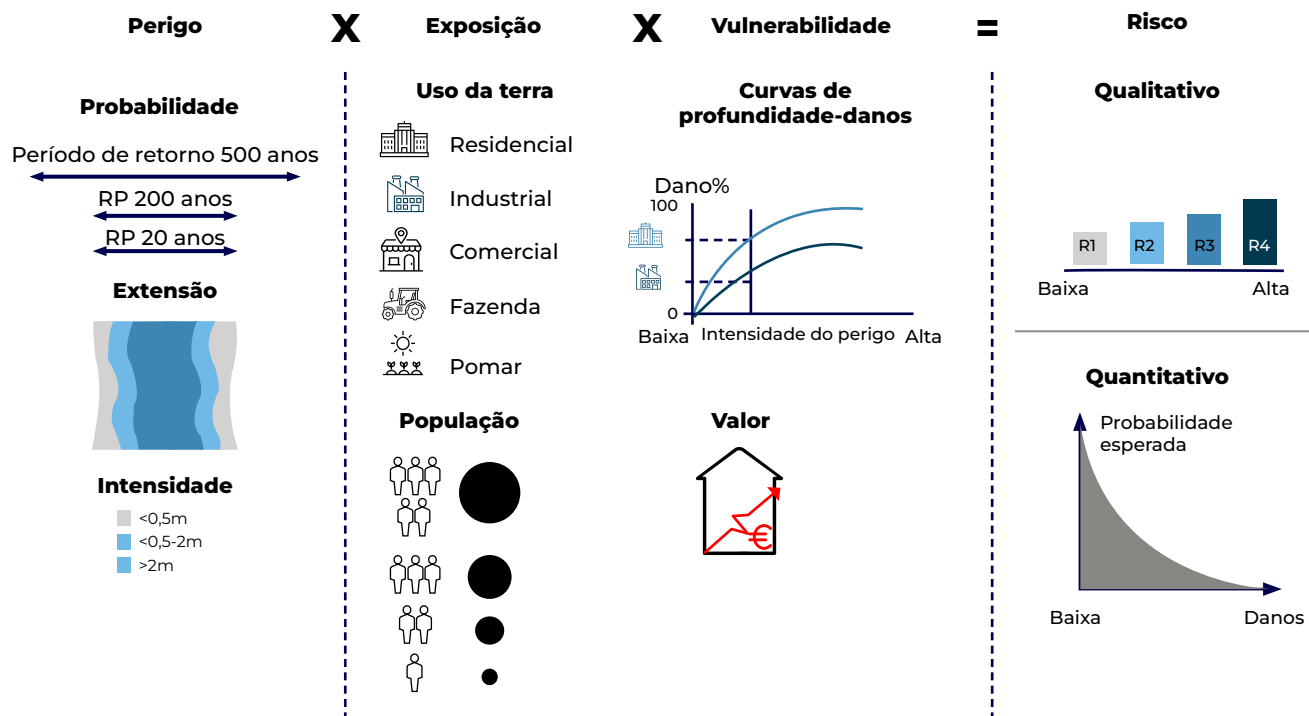
O plug-in permite estimar as consequências das inundações, incluindo a perda de vidas e os danos econômicos diretos, em conformidade com a abordagem da Diretiva Europeia sobre Inundações. O complemento integra diversas técnicas de avaliação do risco de inundação, incluindo abordagens meteorológicas, hidrológicas e socioeconômicas, dentro de uma estrutura baseada em SIG. Essa ferramenta apoia os responsáveis pela tomada de decisão na avaliação de estratégias de mitigação de inundações e promove práticas sustentáveis de gerenciamento de riscos.

O marco de trabalho do plug-in FloodRisk se baseia no método de perda unitária; portanto, os parâmetros que definem os elementos expostos, os valores de dano máximo e as funções de dano influenciam significativamente os resultados. Além disso, o FloodRisk permite o uso de uma abordagem baseada em objetos, que emprega um grande número de tipos de objetos, como um mapa de edificações ou uma abordagem de uso do solo – isto é, modelos baseados em superfícies agregadas, em que os dados de exposição são fornecidos na forma de um mapa de uso do solo (Albano et al. 2017c).

O marco conceitual do FloodRisk (veja a **Figura 56**) se baseia na modelagem de inundações com diferentes períodos de retorno, que, combinada com informações de exposição e vulnerabilidade, permite o cálculo dos danos. A partir dos danos por inundação associados a diferentes probabilidades, é possível construir uma curva de probabilidade de perda, com a qual se calcula o Dano Anual Esperado (EAD). No modelo de danos, podem ser implementadas diferentes medidas de redução do risco de inundação com o objetivo de calcular sua eficácia. Com relação à avaliação da vulnerabilidade, o FloodRisk segue uma abordagem padrão, que reflete tanto o potencial de dano de um receptor exposto quanto a quantificação de propriedades e pessoas suscetíveis a um evento de inundação específico. Assim, o risco de inundação é avaliado pela combinação entre os receptores expostos à ameaça e sua susceptibilidade, valor e resiliência. A susceptibilidade descreve a propensão de determinado receptor a sofrer dano durante um evento de inundação específico. O método padrão, usado no FloodRisk para definir a susceptibilidade dos elementos em risco e estimar os danos diretos causados por inundações, é o uso de funções de dano. Essas funções definem, para os respectivos elementos em risco, a relação entre as características da ameaça e da exposição e o dano esperado nas circunstâncias dadas. O valor é usado para expressar o grau de dano de um receptor e pode ser representado em termos monetários, como o valor máximo dos ativos, ou por impactos intangíveis (por exemplo, o número de pessoas que perdem a vida) (Albano et al. 2017c).



**Figura 56. Representação gráfica da abordagem FloodRisk.**



Fonte: Albano et al. (2017b).

### A.10.3. Avanços recentes e inovações

O FloodRisk teve cinco versões, sendo a mais recente lançada em outubro de 2020. Posteriormente, o FloodRisk foi substituído pelo FloodRisk2 para QGIS 3.x, oferecendo avaliação das consequências de inundações em termos de perda de vidas e danos econômicos diretos, bem como a avaliação quantitativa dos benefícios resultantes das medidas de mitigação (FloodRiskGroup 2021). A versão mais nova do plug-in, FloodRisk2, desenvolvida para o QGIS 3.x, incorpora funcionalidades extras e melhorias em relação à versão anterior, compatível com o QGIS 2.x. Entre os avanços estão maior integração com o QGIS e aperfeiçoamentos na interface do usuário. Pesquisas recentes exploraram a capacidade do complemento de analisar incertezas nas avaliações de danos por inundação, destacando a necessidade de curvas de vulnerabilidade específicas para cada local e de uma classificação detalhada das edificações para reduzir a incerteza epistêmica (Albano et al. 2018).

### A.10.4. Comunidade de desenvolvimento

O FloodRisk é desenvolvido e mantido pela comunidade FloodRiskGroup no GitHub, vinculada à Universidade de Basilicata.



## A.10.5. Limitações

Uma das limitações do plug-in é que ele realiza estimativas de risco com base em eventos associados a uma probabilidade específica. Essa abordagem geralmente envolve o uso de poucos eventos, e o sistema não foi originalmente concebido para executar centenas de simulações. Além disso, embora o plug-in permita ajustar taxas de fatalidade, elas podem não refletir adequadamente as condições específicas de cada cenário de inundação.

## A.10.6. Casos de uso

O FloodRisk tem sido usado em projetos de avaliação de risco de inundação na Europa. Foi empregado no estudo de caso da inundação de 2006 na bacia do rio Ilisua, na Romênia (Albano et al. 2017a) e no estudo de caso do Vale do rio Serio (Albano et al. 2017b), descrito no **Quadro 10**.



Imagem: Adobe Stock

## Implementação do FloodRisk no Vale do rio Serio: estudo de caso

---




Imagem: Adobe Stock

Com uma extensão de aproximadamente 600 km<sup>2</sup>, o Vale do rio Serio, na Itália, abrange 52 municípios e uma população total de cerca de 200 mil habitantes. O objetivo do estudo foi avaliar a viabilidade do uso da ferramenta FloodRisk em um contexto real, considerando limitações de dados e recursos, e verificar a eficácia dos resultados para subsidiar os Planos de Gerenciamento de Riscos de Inundação.

Foram usados os mapas de perigo da bacia do rio Pó, que indicam áreas inundáveis para diferentes períodos de retorno. A distribuição espacial da profundidade da água foi estimada a partir de níveis de referência em diversas seções transversais fornecidas pela autoridade da bacia do rio Pó. Além disso, mapas de uso e ocupação do solo e dados censitários foram empregados para identificar os ativos expostos ao risco.

As curvas de risco geradas com o FloodRisk, usando oito curvas de dano diferentes, são apresentadas na figura abaixo:



O FloodRisk permitiu avaliar o impacto de medidas estruturais e não estruturais na redução do risco socioeconômico. Foi realizada uma análise de custo-benefício de medidas locais para a reconstrução e manutenção de obras de proteção de rios, bem como medidas não estruturais, como sistemas de alerta precoce.

Os resultados do FloodRisk estão condicionados à disponibilidade e qualidade dos dados, o que gera incertezas significativas, especialmente nas curvas de dano em função da profundidade. Um análise de sensibilidade foi conduzida para avaliar a influência dessas curvas na estimativa quantitativa do risco econômico.

O FloodRisk demonstrou ser uma ferramenta eficaz tanto para análises qualitativas e quantitativas de risco de inundação quanto para elaboração de mapas de risco. Embora enfrente desafios como a disponibilidade de dados e a incerteza, ele oferece uma ferramenta robusta para apoiar a tomada de decisões na gerenciamento de riscos de inundação e no planejamento de medidas de mitigação.



## **A.11. FLOODRISE**

### **A.11.1. Descrição geral**

O FloodRISE (Flood Resilience, Insurance, and Spatial Equity) é um projeto liderado pela Universidade da Califórnia, em Irvine (EUA), que tem como foco melhorar a resiliência a inundações por meio do desenvolvimento de simulações de ameaça de inundação em alta resolução. O projeto tem como objetivo fornecer visualizações de risco de inundação que sejam úteis para a tomada de decisões locais, envolvendo as comunidades no processo de codesenvolvimento de mapas de perigo de inundação.

### **A.11.2. Métodos aplicados**

O FloodRISE usa simulações de ameaça de inundação em escala métrica para avaliar os riscos em diferentes tipos de inundações (costeiras, fluviais, pluviais). A abordagem inclui a participação iterativa das partes interessadas por meio de reuniões, pesquisas e sessões de capacitação para desenvolver mapas de perigo de inundação personalizados para cada comunidade.

### **A.11.3. Avanços recentes e inovações**

O projeto também abordou novos desafios associados a inundações costeiras, incluindo inundações molestas e compostas. Além disso, desenvolveu visualizadores online de ameaça de inundação, melhorando a compreensão e o gerenciamento de riscos nas comunidades envolvidas.

### **A.11.4. Comunidade de desenvolvimento**

O FloodRISE foi desenvolvido por uma equipe interdisciplinar da Universidade da Califórnia, Irvine, em colaboração com autoridades locais, comunidades residentes e demais partes interessadas. Essa abordagem colaborativa tem sido essencial para o êxito do projeto.

### **A.11.5. Limitações**

A principal limitação identificada é que, embora não tenha sido encontrada informação específica, parece que a ferramenta se destina apenas à visualização da ameaça, apesar de indicar em seu site que constitui uma contribuição para a análise de risco e a tomada de decisões. Outras limitações incluem a necessidade de dados de alta resolução e a dependência da participação contínua das partes interessadas locais para manter a relevância e precisão das visualizações.

### **A.11.6. Casos de uso**

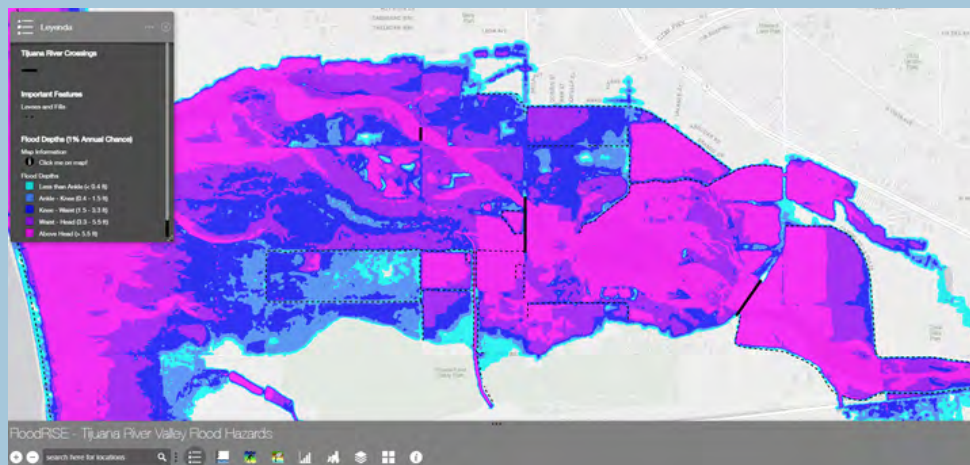
O FloodRISE foi implementado em diversas comunidades, incluindo o Vale do rio Tijuana e Newport Beach, onde ajudou a melhorar a preparação e resposta a inundações. Os mapas de perigo desenvolvidos têm sido usados para planejar e executar medidas de mitigação e adaptação a eventos de inundação.



## Quadro 12. Exemplo de aplicação do FloodRise

# Perigo de inundação no rio Tijuana

O site do projeto apresenta a ferramenta de visualização de mapas ilustrada na figura a seguir. Não foram encontradas informações adicionais.



Fonte: FloodRise (2024).

## A.12. Delft-FIAT

### A.12.1. Descrição geral

O Delft-FIAT (Flood Impact Assessment Tool) é uma ferramenta desenvolvida pela empresa Deltares que é usada para avaliar rapidamente os impactos econômicos diretos das inundações na infraestrutura, nas edificações e nas rodovias. Essa ferramenta de código aberto, baseada no Python, é particularmente útil no planejamento da adaptação climática, já que permite a modelagem rápida dos impactos de diferentes cenários de inundação e das medidas de mitigação correspondentes. O Delft-FIAT se destaca por sua capacidade de automação e flexibilidade, o que a torna uma solução adaptável para diferentes necessidades de análise.



O Delft-FIAT é rápido e pode ser automatizado. Ele permite a execução de várias simulações via scripts ou interfaces personalizadas, possibilitando a estimativa automática de centenas ou milhares de cenários de danos. Essa capacidade facilita a avaliação do risco futuro associado a fatores variáveis, como o aumento do nível do mar, a frequência de tempestades, o incremento das precipitações e o crescimento da população e da economia. Além disso, permite avaliar a eficácia de diferentes intervenções – como melhorias nos sistemas de drenagem, construção de diques, muros marítimos, bombas de drenagem, elevação de moradias ou medidas de proteção contra inundações – tanto nas condições atuais quanto em cenários em transformação (Deltares 2024b).

Cada simulação leva aproximadamente um minuto por cenário e pode ser executada em modo batch, permitindo o processamento automatizado de grandes volumes de dados. Sua arquitetura flexível possibilita a adaptação do software sem necessidade de alterar o código. O Delft-FIAT permite testar diferentes funções de dano por profundidade ou incorporar categorias de dano além das tradicionais, como danos a infraestruturas, interrupções no transporte ou impactos sobre atividades econômicas (Deltares 2024b).

Qualquer tipo de dano que possa ser descrito por uma função de dano por profundidade pode ser analisado com o Delft-FIAT. Os dados de exposição podem ser facilmente modificados e os mapas de perigo (mapas de inundação) podem ter qualquer origem. O Delft-FIAT também é personalizável, permitindo sua integração com interfaces de usuário sob medida para facilitar o uso por pessoas com menor experiência técnica. Além disso, pode ser conectado a ferramentas como Power BI, ArcGIS Online ou softwares de modelagem de inundações, e até mesmo integrado a sistemas operacionais de previsão (Deltares 2024b).

O software também oferece suporte a scripts personalizados para responder a questões específicas. Por exemplo, é possível analisar os impactos da incerteza na altura do piso das edificações ou nas funções de dano. Isso permite realizar análises de sensibilidade ou incorporar essas incertezas diretamente nas estimativas de danos (Deltares 2024b). Outra aplicação do Delft-FIAT é a identificação de pontos de inflexão – isto é, o momento em que uma intervenção de adaptação deixa de atender aos níveis de serviço desejados. Ao executar simulações sob condições futuras, é possível identificar esses pontos. Os usuários também podem selecionar métricas específicas para avaliar os níveis de serviço, como os danos anuais esperados, o número de moradias inundadas em um evento com período de retorno de 10 anos ou o número de famílias afetadas cujos rendimentos estejam abaixo do nível de pobreza (Deltares 2024b).

## A.12.2. Métodos aplicados

O Delft-FIAT usa uma metodologia baseada em funções de dano por profundidade para avaliar os danos econômicos causados por inundações. Essa abordagem permite modelar qualquer tipo de dano que possa ser representado por esse tipo de função. Além disso, sua arquitetura flexível possibilita modificar facilmente os dados de exposição e adaptar os mapas de perigo usados como insumo. O software foi projetado para processar grandes volumes de dados com rapidez.



### A.12.3. Avanços recentes e inovações

O código-fonte do Delft-FIAT se encontra em processo de reestruturação para melhorar o desempenho e a flexibilidade, e será disponibilizado como software de código aberto após sua conclusão.

Entre as novas funcionalidades em desenvolvimento (Deltares 2024b) estão:

- ➔ Geração automática de relatórios resumidos personalizados para cada simulação, incluindo métricas como:
  - número de residências danificadas;
  - quantidade de hospitais afetados;
  - extensão de rodovias inundadas acima de um limite definido pelo usuário;
- ➔ cálculo de danos ponderados por equidade, a fim de apoiar análises de custo-benefício mais justas;
- ➔ avaliação de impactos no bem-estar, visando realizar avaliações mais equitativas das opções de adaptação;
- ➔ criação de um construtor de modelos para o Delft-FIAT, destinado a facilitar e agilizar a configuração e modificação de modelos.

### A.12.4. Comunidade de desenvolvimento

O Deltares, organização de pesquisa aplicada nos campos da água e do subsolo, lidera o desenvolvimento do Delft-FIAT. O software é de código aberto e está disponível sob a licença GNU GPL v3. A comunidade de usuários inclui principalmente especialistas em risco de inundações e modelagem hidrológica, que podem contribuir para a melhoria do software usando plataformas como o GitHub.

### A.12.5. Limitações

A precisão dos resultados depende da qualidade dos dados de entrada, especialmente dos mapas de inundação e das funções de dano. Embora a ferramenta seja altamente automatizável, a configuração inicial e a adaptação dos dados de entrada podem exigir conhecimento técnico avançado.

### A.12.6. Casos de uso

O Delft-FIAT tem sido implementado tanto em comunidades com ampla disponibilidade de dados quanto em contextos com recursos e informações limitados. Ele constitui a base do modelo nacional de danos dos Países Baixos e contribuiu para projetos realizados nos Estados Unidos, Austrália, Ásia, África, Europa, Caribe, América Central e América do Sul, além de pequenos Estados insulares em desenvolvimento (Deltares 2024b).



Além disso, integra a ferramenta FloodAdapt, um sistema de apoio à decisão destinado a acelerar o planejamento de adaptação climática, atualmente em uso piloto nos Estados Unidos, Europa, Ásia e África (Deltares, 2024b).

O Delft-FIAT também foi incorporado a iniciativas como o projeto interTwin, no qual foi integrado a outros modelos para avaliar riscos de inundação e desenvolver estratégias de mitigação. Ele tem servido como recurso fundamental para governos e organizações no planejamento da adaptação às mudanças climáticas e na avaliação da eficácia de diversas medidas de mitigação de inundações.

### Quadro 13. Exemplo de aplicação do Delft-FIAT

## Caribe resiliente: aumento do nível do mar e potencial de adaptação

O Deltares e o Banco Mundial, em parceria com a Agência de Gestão de Emergências e Desastres do Caribe (CDEMA), aplicaram o Delft-FIAT para avaliar os impactos do aumento do nível do mar e o consequente agravamento das inundações e erosão costeira na região. O estudo teve como objetivo gerar indicadores regionais para estimar o potencial de resiliência e o potencial de adaptação de cada país caribenho.





## A.13. HEC-FDA

### A.13.1. Descrição geral

O software HEC-FDA (Hydrologic Engineering Center - Flood Damage Reduction Analysis) é uma ferramenta desenvolvida pelo Corpo de Engenheiros do Exército dos Estados Unidos (USACE). Seu principal objetivo é avaliar e quantificar os danos econômicos associados a eventos de inundação, auxiliando na tomada de decisões em projetos de redução de riscos de inundação. A HEC-FDA emprega métodos probabilísticos para analisar a relação entre a frequência das inundações e os possíveis danos, permitindo a estimativa de benefícios e custos associados a diferentes medidas de mitigação de riscos.

### A.13.2. Métodos aplicados

O HEC-FDA (Flood Damage Reduction Analysis) integra dados hidrológicos e hidráulicos, combinando-os com informações econômicas sobre estruturas e conteúdos para calcular os danos potenciais em função de diferentes cenários de inundação. Isso é obtido com análises de frequência de inundações, curvas de dano e funções de vulnerabilidade, permitindo uma avaliação detalhada e probabilística dos riscos e dos benefícios econômicos em projetos de mitigação de inundações.

A metodologia aplicada no HEC-FDA se concentra na avaliação do risco de inundação, definido como a combinação da probabilidade de ocorrência de um evento de inundação e suas consequências. Nesse contexto, a ameaça se refere ao evento que causa o dano – neste caso, a própria inundação. O HEC-FDA representa a ameaça usando funções hidrológicas e hidráulicas, que descrevem a frequência, a vazão, o nível da água, a extensão e a profundidade da inundação. O desempenho diz respeito à capacidade de um sistema, como um dique ou barragem, de responder à ameaça. O HEC-FDA avalia esse desempenho com base na elevação do dique e em uma curva de resposta do sistema, que relaciona a carga da ameaça à probabilidade de falha do sistema (USACE 2024a).

As consequências são medidas em termos de perdas econômicas resultantes de uma inundação. Para isso, o HEC-FDA usa funções que relacionam o nível da água ao percentual de dano nas estruturas e seus conteúdos, integrando essas informações em uma curva de dano-frequência.

A exposição descreve quem e o que estão sujeitos a danos em caso de inundação. No HEC-FDA, a exposição é geralmente representada por inventários de estruturas que contêm informações sobre a população e as propriedades potencialmente afetadas. A vulnerabilidade é representada por funções que correlacionam a profundidade da água com o percentual de dano, considerando também características estruturais, como a elevação do primeiro piso.

Como resultado da análise, o HEC-FDA calcula o Dano Anual Esperado (EAD), métrica que combina a probabilidade de ocorrência de um evento de inundação com suas consequências econômicas. Esse cálculo é realizado integrando as informações sobre a frequência do nível da água, o dano correspondente e a curva de dano-frequência (USACE 2024a).



Além do EAD, o HEC-FDA gera métricas de desempenho, incluindo a Probabilidade de Excedência Anual (AEP), que mede a probabilidade de ultrapassar um determinado nível em qualquer ano, e a Probabilidade Condicional (CNP), que indica a probabilidade de não ultrapassar um valor de referência, dado que ocorre um evento hidrometeorológico. O HEC-FDA permite, dessa forma, uma avaliação detalhada do risco de inundação, fornecendo tanto uma análise dos danos econômicos potenciais quanto uma avaliação da capacidade dos sistemas de defesa para gerenciar esses riscos (USACE 2024a).

Após o cálculo do EAD, o valor é interpolado entre os anos de análise, atualizado para o ano-base e amortizado para estimar o Dano Anual Médio Equivalente (Average Annual Equivalent Damage). Esse procedimento garante que as flutuações nos danos esperados ao longo do tempo sejam consideradas, ajustando os valores ao presente e permitindo comparações consistentes entre diferentes alternativas de redução do risco de inundação (USACE 2024b).

### A.13.3. Abordagem matemática

A quantificação da incerteza no HEC-FDA aplica a simulação de Monte Carlo para considerar explicitamente a incerteza nos parâmetros fundamentais usados na estimativa dos danos por inundação. Com esse método, cada parâmetro de entrada pode ser expresso como uma distribuição empírica ou analítica, e os valores de cada simulação de Monte Carlo são selecionados com números aleatórios. Esse processo pode ser aplicado a todas as variáveis de entrada que apresentem incerteza na análise. O HEC-FDA depende de um gerador de números aleatórios e das distribuições empíricas e analíticas no motor estatístico para executar a simulação de Monte Carlo (USACE 2024c).

A incerteza pode ser incluída explicitamente na análise ao se assumir uma distribuição de densidade de probabilidade que melhor descreva o intervalo de valores plausíveis. A simulação de Monte Carlo substitui uma distribuição de probabilidade por uma amostra extensa de valores aleatórios, avaliando cada elemento dessa amostra para formar uma nova amostra dos resultados da análise.

A abordagem implementada no HEC-FDA, denominada amostragem de curvas, usa amostragem aleatória para alterar cada função no cálculo de risco dentro do seu intervalo de incerteza, produzindo uma realização individual de cada função. Cada função completa (frequência de vazão, nível da água, perda por inundação etc.) é substituída pela função amostrada aleatoriamente, gerando uma grande amostra de curvas de saída.

Para realizar o cálculo de risco tradicional, obtém-se a vazão máxima para determinada frequência e relaciona-se com um nível d'água, o qual é associado a um ponto na curva de vulnerabilidade ou curva de dano por nível para todas as frequências, com o objetivo de desenvolver uma distribuição de probabilidade dos danos (curva de frequência de danos). O processo de amostragem de curvas de Monte Carlo realiza o mesmo princípio, mas em vez de uma relação ponto a ponto, amostra uma curva inteira dentro do seu intervalo de incerteza. O HEC-FDA usa a simulação de Monte Carlo para gerar novas iterações de curvas, selecionando aleatoriamente parâmetros dentro das faixas de incerteza que cercam cada função. Ao selecionar aleatoriamente parâmetros que representam, por exemplo, uma curva de

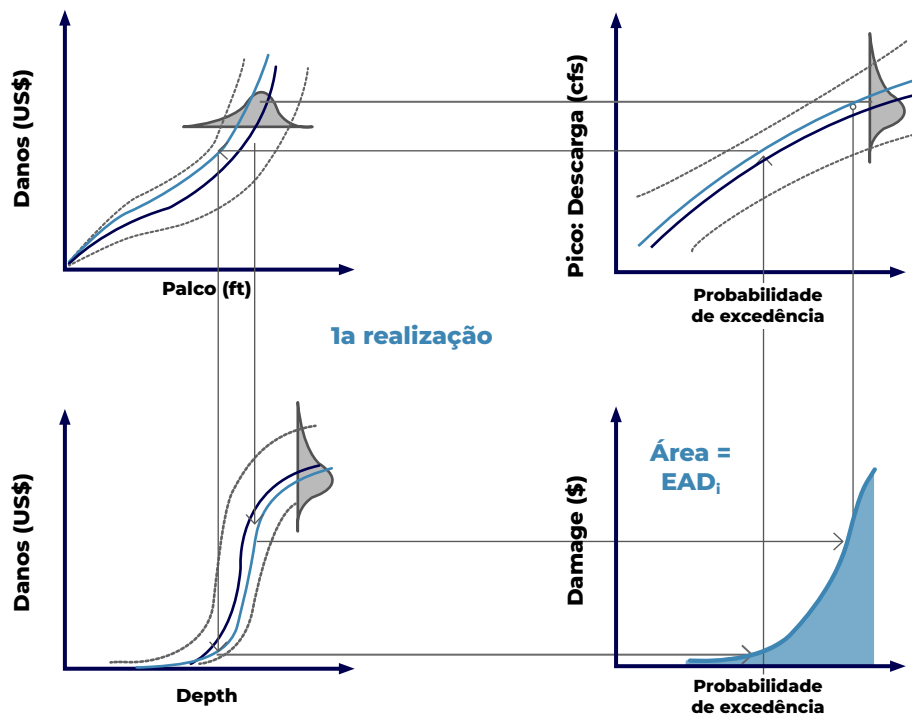


frequência de vazão, a curva se altera aleatoriamente, refletindo a variabilidade estocástica dos eventos hidrológicos. Cada execução gera uma nova curva, da qual se extraem dados para análise. Esse processo é repetido várias vezes, formando uma amostra de valores do EAD que, quando representada graficamente, pode ser descrita por medidas de tendência central e dispersão (ou seja, média e percentis). A amostra do EAD representa a incerteza total associada às variáveis de entrada usadas na estimativa.

A **Figura 57** ilustra o processo de uma realização do método de amostragem de curvas, que produz uma estimativa do EAD. Os limites de incerteza e distribuições são representados pelas curvas em forma de sino e linhas pontilhadas. Com a amostragem aleatória repetida (análise de Monte Carlo), as distribuições de incerteza são reproduzidas para capturar explicitamente a incerteza no cálculo de risco e nas métricas de risco. São necessárias milhares de iterações para representar plenamente a incerteza associada a cada função e, conseqüentemente, ao EAD.

are replicated to explicitly capture uncertainty in the risk calculation and risk metrics. Thousands of realizations are needed to fully reproduce the uncertainty around each function and thus around the EAD.

**Figura 57. Cálculo de risco incluindo a incerteza com amostragem de curvas**



Fonte: USACE (2024c).

Matematicamente, o EAD é definido por uma equação que integra a função de densidade de probabilidade do dano esperado em todo o domínio de probabilidade, capturando, assim, toda a faixa de possíveis danos em um único valor, conforme ilustrado na Equação 22.



## Equação 22

$$E[X] = \int_{-\infty}^{\infty} x f_x(x) dx = \int_{-\infty}^{\infty} (1 - F_x(x)) dx =$$

$$F_x(X) = P(X \leq x) \text{ y } 1 - F_x(X) = P(X > x)$$

Em que:

X = consequências (por exemplo, dano por inundação, perda de vidas, custos de atendimento de emergência).

$E[X]$  = valor esperado das consequências

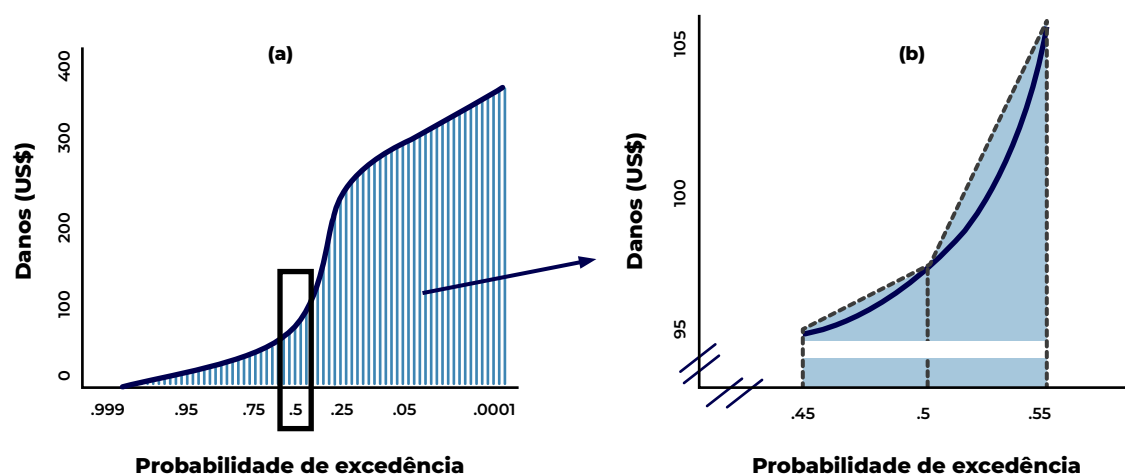
x = valor das consequências

$f_x(x)$  = função de densidade de probabilidade da probabilidade de X

$F_x(x)$  = função de distribuição acumulada de X.

Essa integração é realizada de forma gráfica pelo HEC-FDA, aplicando a regra trapezoidal para calcular a área sob a curva de dano-frequência. Um exemplo da aplicação dessa regra é apresentado no painel (a) da **Figura 58**. Para cada intervalo de probabilidade de excedência, a área sob a curva é calculada como um trapézio, em que o topo é uma linha reta conectando dois valores consecutivos da função. Esse cálculo é repetido para intervalos de probabilidade de excedência entre 0 e 1. Como mostra o painel (b) da figura, a precisão da estimativa do EAD pode ser melhorada com a seleção de intervalos de frequência menores. O HEC-FDA usa intervalos muito reduzidos para obter maior precisão (USACE 2024d).

**Figura 58. Regra trapezoidal para integração de curvas**




Fonte: USACE (2024d).



A **Figura 59** correspondente ilustra um exemplo de estimativas do EAD derivadas da análise de Monte Carlo, mostrando o impacto das incertezas epistêmicas sobre o valor do EAD.

**Figura 59. Amostra do EAD incorporando a incerteza epistêmica usando Monte Carlo**



Fonte: USACE (2024c).

A distribuição do Dano Anual Médio Equivalente (AAED) é calculada assumindo a correlação perfeita entre a distribuição do Dano Anual Esperado (EAD) do ano-base e o EAD dos anos futuros. Em outras palavras, o primeiro percentil do EAD do ano-base e o primeiro percentil do EAD futuro são usados para calcular o primeiro percentil do AAED (USACE 2024e).

A redução de danos é calculada como a diferença entre os danos sem projeto e os danos com projeto, e esses danos podem ser expressos em termos de EAD ou AAED. Assume-se novamente a correlação perfeita entre as distribuições, de modo que o primeiro percentil da redução de danos resulta da subtração do primeiro percentil do cenário sem projeto pelo primeiro percentil do cenário com projeto (USACE 2024f).

Além do EAD, as métricas de desempenho do sistema de proteção contra inundações também são úteis e muito importantes. Essas métricas incluem a Probabilidade de Excedência Anual (AEP), a Probabilidade de Excedência de Longo Prazo (LTEP) e a Confiabilidade, ou Probabilidade Condicional de Não Excedência (CNP). A AEP e a LTEP podem ser calculadas de forma determinística, enquanto a Confiabilidade (CNP) é uma estatística que requer a incorporação da incerteza na avaliação de riscos (USACE 2024g).



Além do EAD, as métricas de desempenho do sistema de proteção contra inundações também são úteis e muito importantes. Essas métricas incluem a Probabilidade de Excedência Anual (AEP), a Probabilidade de Excedência de Longo Prazo (LTEP) e a Confiabilidade, ou Probabilidade Condicional de Não Excedência (CNP). A AEP e a LTEP podem ser calculadas de forma determinística, enquanto a Confiabilidade (CNP) é uma estatística que requer a incorporação da incerteza na avaliação de riscos (USACE 2024g).

### **A.13.4. Avanços recentes e inovações**

Entre as melhorias mais recentes do HEC-FDA, destaca-se a versão 1.4.3, que introduziu ajustes no cálculo de danos associadas a eventos de inundação de baixa frequência, como os usados em avaliações de segurança de barragens. Essa versão foi certificada pelo Centro de Especialistas em Planejamento para a Gestão do Risco de Inundações do USACE, assegurando sua aplicabilidade e precisão em estudos de planejamento e segurança de infraestruturas hidráulicas.

### **A.13.5. Comunidade de desenvolvimento**

O desenvolvimento do HEC-FDA é conduzido pelo Hydrologic Engineering Center do USACE, um centro especializado na criação de ferramentas e softwares para a gestão de recursos hídricos. A comunidade de desenvolvimento é composta por engenheiros, cientistas e planejadores, que colaboram na melhoria contínua do software, garantindo conformidade com as exigências técnicas e normativas dos estudos de gestão do risco de inundações. A plataforma permanece ativa e atualizada, com certificações e revisões periódicas que incorporam os avanços mais recentes em gerenciamento de riscos.

### **A.13.6. Limitações**

O software requer dados hidrológicos locais detalhados e precisos, bem como informações sobre estruturas existentes e sua vulnerabilidade a inundações. Sem esses dados, os resultados podem ser imprecisos ou não representativos. Além disso, a complexidade da interface e a necessidade de conhecimento técnico avançado podem dificultar seu uso por pessoal não especializado.

### **A.13.7. Casos de uso**

O HEC-FDA é usado principalmente na planificação de projetos de redução do risco de inundações. Ele foi implementado em estudos de segurança de barragens, avaliações de risco em áreas urbanas e na planificação de infraestruturas destinadas a reduzir a vulnerabilidade a eventos de inundação.



## Avaliação de danos causados por inundações na bacia do rio Neka (Irã) usando HEC-FDA

---



A bacia do rio Neka, localizada no extremo leste da província de Mazandaran (Irã), representa uma região crítica para o gerenciamento de riscos de inundações. Sua localização estratégica e características geográficas – como a nascente nas elevações de Shah Kooh, a desembocadura no Mar Cáspio e a cobertura florestal de aproximadamente 80% – tornam essa bacia uma área de estudo prioritária.

O rio Neka percorre cerca de 160 km e drena uma área de 2.004 km<sup>2</sup>. Ele apresenta uma declividade longitudinal de 1,9%, e o canal se torna mais sinuoso à medida que se aproxima da cidade de Neka.

Os caudais de inundação foram calculados para períodos de retorno de 2, 5, 10, 20, 25, 50, 100 e 200 anos, usando o HEC-RAS, com coeficientes de rugosidade de Manning obtidos usando estudos hidráulicos e inspeções de campo.



A análise de danos por inundações foi realizada considerando:

- ➔ Foram identificados seis tipos de cobertura do solo, conforme o uso predominante: residencial, comercial, industrial, público, parques e agrícola.
- ➔ As profundidades de fluxo obtidas do HEC-RAS para os diferentes períodos de retorno foram armazenadas em formato compatível com o HEC-FDA.

Aplicaram-se curvas de dano específicas para cada tipo de cobertura do solo.

Os seguintes resultados foram obtidos com a análise:

- ➔ Foi estimada a perda anual média na área urbana de Neka, o que permite priorizar as intervenções.
- ➔ Mapas de risco e zoneamento: Com base nos resultados do HEC-FDA, foram gerados mapas de zoneamento de risco de inundações, úteis para a planificação urbana e mitigação de riscos.
- ➔ Gerenciamento de desastres: Os resultados oferecem insumos técnicos fundamentais para o desenho de mapas de evacuação e a elaboração de planos de gerenciamento de desastres, incluindo estratégias de seguro contra inundações.



## A.14. OPENQUAKE

### A.14.1. Introdução ao OpenQuake

O OpenQuake é uma ferramenta de código aberto desenvolvida no Python pela Global Earthquake Model (GEM) Foundation. Ele foi projetado para a avaliação de risco sísmico com base em modelos probabilísticos. O OpenQuake permite simular eventos sísmicos e avaliar seus possíveis impactos em termos de danos e perdas econômicas. O motor do OpenQuake é instalado como um software independente, podendo ser operado com um plug-in do QGIS.

Esse plug-in foi significativamente ampliado em relação à sua função original, permitindo uma integração total com o OpenQuake Engine. Isso permite um fluxo de trabalho completo no qual os cálculos de ameaça e risco podem ser executados diretamente no ambiente QGIS, e os resultados são carregados como camadas vetoriais do QGIS. Os mapas gerados, como os de perigo, são estilizados automaticamente de acordo com os campos selecionados pelo usuário. Além disso, as curvas de risco podem ser geradas e visualizadas em uma janela específica de Visualização de Dados (GEM 2024a).

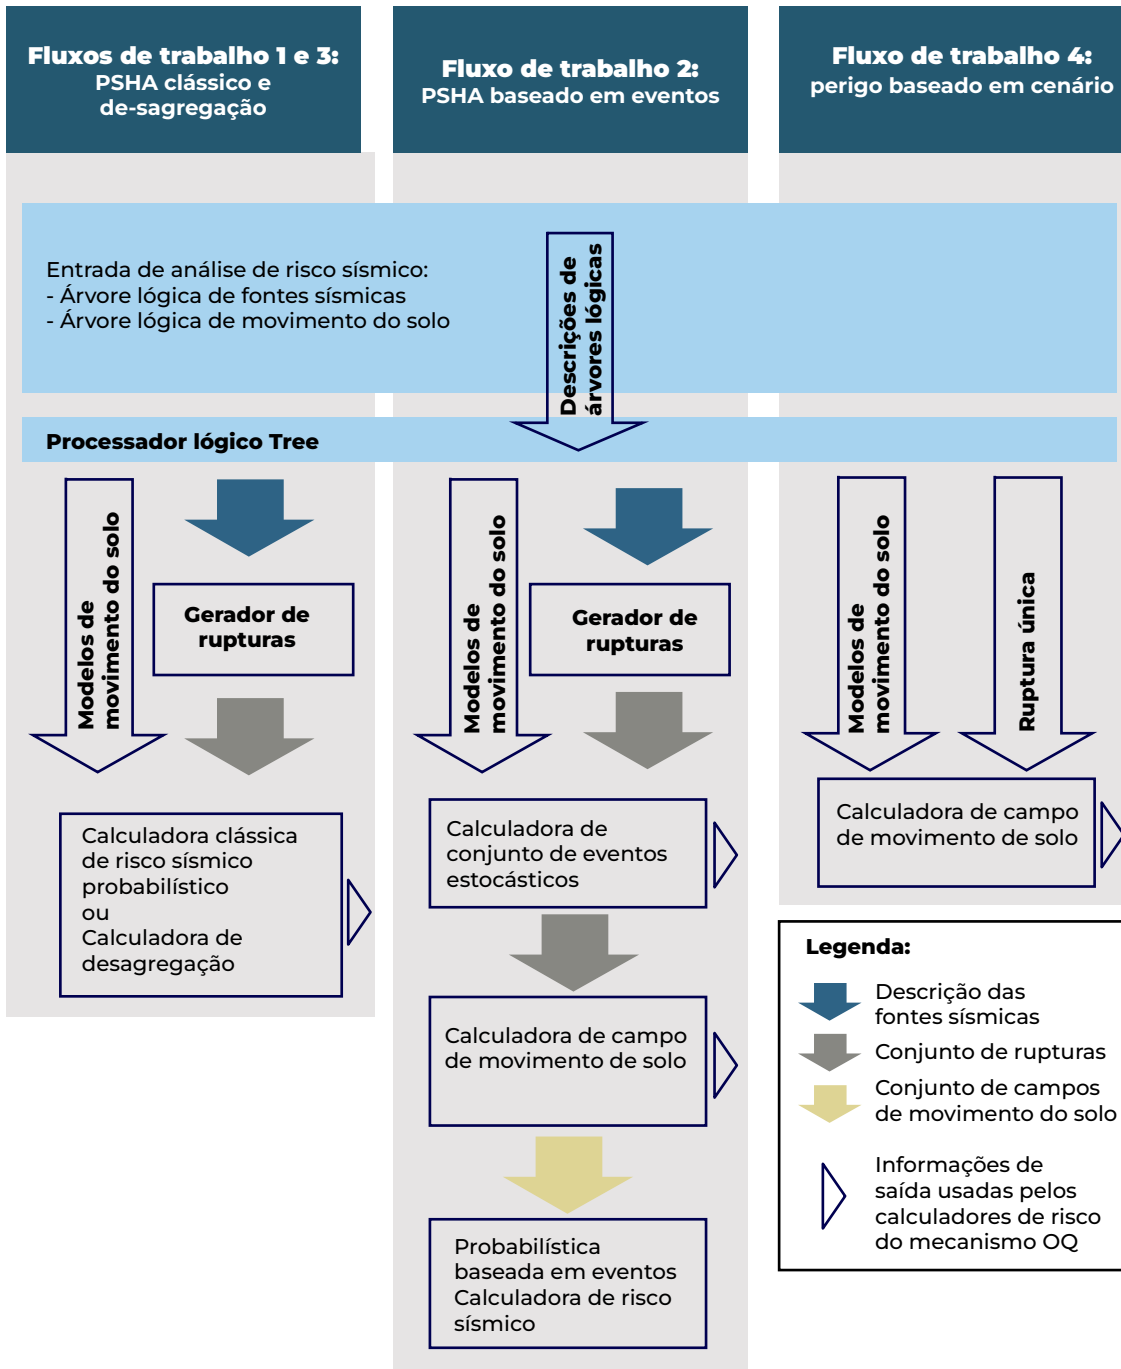
### A.14.2. Métodos aplicados

O OpenQuake usa uma variedade de métodos de cálculo de risco sísmico, incluindo a Análise Probabilística de Ameaça Sísmica (PSHA) e a análise baseada em eventos. A plataforma também permite realizar simulações de cenários sísmicos e avaliar as consequências de possíveis eventos sísmicos a partir da definição da ruptura de uma falha geológica.

O componente de risco do OpenQuake Engine disponibiliza quatro fluxos de cálculo principais, mostrados na **Figura 60**.



**Figura 60. Esquema dos principais fluxos de trabalho de cálculo do OpenQuake Engine disponíveis no componente de risco**



Fonte: GEM (2024d).



Os métodos usados estão descritos abaixo (GEM 2024d):

→ **Análise Probabilística de Ameaça Sísmica (PSHA) clássica:** Calcula curvas e mapas de perigo, bem como espectros de ameaça uniforme, resolvendo a integração PSHA proposta por Field et al. (2003). Usado em avaliações de ameaça em escala regional ou nacional e em estudos específicos de locais. Usa curvas de perigo em conjunto com modelos de vulnerabilidade e de exposição para derivar curvas de excedência de perdas e mapas de perdas para diferentes períodos de retorno.

→ **PSHA baseado em eventos:** Calcula conjuntos de eventos estocásticos e campos de movimento do solo para cada ruptura, incluindo a correlação espacial dos resíduos dentro do evento. Trata-se de um método baseado em Monte Carlo para PSHA. Os catálogos sintéticos gerados são comparados com catálogos reais, e, a partir dos campos de movimento do solo, são derivadas curvas de perigo e mapas de perigo. Esses campos são essenciais para as estimativas de perdas, somando-se as perdas por ativo em cada campo de movimento para

→ obter uma curva de excedência de perdas total representativa de todos os ativos.

**Desagregação:** Com um modelo de PSHA, identifica os cenários sísmicos que mais contribuem para um nível específico de ameaça em um determinado local. Atualmente, isso é feito conforme a metodologia clássica de PSHA, mas será incorporado ao calculador baseado

→ em eventos em fases futuras de desenvolvimento.

**Análise de risco sísmico (SHA) baseada em cenários:** Dada uma ruptura sísmica e um modelo de movimento do solo, podem ser calculados conjuntos de campos de movimento do solo. Esse método é típico de análises de perdas em escala urbana, pois permite captar a correlação das perdas entre os ativos de um portfólio. Esses campos são usados com um modelo de fragilidade/vulnerabilidade para calcular a distribuição de danos/perdas em um conjunto de ativos.

As principais fontes de informação necessárias, além da ameaça, para um cálculo de risco com o OpenQuake Engine são um modelo de exposição e um modelo de vulnerabilidade física ou modelo de fragilidade, além do tipo de cálculo e da região de interesse.

### A.14.3. Abordagem matemática

O OpenQuake oferece três tipos principais de cálculo, detalhados abaixo (GEM 2024d).

#### Cálculo baseado em cenários

O calculador de risco baseado em cenários do OpenQuake calcula perdas e estatísticas de perdas a partir de um único evento para uma coleção de ativos, usando um conjunto de campos de movimento do solo. Esses campos representam a variabilidade aleatória nas equações de previsão de movimento do solo e podem incluir ou não a correlação espacial dos resíduos do movimento do solo.



Etapas do cálculo:

- 1 Os níveis de intensidade em cada local são combinados com uma função de vulnerabilidade associada a cada ativo, da qual é extraída aleatoriamente uma taxa de perda.
- 2 O motor usa a função de vulnerabilidade atribuída a cada ativo e verifica se o coeficiente de variação é igual a zero. Se for o caso, as taxas de perdas são derivadas com base na relação de perdas médias para cada nível de medida de intensidade. Caso contrário, se houver incerteza definida, realiza-se uma amostragem aleatória seguindo a distribuição probabilística da respectiva função de vulnerabilidade,  $\log LR_n = \mu + \epsilon\sigma$ . Em que  $\mu$  e  $\sigma$  representam, respectivamente, a média e o desvio padrão do logaritmo das taxas de perdas, e  $\epsilon$  é um termo com distribuição normal padrão, média zero e desvio padrão igual a um. O método usado para amostrar  $\epsilon$  depende de considerar ou não a correlação entre a incerteza de vulnerabilidade dos ativos pertencentes a uma determinada taxonomia.
- 3 A taxa média de perda para cada ativo, considerando todas as simulações possíveis do evento no cenário, pode ser calculada pela fórmula:

### Equação 23

$$LR = \frac{\sum_{n=1}^m LR_n | IML}{m}$$

Em que  $m$  representa o número de campos de movimento do solo simulados e IML os níveis de medida de intensidade.

### Cálculo baseado em eventos probabilísticos

O módulo de risco probabilístico baseado em eventos usa conjuntos de eventos estocásticos e campos de movimento do solo para calcular curvas de excedência de perdas para cada ativo de um modelo de exposição. Esse processo combina níveis de medida de intensidade com funções de vulnerabilidade, a fim de determinar taxas de perda, que podem ser independentes ou correlacionadas. As perdas são calculadas para todos os campos de movimento do solo e ordenadas por taxa de perda. Em seguida, são determinadas a taxa de excedência e a probabilidade de excedência correspondentes a cada taxa de perda. Também é possível realizar uma desagregação das perdas por magnitude/distância ou por coordenadas geográficas.

O procedimento estima as perdas individuais por ativo para cada evento, de forma análoga ao cálculo baseado em cenários, e depois ordena os resultados em ordem decrescente. A taxa de excedência de cada perda é calculada dividindo o número de excedências daquela perda pelo número de conjuntos de eventos estocásticos multiplicado pela duração de cada conjunto de eventos. Assim, a maior perda terá zero excedências; a perda imediatamente seguinte terá uma excedência, e assim sucessivamente.



A fórmula a seguir é usada para calcular a taxa de excedência:

#### **Equação 24**

$$\lambda (L_n) = \frac{NE_L}{TSES}$$

Em que  $\lambda$  representa a taxa de excedência do respectivo índice de perda,  $NE_L$  representa o número de excedências da perda em questão e  $TSES$  representa o período total considerado para todos os conjuntos de eventos estocásticos, isto é, o número de conjuntos de eventos estocásticos multiplicado pela duração de cada um.

Assumindo uma distribuição de Poisson no modelo de ocorrência, a probabilidade de excedência do conjunto de perdas em um determinado período pode ser derivada pela seguinte fórmula:

#### **Equação 25**

$$PE(L_n) = 1 - \exp - \lambda_n \times t$$

Em que  $t$  representa o período de tempo usado para gerar o conjunto de eventos estocásticos.

Para a desagregação das perdas, é necessário fornecer as coordenadas das localizações onde o procedimento será aplicado. O OpenQuake Engine então calcula, para os locais selecionados, a soma das perdas (considerando todos os ativos existentes em cada ponto) para cada evento sísmico simulado. Além disso, estima-se a distância de ruptura (Joyner-Boore) e as coordenadas do ponto mais próximo dentro da projeção vertical do plano de ruptura para cada local analisado.

O OpenQuake Engine calcula o intervalo (valores máximos e mínimos) das listas de magnitudes, distâncias, latitudes e longitudes de todos os eventos sísmicos. Com base no incremento definido para cada parâmetro, gera-se um conjunto de intervalos linearmente espaçados. Em seguida, as perdas de cada evento são agregadas conforme a combinação de magnitude/distância ou latitude/longitude em que se enquadram.

As perdas resultantes para cada par de parâmetros são então normalizadas dividindo-se pelo total de perdas de todos os eventos.

### **Cálculo de risco baseado na PSHA clássica**

A calculadora de risco baseada na PSHA clássica é usada para calcular curvas de excedência de perdas para ativos individuais, estimadas ponto a ponto, a partir de curvas de perigo. Essa calculadora requer curvas de perigo como entrada, as quais podem ser geradas pelo OpenQuake Engine. Atualmente, essa



calculadora só consegue estimar perdas diretas, embora perdas seguradas devam ser incorporadas em versões futuras.

Para usar essa calculadora, as curvas de perigo devem primeiro ser convertidas em funções de massa de probabilidade (isto é, probabilidades de ocorrência para um conjunto discreto de níveis de medida de intensidade). Para isso, o engine começa lendo os níveis de medida de intensidade das funções de vulnerabilidade discretas e calcula o valor central entre níveis consecutivos. Dois valores consecutivos definem os limites do intervalo de cada nível de medida de intensidade e, relacionando esses limites à curva de ameaça, o engine calcula as probabilidades correspondentes de excedência.

A probabilidade de ocorrência (PO) dos níveis de medida de intensidade que se enquadram em cada intervalo pode ser obtida subtraindo-se as probabilidades de excedência dos limites inferior e superior, conforme descrito na fórmula a seguir:

#### **Equação 26**

$$PO = PE [lowerbound] - PE [upperbound]$$

As funções de vulnerabilidade discretas para cada ativo são convertidas em matrizes de excedência de índices de perda (ou seja, matrizes que descrevem a probabilidade de excedência de cada taxa de perda para um conjunto discreto de níveis de medida de intensidade). Essas matrizes têm um número de colunas igual ao número de níveis de medida de intensidade definidos na função de vulnerabilidade e um número de linhas que pode variar desde a quantidade de índices de perda definidos pela função discreta até qualquer múltiplo desse número. Para representar adequadamente a distribuição probabilística das taxas de perda por nível de medida de intensidade, as probabilidades de excedência devem ser calculadas não apenas para as taxas de perda definidas pela função de vulnerabilidade, mas também para diversos valores intermediários entre taxas de perda consecutivas. Após diversos testes de sensibilidade, verificou-se que cinco valores intermediários entre taxas consecutivas é uma opção razoável; contudo, esse parâmetro pode ser ajustado pelo usuário.

Por fim, cada coluna da matriz mencionada é multiplicada pela probabilidade de ocorrência do respectivo nível de medida de intensidade (obtida das curvas de perigo) para gerar uma matriz de excedência condicional de taxas de perda. Em seguida, para cada taxa de perda, somam-se as probabilidades de excedência, resultando em uma curva de excedência de taxas de perda. O conjunto de taxas de perda dessa curva pode então ser multiplicado pelo valor do ativo fornecido pelo modelo de exposição para produzir uma curva de excedência de perda absoluta.

### **A.14.4. Avanços recentes e inovações**

A versão 3.23 do OpenQuake Engine é uma atualização de Suporte de Longo Prazo (LTS) que oferece melhorias significativas de desempenho, especialmente para modelos de grande escala, com uma



velocidade de processamento de três a quatro vezes superior em comparação com a versão 3.16. A atualização introduz novas funcionalidades nos cálculos de risco e de ameaça, incluindo melhorias no tratamento de modelos de sítio, nos cálculos de cenários e na incorporação de novos Modelos de Predição de Movimento do Solo (GMPEs). Além disso, o projeto OQ-Impact foi integrado, ampliando as capacidades de avaliação de impacto, e diversos erros foram corrigidos para melhorar a estabilidade e a precisão do software (GEM 2024e).

No que diz respeito à funcionalidade, desde a versão 3.19 toda a documentação associada ao uso da plataforma foi unificada e migrada para um site (<https://docs.openquake.org/oq-engine/master/manual/index.html>), o que melhora sua acessibilidade e facilita a localização das informações necessárias.

### **A.14.5. Comunidade de desenvolvimento**

O OpenQuake Engine é desenvolvido com uma colaboração estreita e contínua entre as equipes científicas e de TI da GEM. O processo de desenvolvimento ocorre de forma aberta, incentivando a participação de especialistas que atuam nas áreas de análise de risco e de ameaça sísmica, bem como de profissionais especializados em desenvolvimento de software (GEM 2024d).

O código do OpenQuake está disponível no GitHub, o que garante um controle de versão completo e facilita o acompanhamento da implementação de novas funcionalidades e da correção de erros. Isso também assegura que versões anteriores do software possam ser recuperadas com facilidade. Quando um desenvolvedor envia um novo código ao repositório principal, o registro da alteração é preservado. Caso o código tenha como objetivo resolver um erro ou falha identificados no sistema de rastreamento, ou implementar uma nova funcionalidade em resposta a uma solicitação, o registro da contribuição deve indicar claramente o erro ou a funcionalidade que o código pretende resolver. Dessa forma, mantém-se um histórico completo e auditável de cada problema identificado e das alterações realizadas no código para solucioná-lo (GEM 2024d).

### **A.14.6. Limitações**

Dada sua longa trajetória e a existência de uma comunidade ativa de desenvolvimento que realiza melhorias contínuas na plataforma, as limitações do OpenQuake estão mais relacionadas à sua funcionalidade do que à sua capacidade. Por ser uma ferramenta capaz de lidar com modelos altamente complexos, pode apresentar uma curva de aprendizado acentuada, principalmente para usuários com pouca experiência em modelagem de risco – razão pela qual os próprios desenvolvedores recomendam formação de nível de mestrado em sismologia para uso adequado da plataforma.

Atualmente, a ferramenta conta com um site dedicado exclusivamente ao treinamento no uso da plataforma (<https://www.training.openquake.org/>), que disponibiliza diversos módulos e recursos voltados para usuários iniciantes. No entanto, esses materiais foram desenvolvidos em 2020, com base na versão 3.9 da plataforma, e se encontram em grande medida desatualizados.



Além disso, trata-se de uma ferramenta desenvolvida exclusivamente para riscos sísmicos, o que exige um grau elevado de especialização e dedicação, embora seu uso se restrinja a uma única ameaça. Isso implica a necessidade de múltiplas plataformas, modelos e profissionais para realizar avaliações de risco em contextos multiameaça. It is not to have multiple platforms, models and professionals to assess risks in a multi-hazard context.

### A.14.7. Casos de uso

O OpenQuake tem sido usado em diversos projetos de avaliação de risco sísmico em escala mundial. Há exemplos de aplicação na América Latina, Estados Unidos, Europa, Ásia e África (Azizi 2024).



Imagem: Adobe Stock

## Estudo de caso: Implementação do OpenQuake para a Avaliação do Risco Sísmico na Índia



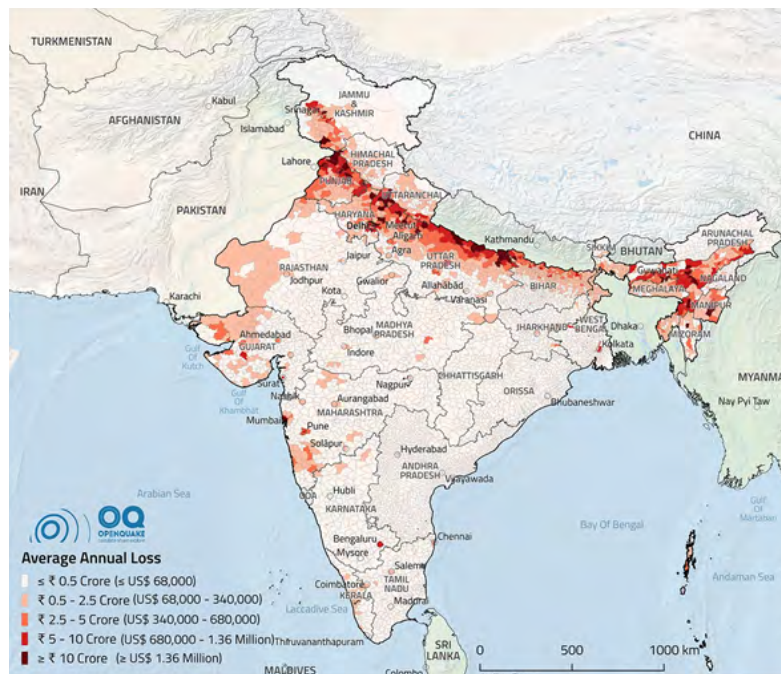
Imagem: Adobe Stock

O risco sísmico probabilístico para a Índia foi estimado usando a plataforma OpenQuake, com o objetivo de melhorar a compreensão das ameaças e dos riscos sísmicos em todo o país. Esse modelo funciona como uma ferramenta essencial para avaliar exposição, vulnerabilidade e risco, permitindo definir metas racionais de mitigação e priorizar investimentos em gerenciamento de desastres.

O estudo destaca os desafios enfrentados na elaboração de um modelo nacional de risco sísmico, especialmente a falta de informações detalhadas sobre o inventário atual de edificações e a escassez de modelos de fragilidade e vulnerabilidade sísmica para diversos tipos de edifícios no país. As avaliações anteriores se concentraram principalmente em análises baseadas em cenários para cidades específicas que, embora úteis, não oferecem a resolução necessária para uma análise de risco em escala nacional.

O OpenQuake Engine foi usado para calcular métricas de ameaça sísmica, incluindo a aceleração máxima do solo (PGA) e acelerações espectrais, adotando uma abordagem de Análise Probabilística de Ameaça Sísmica (PSHA). O modelo incorpora uma ampla variedade de tipologias e práticas construtivas, permitindo compreender o risco em diferentes regiões. Os resultados incluem mapas de perigo médio e curvas de excedência de perdas, que são fundamentais para atividades de planejamento e preparação.

### Mapa da perda anual média para a Índia obtida com o OpenQuake



O estudo também ressalta a importância da melhoria contínua do modelo por meio de avaliações locais e da coleta de dados empíricos. A natureza aberta dos conjuntos de dados e dos componentes do modelo favorece a colaboração entre especialistas e partes interessadas, promovendo uma abordagem orientada pela comunidade para a gestão do risco sísmico.

Em síntese, a implementação da plataforma OpenQuake para a avaliação do risco sísmico na Índia representa um avanço significativo no campo da redução do risco de desastres. O modelo não apenas oferece informações essenciais para melhorar os códigos nacionais de projeto sísmico, como também serve de base para futuras pesquisas e para decisões informadas sobre riscos em áreas suscetíveis a terremotos.

Fonte: Rao et al. (2020)



## ANNEX B. ANNEX TYPES OF DATA

---

The main types of data required for hazard, vulnerability and exposure assessment in disaster risk studies, as well as their common formats and the software tools used for their processing are:

- **Vector data:** represent geographic elements using geometries such as points, lines and polygons. Each geometry is associated with an attribute table containing descriptive information about that element (ESRI, Esri Products, s.f.)

**Points:** represent unique locations, such as wells, sensors or weather stations.

**Lines:** represent linear elements such as rivers, streets or electrical networks.

**Polygons:** represent areas such as lakes, agricultural areas or administrative boundaries.

**Most common extensions:** .shp, .geojson, .dwg, .dxf, .kml

- **Point clouds:** are massive sets of points in 3D space, each with X, Y, Z coordinates and sometimes with additional information such as intensity or classification (soil, vegetation, buildings). They are commonly generated by LiDAR (Light Detection and Ranging) sensors from drones or airplanes.

These point clouds allow the creation of 3D models of terrain, buildings or vegetation, and can be used to generate products such as Digital Elevation Models (DEM) or Surface Models (SLM). (Neuvition, s.f.).

**Most common extensions:** .las, .xyz

- **Raster and satellite images:** they are composed of a regular grid of pixels, where each pixel contains a value (such as color, temperature, elevation, etc.). These images are used to represent continuous phenomena on the earth's surface. Satellite imagery is a type of raster captured by remote sensors mounted on satellites. They can contain multiple spectral bands and allow analysis of variables such as vegetation (NDVI), temperature, soil moisture, and more (ESRI, Esri Products, s.f.).

**Most common extensions:** .tiff, .geotiff, .img.



- **Spatio-temporal data:** contains georeferenced information that varies over time. That is, they not only have a spatial dimension (latitude, longitude, altitude), but also a temporal dimension (hour, day, year, etc.). This type of data allows the analysis of changes in climate, weather patterns, evolution of hazards, among others. (NOAA, s.f.)

**Most common extensions:** .nc, grib

The following table summarizes the main extensions and data types used:

**Table 1. Data types, formats and tools used.**

Data	Data type	Common Formats	Analysis Tools / Software
<b>Geospatial data</b>	Elevation, slope, relief (DEM, DTM), contour lines	<ul style="list-style-type: none"> <li>• .tif,</li> <li>• .asc,</li> <li>• .las,</li> <li>• .xyz</li> </ul>	ArcGIS, QGIS, Global Mapper, CloudCompare, LAStools
	Land cover and land use	<ul style="list-style-type: none"> <li>• .tif,</li> <li>• .mgi,</li> <li>• .shp,</li> <li>• .geojson</li> </ul>	Google Earth Engine, ArcGIS, QGIS, SNAP
<b>Climatic and meteorological</b>	Precipitation, temperature, wind, extreme events	<ul style="list-style-type: none"> <li>• .nc,</li> <li>• .csv,</li> <li>• .grib,</li> <li>• .json</li> </ul>	R (climate4R), Python (xarray, pandas), GEE, Panoply
	Climate indices (NDVI, SPI, SPEI, FWI)	<ul style="list-style-type: none"> <li>• .nc,</li> <li>• .tif,</li> <li>• .csv</li> </ul>	R (raster, SPEI package), Python, ArcGIS Pro, GEE
<b>Socioeconomic and demographic</b>	Population density, poverty, critical services	<ul style="list-style-type: none"> <li>• .csv,</li> <li>• .shp,</li> <li>• .xlsx</li> </ul>	Tableau, Power BI, ArcGIS Insights, R (ggplot2, dplyr)
	Critical infrastructure and service networks	<ul style="list-style-type: none"> <li>• .shp,</li> <li>• .dwg,</li> <li>• .dxf</li> </ul>	AutoCAD, ArcGIS, QGIS
<b>Specific threats</b>	Geological faults, volcanoes, landslides, basins, etc.	<ul style="list-style-type: none"> <li>• .shp,</li> <li>• .tif,</li> <li>• .kml,</li> <li>• .geojson</li> </ul>	ArcGIS, QGIS, SAGA GIS, GRASS GIS
<b>Climate models</b>	Projections CMIP6, ERA5, CHIRPS, CRU	<ul style="list-style-type: none"> <li>• .nc,</li> <li>• .zip,</li> <li>• .grib</li> </ul>	Climate Data Store Toolbox, Python (xarray), Panoply, QGIS





