



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

Departamento de Obras Civiles

EVALUACIÓN DE CONVERGENCIA DE MODELOS ESTOCÁSTICOS DE ORDEN REDUCIDO PARA LA OBTENCIÓN Y UTILIZACIÓN DE MAPAS DE INUNDACIÓN EN ANÁLISIS PROBABILÍSTICOS DE PELIGRO DE TSUNAMI EN LAS COSTAS CHILENAS

Memoria de Título presentada por

Cristián Ignacio González Escobar

como requisito parcial para optar al título de la carrera de

Ingeniería Civil

Profesor Guía

Patricio Andrés Catalán Mondaca

Octubre de 2025



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado
Evaluación de convergencia de modelos estocásticos de orden reducido para la obtención y utilización de
Título del trabajo: mapas de inundación en análisis probabilísticos de peligro de tsunami en las costas chilenas

Nombre del candidato(a): Cristián Ignacio González Escobar

Carrera / Grado: Ingeniería Civil

Campus: San Joaquín Departamento: Obras Civiles

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Patricio Andrés Catalán Mondaca, en mi calidad de profesor(a) guía/director(a)
del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

☒ El trabajo **NO** contiene información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (embargo) por (marcar una opción):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 4 NOV 2025

Firma: 

Estudiante o Candidato(a):

Fecha: 4 NOV 2025

Firma: 

Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.



UNIVERSIDAD TECNICA
FEDERICO SANTA MARIA

TÍTULO DE LA TESIS:

**EVALUACIÓN DE CONVERGENCIA DE MODELOS
ESTOCÁSTICOS DE ORDEN REDUCIDO PARA LA
OBTENCIÓN Y UTILIZACIÓN DE MAPAS DE
INUNDACIÓN EN ANÁLISIS PROBABILÍSTICOS DE
PELIGRO DE TSUNAMI EN LAS COSTAS CHILENAS**

AUTOR:

CRISTIÁN IGNACIO GONZÁLEZ ESCOBAR

TRABAJO DE MEMORIA, presentado como requisito parcial para optar al título de la carrera de INGENIERÍA CIVIL de la Universidad Técnica Federico Santa María.

	<u>Nombre</u>	<u>Firma</u>
Prof. Guía		
Miembro 1 Comisión		
Miembro 2 Comisión		

Santiago, Chile, Octubre de 2025

EVALUACIÓN DE CONVERGENCIA DE MODELOS ESTOCÁSTICOS DE ORDEN REDUCIDO PARA LA OBTENCIÓN Y UTILIZACIÓN DE MAPAS DE INUNDACIÓN EN ANÁLISIS PROBABILÍSTICOS DE PELIGRO DE TSUNAMI EN LAS COSTAS CHILENAS

Cristián Ignacio González Escobar¹, Patricio Andrés Catalán Mondaca¹

¹*Universidad Técnica Federico Santa María*

Resumen

Este estudio evaluó la aplicación de Modelos Estocásticos de Orden Reducido (SROM) en el marco de un Análisis Probabilístico de Peligro de Tsunami (PTHA) para las costas chilenas, utilizando una cantidad de muestras superior a la de investigaciones previas en la región. El catálogo de terremotos se generó a partir de escenarios de ruptura estocástica mediante la expansión de Karhunen-Loève, sobre los cuales se realizaron simulaciones de tsunami. Para evaluar el método, primero se aplicaron relaciones de escala con el fin de filtrar únicamente los escenarios con distribuciones de ruptura físicamente posibles. Posteriormente, se aplicó SROM tanto a los deslizamientos de ruptura como a las profundidades de flujo de tsunami, comparando las curvas de distribución acumulada obtenidas con las del modelo completo. Los resultados indican que los modelos basados en vectores reducidos presentan una representación adecuada del peligro y pueden ser una herramienta confiable para la evaluación y planificación de medidas preventivas frente a tsunamis, a medida que se incorporen otras fuentes de incertidumbre.

Palabras claves: SROM, PTHA, expansión de Karhunen-Loève, análisis probabilístico, tsunami, ruptura estocástica, terremoto, costas chilenas.

Índice

1. Introducción	7
2. Estado del Arte	9
2.1. Modelación de terremotos con patrones de deslizamiento y ubicación desconocida	9
2.2. Análisis híbrido de peligro de tsunami	10
2.3. Análisis probabilístico de peligro de tsunami en Chile central	11
2.4. Generación de mapas de inundación de tsunami combinados	13
2.5. Nuevos mapas probabilísticos de inundación de tsunami en Chile	14
3. Objetivos	16
3.1. Objetivo General	16
3.2. Objetivos Específicos	16
4. Metodología	16
4.1. Probabilistic Tsunami Hazard Analysis	16
4.2. Método Monte Carlo	18
4.3. Stochastic Reduced Order Models	19
4.4. Expansión Karhunen-Loève	22
4.5. Leyes de escala de Blaser	26
4.6. Selección de escenarios mediante SROM	26
5. Resultados	32
6. Discusión	52

7. Conclusión	56
----------------------	-----------

Referencias	58
--------------------	-----------

Índice de figuras

1. Distribución de la solución $F(x)$ a través de Monte Carlo, respecto a la misma solución mediante SROM dado un tamaño de muestra m (en rojo).	20
2. Área de estudio; contiene el dominio de las posibles áreas de ruptura para los escenarios sísmicos.	28
3. Área de estudio; contiene el dominio de los puntos de medición para las métricas de tsunami (eta, velocidad, momento de flujo, profundidad de inundación, entre otras).	29
4. Puntos del dominio de ruptura donde se aplica SROM.	30
5. Puntos del dominio de tsunami donde se aplicó el SROM para la profundidad de flujo.	31
6. Ejemplos de fuentes de tsunami filtradas mediante SROM para distintas magnitudes.	34
7. Curvas de distribución acumulada de profundidad de flujo para la ciudad de Arica.	35
8. Curvas de distribución acumulada de profundidad de flujo para la ciudad de Iquique.	36
9. Curvas de distribución acumulada de profundidad de flujo para la ciudad de Antofagasta.	37
10. Curvas de distribución acumulada de profundidad de flujo para la ciudad de La Serena.	38
11. Curvas de distribución acumulada de profundidad de flujo para la ciudad de Viña del Mar.	39
12. Curvas de distribución acumulada de profundidad de flujo para la ciudad de Valparaíso.	40

13.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de San Antonio.	41
14.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Talcahuano.	42
15.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Concepción.	43
16.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Coronel.	44
17.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Valdivia.	45
18.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Puerto Montt.	46
19.	Curvas de distribución acumulada de profundidad de flujo para la ciudad de Ancud.	47
20.	Curvas de distribución acumulada de deslizamiento para la ciudad de Antofagasta.	48
21.	Curvas de distribución acumulada de deslizamiento para la ciudad de La Serena.	49
22.	Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 8,6.	50
23.	Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 8,8.	50
24.	Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 9,0.	51
25.	Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 9,2.	51

1. Introducción

Chile es uno de los países sísmicamente más activos del mundo, particularmente, debido a su ubicación en el Cinturón de Fuego del Pacífico (Scholz, 2019). Los terremotos son la principal causa de tsunamis (Grezio et al., 2017), en especial, los terremotos submarinos que son los que incluyen la mayor cantidad de víctimas al ser naturalmente más destructivos (Lay, 2015; Lorito et al., 2015; Satake & Atwater, 2007; Synolakis & Bernard, 2006). Debido a esto, se entiende que una correcta caracterización, ya sea de los parámetros de los modelos de recurrencia o de la distribución del deslizamiento dado un escenario de ruptura, por ejemplo, son fundamentales para una estimación de la amenaza dentro de rangos confiables. Esto debido a que finalmente son estos resultados los que son utilizados para asesorar a las autoridades en planes de emergencia y evacuación, así como también para poder establecer marcos objetivos para el diseño de estructuras (Adriano et al., 2013; Cho et al., 2016; Grezio et al., 2017; Naim et al., 2021).

Los tsunamis son desastres naturales impredecibles e infrecuentes, pero con un gran potencial de impacto. Para prepararse, mitigar y prevenir pérdidas a causa de estos, se han desarrollado Análisis Probabilísticos de Peligro de Tsunami (PTHA) y métodos de análisis de riesgo, que han demostrado su utilidad. Sin embargo, aún existen grandes brechas e incertidumbres asociadas, además de que muchos pasos en los métodos de asesoramiento carecen de información, ya sea fundación teórica o métodos que sean aceptados por pares. Además, los métodos aplicados tienen distintos niveles de madurez, desde análisis probabilísticos de peligro de tsunami para eventos con fuentes de terremotos, a métodos probabilísticos menos desarrollados. Esto se debe a que, lógicamente, los terremotos no son la única fuente que puede provocar tsunamis en las costas. Existen diversas fuentes como deslizamientos de tierra submarinos, erupciones volcánicas submarinas, desprendimientos de glaciares e incluso meteoritos (Behrens et al., 2021).

Los análisis probabilísticos de peligro de tsunami (PTHA) ofrecen procedimientos estructurados y rigurosos que permiten el seguimiento y la ponderación de elementos claves en el entendimiento del potencial peligro y riesgo de tsunami con aplicaciones globales (*e.g.*, Basili et al., 2021). Debido a esto, realizar PTHA se está volviendo una base estandarizada para el asesoramiento de riesgo de tsunami alrededor del mundo. Sin embargo, aún existen desafíos relevantes en este método de análisis: en primer lugar, la selección de eventos hipotéticos y la asignación “correcta” de su probabilidad de ocurrencia, en segundo lugar, el impacto que genera la fuente distribuido a través de la morfología oceánica en un marco probabilístico homogéneo con un manejo de la incertidumbre controlado. La gran importancia del PTHA radica en sus implicaciones prácticas para la sociedad, otorgando información para la planificación y gestión costera a largo plazo en áreas donde potenciales tsunamis pueden ocurrir (Behrens et al., 2021).

El estudio mediante metodologías de PTHA proveen un marco para evaluar la probabilidad de que una medida dada de intensidad de tsunami (*e.g.*, máxima altura alcanzada por el agua en tierra firme) sea excedida en una ubicación particular para un período de tiempo dado. Debido a que los catálogos de tsunami históricos están inherentemente incompletos, se requiere combinar modelos de generación, propagación e inundación de tsunami (*e.g.*, Geist y Lynett, 2014) con probabilidades de la fuente sísmica para entregar estimaciones cuantitativas de la probabilidad de excedencia de distintos niveles de una métrica de tsunami determinada (Grezio et al., 2017).

Esta metodología está sujeta a la capacidad computacional disponible para realizar las simulaciones de generación, propagación e inundación no lineal de tsunami en modelos topobatimétricos de alta resolución (Lorito et al., 2015). Dicha capacidad computacional es la limitante principal en la utilización de modelos predictivos con escenarios generados aleatoriamente, ya que los tiempos de procesamiento para este tipo de cálculos son considerables (González et al., 2020). La aplicación del SROM busca justamente optimizar los tiempos de procesamiento en estos modelos para poder predecir de manera precisa sin tener una elevada demanda computacional (Grezio et al., 2017).

Actualmente, Chile cuenta con mapas de inundación de tsunami realizados por investigaciones del estado del arte (Aranguiz et al., 2024; Becerra et al., 2020; González et al., 2020; Zamora et al., 2021); sin embargo, no se tiene un consenso sobre cual es el método óptimo para generar los mapas de inundación considerando la incertidumbre asociada (Geist & Parsons, 2006; Lorito et al., 2015), las cuales pueden ser aleatorias o epistémicas. Sin embargo, el problema no radica únicamente en la complejidad por la cantidad de variables que inciden en la modelación, sino en mantener la precisión de los resultados obtenidos disminuyendo el costo computacional que implica la cantidad de escenarios que se deben evaluar (Sepúlveda et al., 2017), así como saber cuánto efectivamente se puede reducir la cantidad de muestras.

El propósito al que sirve la presente investigación, es verificar si SROM es un método utilizable en el contexto de estudios bajo la metodología PTHA y analizar la posibilidad de reducir la cantidad de muestras seleccionando escenarios representativos (Aranguiz et al., 2024) sin alejarse de la precisión de los resultados obtenidos con métodos sin reducción de escenarios (*e.g.*, Monte Carlo clásico), permitiendo tiempos de procesamiento considerablemente menores. Por otro lado, también busca contrastar el SROM en el contexto de PTHA con modelos completos con miles de escenarios para analizar su convergencia, esto es crucial debido a las posibles aplicaciones que tiene en el contexto a nivel país y a nivel global, pudiendo servir como un método práctico para alertar a las autoridades y salvar la mayor cantidad de víctimas ante un posible evento de tsunami en las costas del país.

2. Estado del Arte

2.1. Modelación de terremotos con patrones de deslizamiento y ubicación desconocida

Sepúlveda et al., 2017 constituyen una de las primeras aplicaciones formales del Probabilistic Tsunami Hazard Analysis (PTHA) en Chile, al incorporar la modelación explícita de las incertidumbres asociadas a la ubicación y distribución del deslizamiento sísmico. Utilizando relaciones de escala para definir los parámetros del plano de falla (Blaser et al., 2010; Raghukanth & Sangeetha, 2016; Strasser et al., 2010), el estudio genera escenarios de ruptura estocásticos para evaluar su impacto en la simulación de tsunamis a través de la deformación del suelo marino, como resultado de la dislocación en un plano de falla durante un terremoto (Kozdon & Dunham, 2013; Lay et al., 2012; Scholz & Campos, 2012).

El aporte principal de esta investigación radica en la implementación de la expansión Karhunen-Loève (LeVeque et al., 2016) sobre campos gaussianos, lo que permite representar espacialmente la variabilidad del deslizamiento de forma compacta (Grigoriu, 2009), así, logran representar campos aleatorios de deslizamiento para distintos escenarios de falla. Posteriormente, utilizan el Stochastic Reduced Order Model (SROM) buscando reducir el número de simulaciones de tsunami requeridas respecto al método Monte Carlo clásico, manteniendo una representación consistente desde el punto de vista estadístico del campo de deslizamientos.

Para validar el enfoque, comparan los resultados obtenidos estocásticamente con registros del terremoto y tsunami de Iquique en 2014 (An et al., 2014; Gusman et al., 2015; Lay et al., 2014), dado que existen medidas del tsunami en distintos puntos de la costa, así como también mar adentro en estaciones DART (Meinig et al., 2005). Esto utilizando el modelo COMCOT para simular inundaciones (An et al., 2014; Gusman et al., 2015). Los resultados muestran que existe concordancia entre las mediciones realizadas en el tsunami de 2014 con los tsunamis estocásticos del estudio, así como que el método de generación de escenarios es consistente manteniendo las propiedades estadísticas objetivo definidas según la distribución de deslizamiento y la ubicación. Así, esta metodología minimiza el costo computacional para una precisión dada a la vez que admite áreas de ruptura no rectangulares, que son características de grandes eventos de terremoto. Por otro lado, también resaltan que utilizar el SROM para propagar incertidumbre permite estimar las incertidumbres del análisis de tsunami con mejor precisión que el método Monte Carlo clásico, con el mismo número de simulaciones o un menor costo computacional.

Sin embargo, el estudio presenta limitaciones importantes: el campo de deslizamiento se modela como homogéneo, sin considerar la disminución real del deslizamiento hacia los bordes de la ruptura; no se incorporan adecuadamente las incertidumbres batimétricas ni las deformaciones del fondo marino, y el enfoque se mantiene determinista bajo la lógica del “peor caso posible”. Por otro lado, utilizaron SROM para la selección de muestras de tsunami pero utilizaron un tamaño de muestras único, por lo que no se hace un análisis de convergencia a Monte Carlo para distintos tamaños de muestreo. Estas restricciones dificultan la generalización probabilística de los resultados y limitan la aplicabilidad del método para evaluar el peligro de tsunami a escala regional.

2.2. Análisis híbrido de peligro de tsunami

González et al., 2020 combinan enfoques determinísticos y estocásticos para evaluar el peligro de tsunami en Iquique, generando 400 escenarios estocásticos junto con 10 determinísticos y 10 casos homogéneos, cubriendo la brecha sísmica prevista para un posible evento $M_w \approx 9,0$. Para caracterizar la distribución espacial de trabazón (locking) en la falla, utilizan anomalías gravimétricas paralelas a la trinchera (PTGA) y anomalías topográficas paralelas (TPTA), junto a modelos de bloqueo geodésico disponibles, para inferir zonas de aspereza tectónica que pueden condicionar rupturas en el futuro.

Calculan el déficit de deslizamiento almacenado utilizando el modelo de convergencia GEODVEL (Argus et al., 2010). Al comparar las características de fuentes determinísticas con las fuentes reales contenidas en catálogos globales de fallas finitas (Mai & Thingbaijam, 2014), observan que los modelos determinísticos tienden a producir valores de deslizamiento máximo menores, lo que implica una subestimación sistemática de la amenaza de tsunami (Mueller et al., 2015). Para modelar rupturas estocásticas, utilizan la expansión K-L y el enfoque de Melgar et al., 2016 para parámetros de ruptura cinemáticos y modelos de tipo Slab 3D.

La geometría la discretizan utilizando Slab 1.0 (Hayes et al., 2012), y las correlaciones espaciales del deslizamiento se representan mediante funciones de covarianza interfalla, con valores propios y vectores propios de la expansión K-L. Para la modelación del tsunami, utilizan NEOWAVE (Yamazaki et al., 2011), modificado para incorporar la deformación cosísmica (levantamiento o subsidencia) al actualizar las mallas oceánicas antes de la simulación.

En su análisis, aplican el test t de Welch (Welch, 1951) para comparar el promedio de deslizamiento de poblaciones muestreadas versus la población original, concluyendo que al menos 400 escenarios son necesarios para capturar la variabilidad estadística de la pobla-

ción de rupturas. Sobre la correlación entre deslizamiento máximo y profundidad máxima de flujo en sus escenarios estocásticos, encuentran una correlación débil en regímenes de ola rompiente. Sepúlveda et al., 2017 reporta lo contrario, pero considerando un régimen de ola no rompiente, sumando esos hallazgos a estudios anteriores (Plafker, 1997; Rosenau et al., 2010; Ruiz et al., 2015). Además, los escenarios determinísticos subestiman sistemáticamente las profundidades de flujo en comparación con los escenarios estocásticos.

Observando las profundidades de flujo históricas para terremotos tsunamigénicos en la brecha sísmica del estudio, notaron que los escenarios de ruptura estocásticos generan comportamientos similares, pero aún así existía variabilidad en los resultados. Debido a esto, sugieren que la magnitud del deslizamiento máximo puede ser un control de orden sobre la profundidad de flujo máxima en la línea de costa, pero la alta variabilidad puede estar asociada a otros factores como ondas de borde, resonancia en la plataforma continental y otros efectos locales relacionados con la geomorfología costera (Catalán et al., 2015; Cheung et al., 2013; Melgar & Ruiz-Angulo, 2018; Yamazaki et al., 2013).

Este trabajo representa un avance significativo en la integración de métodos híbridos para evaluar el peligro de tsunami en la zona norte de Chile y sur de Perú, reconociendo las limitaciones que justifican la necesidad de estudios complementarios. En primer lugar, la correlación encontrada entre el deslizamiento máximo y la profundidad de flujo de tsunami resulta dependiente del régimen de ola asumido, esto representa una restricción que es importante considerar. Por otro lado, se necesita más investigación en la generación de escenarios a través de expansión K-L. Esto es debido a que, si bien es una metodología que promete ser más precisa que el análisis determinístico al no subestimar la amenaza de tsunami, aún enfrenta dificultades para generar modelaciones de ruptura en grandes cantidades para tener una mayor capacidad de muestreo.

2.3. Análisis probabilístico de peligro de tsunami en Chile central

Becerra et al., 2020 centran su estudio en la zona central de Chile (30°S a 38°S), generando escenarios estocásticos de M_w 8,8 y 9,2 para evaluar el peligro de tsunami en la bahía de Quintero mediante muestras seleccionadas a través de SROM. El estudio surge ante la necesidad de superar los enfoques determinísticos tradicionales que no capturan adecuadamente la incertidumbre de la fuente sísmica (Becerra et al., 2020).

En primer lugar, determinan la recurrencia de los eventos sísmicos en la zona a través de estudios anteriores (Núñez et al., 2014; Poulos et al., 2019) y determinan que los

parámetros de Núñez tiene una zonificación más parecida. A través de regresión bayesiana (Valdivia Cáceres, 2019) obtienen los parámetros G-R para Chile central y calculan la recurrencia de eventos (Kramer, 2014). Luego, generan escenarios de ruptura estocásticos a través de la expansión K-L, utilizando la metodología de (Melgar et al., 2016) modificada para generar deslizamientos no uniformes. Para el cálculo de los parámetros de falla, utilizan nuevas relaciones de largo de correlación (Goda et al., 2016) debido a que otros son desarrollados para magnitudes menores a M_w 8,0 (Mai & Beroza, 2002).

Una vez que tienen los escenarios de ruptura estocásticos generados, realizan un filtro a partir de las ecuaciones de Blaser (Blaser et al., 2010) para evitar escenarios de tsunami inverosímiles, además de contrastar estos valores con los parámetros delimitados por la geometría de Slab, quedándose siempre con el valor más restrictivo. Con esto se tiene un rango mínimo y máximo de valores para largos y anchos de falla. Posteriormente, se realiza la selección de fuentes de tsunami a través de los escenarios de ruptura más representativos para evitar el costo computacional (Geist & Lynett, 2014). Utilizando SROM (Grigoriu, 2009), reducen la cantidad de escenarios a analizar en simulaciones de inundación a través del modelo NEOWAVE (Yamazaki et al., 2011).

Aquí marcan una diferencia respecto a las investigaciones anteriores ya que utilizan dos tamaños de muestras: 50 y 100. Dentro de los resultados obtenidos, se puede observar que los sets de escenarios con 50 muestras tienen una mayor variabilidad y error que los sets de 100 muestras. A su vez, mientras más grande es el set de muestras, las diferencias estadísticas entre las muestras y la totalidad de escenarios disminuyen. Lógicamente, a mayor tamaño de muestreo, mayor costo computacional dado que la información que se debe manejar en las muestras es mayor.

Respecto a los tsunamis, los resultados sugieren que el comportamiento de la fuente del tsunami (*i.e.*, la distribución de deslizamientos en una ruptura dada), no parece influenciar los valores de inundación. Esto debido a que otros factores tienen mayor preponderancia, *e.g.*, efectos locales como la geografía de la zona, ya que pueden provocar fenómenos de resonancia en las costas. Por otro lado, al buscar el escenario probabilístico que genera la máxima inundación de tsunami, observan que este es concordante con lo registrado en el evento histórico de 1730 en Valparaíso. Donde los valores obtenidos coinciden de manera cercana con los estimados por otros autores (Carvajal et al., 2017). Por otro lado, cuando comparan los mapas de inundación obtenidos con el mapa oficial de la bahía de Quintero (SHOA, 2015), observan que este último subestima la inundación. Esto no resulta extraño, dado que para la generación de ese mapa se considera un evento determinístico de magnitud M_w 8,8 con una distribución de deslizamiento uniforme, por lo que refuerzan la idea de que los enfoques determinísticos subestiman el peligro real ante amenazas de tsunami.

Dentro de las limitaciones, reconocen que los resultados obtenidos bajo esta metodología son precisos únicamente cuando son eventos de probabilidad de excedencia relativamente baja (*i.e.*, profundidades de inundación $\leq 10\text{ m}$) y que para eventos de probabilidad de excedencia alta los sets de 50 y 100 escenarios se comportan de manera similar. Sin embargo, para eventos que ya tienen valores más extremos de inundación (*i.e.*, probabilidades de excedencia muy bajas), se necesita utilizar sets de muestras de más de 100 escenarios para tener resultados estables (De Risi & Goda, 2016; Melgar et al., 2016, 2019; Sepúlveda et al., 2017). Finalmente, este trabajo resalta la urgencia de contrastar las simulaciones estocásticas con sets de mayor cantidad de escenarios para poder determinar con mayor precisión los eventos de baja probabilidad de excedencia. Además de la importancia de que se realicen estudios a lo largo de toda la costa chilena tanto en eventos de campo cercano como de campo lejano.

2.4. Generación de mapas de inundación de tsunami combinados

Zamora et al., 2021 introducen un enfoque híbrido centrado en la combinación de profundidades de inundación y tiempos de arribo para producir mapas cualitativos de amenaza orientados a la planificación de evacuación, constituyendo un acercamiento nuevo para la realización de PTHA en Chile. La zona de estudio definida es Valparaíso-Viña del Mar, zona que ha sido identificada con una gran fuerza de fricción entre placas (Sippl et al., 2021), y coincide con el sector costero más densamente poblado de la zona metropolitana de Chile. Emplean un catálogo de 2.800 escenarios de ruptura (M_w 8,6 – 9,2), generados a través de expansión K-L (LeVeque et al., 2016; Melgar et al., 2016) sobre una discretización de subfallas y acotados por relaciones de escala (Blaser et al., 2010) y la geometría de Slab (Hayes et al., 2012; Poulos et al., 2019). Para cada escenario, el desplazamiento cosísmico del suelo marino se toma como condición inicial del tsunami bajo el supuesto de agua incompresible y ruptura instantánea (Kajiura, 1970).

Las simulaciones hidrodinámicas se ejecutan a través de Tsunami-HySEA (Macías et al., 2017), que resuelve ecuaciones de agua superficiales bidimensionales mediante un método de volúmenes finitos path-conservative de alto orden, lo que permite rastrear el frente de onda y determinar tiempos de arribo registrando el primer paso de seco a húmedo en las celdas de la malla. Para batimetría y topografía utilizan fuentes de alta resolución (Gebco, 2019; SHOA, 2012; Tadono et al., 2014), manteniendo marea constante por simplicidad.

Los resultados de inundación de tsunami muestran que las profundidades de flujo pueden llegar hasta los 17 m sobre una franja muy estrecha cerca de la costa. También, los tsunamis más grandes del set pueden propagarse hasta 4 km tierra adentro. Sin embargo, las

características geográficas de Viña del Mar y Valparaíso controlan el nivel de propagación del flujo, favoreciendo que las áreas de inundación no sean tan extensas. Sin embargo, profundidades de flujo máxima pueden alcanzar entre 25 – 30 *m* en Viña del Mar, mientras que en Valparaíso solo alcanzan entre 15 – 20 *m* debido a la topografía de la ciudad. Esto es consistente con la información proporcionada por el SHOA, que fue obtenida a partir de la utilización de fuentes sísmicas basadas en estimaciones del terremoto de 1730 en Valparaíso, basada en evidencia de tsunamis de campo cercano y lejano (Carvajal et al., 2017). Además, indican que podría existir una alta sensibilidad en las características de inundación a detalles como las propiedades de la fuente sísmica; como la distancia entre concentraciones de alto deslizamiento y las ciudades de estudio.

Por otro lado, los hallazgos muestran que la categorización del peligro depende más del tiempo de arribo que de la magnitud de la profundidad de flujo, especialmente para la toma de decisiones de evacuación. Además, pocos escenarios generan inundaciones extensas, indicando alta sensibilidad a la localización espacial del deslizamiento. Sin embargo, resaltan que la profundidad de flujo es el principal impulsor del daño de tsunami, al menos en primer orden; siempre manteniendo la premisa de que el parámetro clave para salvar vidas es poder maximizar la diferencia entre tiempo de evacuación y tiempo de arribo. Finalmente, proponen mapas combinados (profundidad de flujo y tiempo) para optimizar rutas e infraestructura de evacuación vertical.

Este estudio constituye un avance significativo en la aplicación de PTHA en Chile, con hallazgos cruciales como la importancia de la consideración del tiempo de arribo para la estimación del peligro y la consideración de que el tiempo de camino hacia la zona segura delimitada puede variar drásticamente dependiendo de factores como la topografía, conectividad vial, bloqueos y el propio criterio para definir esas zonas seguras, entre otros. Sin embargo, no está exento a limitaciones; *e.g.*, no estima probabilidades ni recurrencia (dado que su enfoque residía en la capacidad de asesoramiento en el costo de vidas humanas), no analiza la representatividad estadística de su catálogo frente a Monte Carlo, no incorpora marea variable ni explora la sensibilidad a parámetros como el tamaño de escenarios utilizados en SROM.

2.5. Nuevos mapas probabilísticos de inundación de tsunami en Chile

(Aranguiz et al., 2024) presentan el primer PTHA a nivel nacional a gran escala para la costa Chile-Perú, obteniendo mapas probabilísticos de inundación para 11 ciudades. Metodológicamente, generan 100.000 escenarios de ruptura estocásticos cada intervalos de M_w 0,2 para magnitudes entre 8,0 – 9,6 utilizando expansión K-L, siguiendo el pro-

cedimiento de Melgar et al., 2016 sobre cuatro segmentos sísmicos definidos en la zona de subducción (Saillard et al., 2017) a lo largo de Chile (Slab 2.0; Hayes et al., 2018). Esto, acotando algunos parámetros de ruptura como la profundidad máxima en 60 m siguiendo trabajos previos (Becerra et al., 2020). Posteriormente, aplican relaciones de escala (Blaser et al., 2010) para filtrar únicamente los escenarios físicamente plausibles, dejando aproximadamente 10.000 escenarios por segmento de magnitud. Sobre estos escenarios, aplican SROM para seleccionar los escenarios más representativos (50 escenarios por segmento de magnitud). Este procedimiento lo realizan 20 veces, seleccionando el set de muestras con el menor error (*i.e.*, el set con menor diferencias estadísticas respecto al catálogo completo). Finalmente, simulan las inundaciones de tsunami mediante NEO-WAVE. La recurrencia sísmica la estiman mediante un modelo de Poisson combinado con leyes Gutenberg-Richter (Gutenberg & Richter, 1944) con los parámetros ajustados de Núñez et al., 2014, lo que permite convertir alturas de inundación en mapas con períodos de retorno.

Los resultados obtenidos muestran que para los mapas de inundación, a pesar de ser eventos con distintas probabilidades de excedencia (*i.e.*, distintos períodos de retorno), resultan en áreas similares de inundación con diferencia solo en el valor de profundidad de flujo observada. Esto evidencia un punto interesante y es que el deslizamiento es un buen predictor de áreas de inundación, mientras que la probabilidad de excedencia de esa ruptura en particular es la que aumenta o disminuye el valor de las profundidades de flujo en el dominio. Este comportamiento es observado en diversos puntos de la costa, aunque está fuertemente influenciado por la forma geográfica de la región donde llega el tsunami, ya que existen puntos donde hay actividad de resonancia. Debido a esto, concluyen que formular criterios de planificación generales para las localidades chilenas no es apropiado y es necesario un enfoque específico para cada caso.

Dentro de las limitaciones, remarcan la sensibilidad de los mapas a la incertidumbre de recurrencia (el parámetro b de la relación G-R), que varía mucho dependiendo de los segmentos sísmicos utilizados en la metodología. Por lo que la comparación de los valores de recurrencia entre estudios con distinta zonificación se vuelve más compleja. Por otro lado, la dependencia en el filtrado de escenarios a través de relaciones de escala necesita análisis más profundos (Morales-Yáñez et al., 2022). A su vez, tampoco se exploran sistemáticamente efectos de marea, fuentes distantes o incertidumbres batiméticas. Sin embargo, la utilización de escenarios de tsunami estocásticos y la simulación numérica a un nivel de inundación dado en este estudio, constituyen los primeros pasos para realizar un PTHA completo de la costa chilena. Esto resalta la importancia de la presente investigación, ya que se tiene que aunque logran cubrir las localidades costeras más importantes del país y aplican el SROM para seleccionar los escenarios de inundación más representativos, la elección de 50 muestras por magnitud no es contrastada exhaustivamente respecto a

Monte Carlo o con otros tamaños de muestreo para corroborar la representatividad de los sets reducidos (ya sea en deslizamientos de ruptura, profundidades de flujo o tiempos de arribo).

3. Objetivos

3.1. Objetivo General

1. Evaluar la convergencia de Stochastic Reduced Order Models en las costas chilenas utilizando una base de datos de 40.609 escenarios.

3.2. Objetivos Específicos

1. Generar una base de datos de terremotos y de datos de intensidad de tsunami reducida a través de las relaciones de escala entregadas por Blaser.
2. Obtener las curvas de distribución acumulada a partir de los deslizamientos de ruptura de los terremotos, así como a través de las profundidades de flujo registradas.
3. Cuantificar la representatividad de las muestras obtenidas mediante SROM respecto al método Monte Carlo para cada caso.
4. Identificar si existen diferencias entre el proceso de SROM llevado desde las rupturas versus desde las intensidades de tsunami registradas.

4. Metodología

4.1. Probabilistic Tsunami Hazard Analysis

Los análisis probabilísticos de peligro de tsunami (PTHA por sus siglas en inglés) ofrecen un procedimiento estructurado y riguroso que permite rastrear y ponderar los elementos claves en el entendimiento del potencial peligro de tsunami con aplicaciones globales (Behrens et al., 2021). Es por esto que los análisis probabilísticos están volviéndose la base estándar para el asesoramiento de las autoridades en todo el mundo, en contraste de los análisis determinísticos de peligro de tsunami (DTHA), que se encuentra limitada a los registros históricos; por lo que cuenta con una gran incertidumbre asociada. Debido a esto, pueden resultar en una subestimación del peligro (Becerra et al., 2020). El propósito

de un PTHA es encontrar la probabilidad para que una medida de intensidad de tsunami (IM) exceda cierto umbral en un intervalo de tiempo predefinido. Nótese que, en el marco de PTHA, “Medida de intensidad” es usado con un significado que difiere de “escala de intensidad de tsunami”, utilizado en catálogos de tsunami para definir el “tamaño” de un tsunami o los efectos que produce en tierra. En el contexto de PTHA, una medida de intensidad es observable físicamente y está estrictamente conectada al proceso que la genera. Intensidades de tsunami comunes son la amplitud de ola, profundidad de flujo, velocidad de corriente, momento de flujo o máxima altura de inundación, dependiendo de las configuraciones del problema. La probabilidad para que la medida de intensidad supere cierto umbral está dada por la siguiente ecuación:

$$\lambda(IM(x) \geq im) = \sum_i^N \lambda_{M_{min,i}} \int P(IM(x) \geq im|s, m) f_{S|M}(s|m) f_M(m) ds dm \quad (1)$$

Donde $\lambda_{M_{min,i}}$ corresponde a la tasa promedio anual de ocurrencia de eventos tsunamigénicos (*e.g.*, terremotos, deslizamientos de tierra, etc.) teniendo magnitudes M excediendo M_{min} , f_M corresponde a la función de densidad de probabilidad condicional para $M \geq M_{min,i}$, mientras que $f_{S|M}$ corresponde a la función de densidad de probabilidad para el set de parámetros de fuente S dada una magnitud M . Finalmente, $P(IM(x) \geq im|s, m)$ corresponde a la función de distribución acumulada complementaria de IM dado $S = s$ y $M = m$, y puede ser evaluada a través de simulaciones de tsunami. Esta ecuación puede ser utilizada solo si las fuentes tsunamigénicas son independientes (Behrens et al., 2021). En este caso, se asume que todos los escenarios de estudio son generados por terremotos, por lo que los escenarios de tsunami son ligados únicamente a esta fuente en particular.

El método computacional de PTHA sigue generalmente el método PSHA (Probabilistic Seismic Hazard Analysis) desarrollado originalmente por Cornell, 1976. PSHA es un método ampliamente utilizado para asesorar el peligro sísmico y ha sido descrito exhaustivamente y revisado en distintos reportes (Benson & Berg Jr, 1988; Budnitz et al., 1997; Council et al., 1997). En términos rudimentarios, el método consiste en tres pasos: (1) la especificación de los parámetros de la fuente sísmica y sus incertidumbres asociadas; (2) la especificación de las relaciones de atenuación; y (3) el cálculo de las probabilidades. El segundo paso de PSHA a menudo involucra el análisis empírico de información para determinar el movimiento del suelo (*e.g.*, Boore et al., 1997). Diversos aspectos de PSHA han sido discutidos por varios autores, incluyendo la distinción entre incertidumbres aleatorias y epistémicas, uso de catálogos de terremotos artificiales, métodos de Monte Carlo, y árboles lógicos, aplicación a peligros de ruptura de falla, y desagregación de resultados probabilísticos (Geist & Parsons, 2006).

El fin último de este enfoque es la generación de mapas de inundación de tsunami, los cuales usualmente contienen información acerca de la profundidad de flujo, medida discretamente en unidades de longitud (*e.g.*, metros) con algún nivel de discretización. Esto puede ser contraintuitivo y difícil de interpretar así como sus implicaciones. En contraste, el enfoque utilizado para algunos sistemas de alerta de tsunami es caracterizar el peligro basado en las amplitudes de tsunami peak en la costa estimadas cerca de la costa. El uso de valores numéricos es descartado en favor de la categorización basada en umbrales, de esta manera, es posible asimilarla unívocamente a la realización de una acción de evacuación por la población. En este caso, el sistema de alerta de tsunami en Chile donde el análisis de peligro de tsunami identifica cuatro niveles de peligro son asociados a tres distintas acciones de evacuación (Catalan et al., 2020):

$$\text{máx}(\eta) \begin{cases} \leq 0,30 \, m & \text{Informative} \\ 0,30 - 1,00 \, m & \text{Advisory} \\ 1,00 - 3,00 \, m & \text{Watch} \\ > 3,00 \, m & \text{Warning} \end{cases} \quad (2)$$

Donde $\text{máx}(\eta)$ es estimado fuera de la costa, a una profundidad de agua prescrita. En estos niveles de peligro, tanto “Watch” como “Warning” tienen una evacuación completa de áreas que están bajo los 30 *m* de elevación, y el nivel de peligro “Advisory” indica una evacuación de los primeros 80 *m* (medidos horizontalmente) a cuerpos de agua y el océano. Para el nivel de peligro “Informative”, no se requiere ninguna acción.

No existe una métrica equivalente o categorización existente para la profundidad de flujo de inundación, ya que se ha asumido implícitamente que cualquier nivel de inundación es suficientemente peligroso para comenzar una evacuación. Es más, tampoco existe categorización existente para los tiempos de arribo, ya que se ha asumido que la evacuación necesita realizarse inmediatamente, independientemente de cuándo la inundación tomará lugar. Aquí se ha hipotetizado que unir estos parámetros puede ser relevante para un análisis más detallado de estrategias de evacuación. También, podría llevar a mapas que sean mucho más fáciles de interpretar por el público general (Zamora et al., 2021).

4.2. Método Monte Carlo

Todos los sistemas físicos y sus modelos computacionales correspondientes tienen inherentemente una aleatoriedad asociada. En práctica, esta incertidumbre se manifiesta en la información de entrada (*e.g.*, propiedades del material, condiciones de borde, etc.) de una simulación determinística que describe un sistema físico particular. Entender y cuantificar el impacto de esta incertidumbre en la simulación resulta crítico para caracterizar

exitosamente el sistema de respuesta. Dejando de lado los avances en el campo del cálculo estocástico, sigue siendo un desafío propagar con precisión y efectividad la incertidumbre en modelos computacionales. Generalmente, este es un problema de caracterización de las estadísticas de salida $\mathbf{Y} \in \mathcal{Y} \subset \mathbb{R}^d$ para un mapeo hacia adelante dado:

$$\mathcal{M} : \mathcal{X} \mapsto \mathcal{Y} \quad (3)$$

con parámetros de entrada aleatorios $\mathbf{X} \in \mathcal{X} \subset \mathbb{R}^d$. Se puede notar que modelos dependientes de campos aleatorios también pueden ser descritos por esta forma general luego de una parametrización apropiada.

El enfoque general y más común para la solución de la ecuación (3), es la simulación Monte Carlo. Esta tiene una implementación simple y no intrusiva, pero debido a su convergencia lenta (proporcional al número de muestras, *i.e.*, converge cuando el tamaño de muestras tiende a infinito), se vuelve inviable para mapeos intensivos $\mathcal{M}$ computacionalmente. Se han desarrollado variantes para acelerar su convergencia (*e.g.*, Xiu, 2010), pero su aplicabilidad es limitada. Enfoques intrusivos como métodos de perturbación, métodos basados en operadores (*e.g.*, series de Neumann) y el método de momentos están entre las técnicas comunes sin muestreo. Una desventaja inherente de estos métodos es que son difíciles de implementar y están limitados a problemas con pequeñas magnitudes de incertidumbre.

Básicamente, el tiempo computacional puede ser considerable cuando se resuelven problemas reales, esta es la única limitación del método Monte Carlo clásico. Sin embargo, la eficiencia de este método puede ser mejorada de manera significativa por una inteligente selección de muestras de $\mathbf{X}$ (Warner et al., 2013).

4.3. Stochastic Reduced Order Models

La construcción del SROM contempla el resolver el problema estocástico mediante un muestreo reducido $\tilde{\mathbf{X}}$ a partir del muestreo total $\mathbf{X}$ de Monte Carlo. Se busca que las diferencias entre ambos modelos sean reducidas al máximo mediante un problema de optimización, donde la función objetivo puede ser una medida de error que cuantifique la diferencia entre las propiedades estadísticas entre ambos. Estas diferencias pueden ser los momentos estadísticos y/o correlaciones entre las variables aleatorias que pertenecen al vector aleatorio $\mathbf{X}$. Una vez se hayan seleccionado los parámetros a ajustar y se ejecutan las técnicas de optimización numérica, se validan comparando las propiedades estadísticas obtenidas de SROM con las de Monte Carlo, si las propiedades son suficientemente cercanas (*e.g.*, a través de normas de diferencia, criterios de error relativo, pruebas estadísticas

o intervalos de confianza), se considera que el modelo reducido es un modelo válido y eficiente (Warner et al., 2013). Para entender mejor lo anterior, se tiene la Figura 1, que gráficamente muestra lo que se obtiene mediante un SROM respecto a un Monte Carlo dado un número m de muestras seleccionadas.




Figura 1: Distribución de la solución $F(x)$ a través de Monte Carlo, respecto a la misma solución mediante SROM dado un tamaño de muestra m (en rojo).

La definición formal indica: Sea $\mathbf{X} \in \Gamma \subset \mathbb{R}^d$ un vector aleatorio d -dimensional con probabilidades conocidas, es decir, sus propiedades estadísticas son conocidas y se pueden calcular:

$$F_i(x_i) = P(X_i \leq x_i) \quad (4)$$

$$\mu_i(q) = E[X_i^q] \quad (5)$$

$$\mathbf{r} = E[\mathbf{X}\mathbf{X}^T] \quad (6)$$

Donde F_i y $\mu_i(q)$ son la función de distribución acumulada marginal (CDF por sus siglas en inglés) y el momento marginal de orden q para la componente i del vector aleatorio, respectivamente, y $\mathbf{r}$ es la matriz de correlación (no escalada). Un SROM $\tilde{X}$ de X es simplemente una colección finita de muestras $\{\tilde{\mathbf{x}}^{(1)}, \dots, \tilde{\mathbf{x}}^{(m)}\}$ y sus probabilidades correspondientes $(\tilde{p}^{(1)}, \dots, \tilde{p}^{(m)})$ tal que $p^{(k)} = P(\mathbf{X} = \tilde{\mathbf{x}}^{(k)})$, $p^{(k)} \geq 0 \forall k$, y $\sum_{k=1}^m p^{(k)} = 1$. Aquí, m corresponde al tamaño del SROM. Con estos parámetros de SROM especificados, las estadísticas de $\tilde{\mathbf{X}}$ correspondientes a las de $\mathbf{X}$ dadas las ecuaciones (4-6) son:

$$\tilde{F}_i(x_i) = \sum_{k=1}^m p^{(k)} \mathbf{1}(\tilde{x}_i^{(k)} \leq x_i) \quad (7)$$

$$\tilde{\mu}_i(q) = \sum_{k=1}^m p^{(k)} (\tilde{x}_i^{(k)})^q \quad (8)$$

$$\tilde{r}(i, j) = \sum_{k=1}^m p^{(k)} \tilde{x}_i^{(k)} \tilde{x}_j^{(k)} \quad (9)$$

Donde $\mathbf{1}$ corresponde al indicador condicional de la función, evaluando en 1 si la condición es verdadera y 0 en caso contrario.

La definición de los parámetros del SROM (muestras y probabilidades) son escogidos de manera tal que $\tilde{\mathbf{X}}$ es una óptima representación de $\mathbf{X}$ desde el punto de vista estadístico. Esto es realizado mediante la solución del siguiente problema de optimización:

$$\tilde{\mathbf{X}} \equiv \underset{\{\tilde{\mathbf{x}}\}, \mathbf{p}}{\operatorname{argmin}} \left(\sum_{i=1}^3 \alpha_i e_i(\{\tilde{\mathbf{x}}, \mathbf{p}\}) \right) \quad (10)$$

$$\text{tal que } \sum_{k=1}^m p^{(k)} = 1 \text{ y } p^{(k)} \geq 0, \quad k = 1, \dots, m \quad (11)$$

Donde e_1 , e_2 y e_3 cuantifican el error entre el SROM y las CDFs objetivo, momentos, y matriz de correlación, respectivamente, y α_i son factores de ponderación. Una métrica típica para el error es la función de suma de cuadrados de los errores (SSE por sus siglas en inglés):

$$e_1^{SSE}(\{\tilde{\mathbf{x}}\}, \mathbf{p}) = \frac{1}{2} \sum_{i=1}^d \sum_{j=1}^n \left(\frac{\tilde{F}_i(x_i^j) - F_i(x_i^j)}{C_1^{ij}} \right)^2 \quad (12)$$

$$e_2^{SSE}(\{\tilde{\mathbf{x}}\}, \mathbf{p}) = \frac{1}{2} \sum_{i=1}^d \sum_{q=1}^{\tilde{q}} \left(\frac{\tilde{\mu}_i(q) - \mu_i(q)}{C_2^{iq}} \right)^2 \quad (13)$$

$$e_3^{SSE}(\{\tilde{\mathbf{x}}\}, \mathbf{p}) = \frac{1}{2} \sum_{i=1}^d \sum_{j=i+1}^d \left(\frac{\tilde{r}_{ij} - r_{ij}}{C_3^{ij}} \right)^2 \quad (14)$$

donde $\{x_i^j\}_{j=1}^n$ corresponde a un set preseleccionado de puntos grillados sobre el rango de x_i y $\tilde{q}$ es el máximo momento de orden considerado. Aquí, los errores relativos ($C_1^{ij} = F_i(x_i^j)$, $C_2^{iq} = \mu_i(q)$ y $C_3^{ij} = r_{ij}$) o absolutos ($C_1^{ij} = C_2^{iq} = C_3^{ij} = 1$) pueden ser utilizados. Otras opciones también puede ser los errores máximos o los errores promedios, sin embargo, la ventaja de utilizar SSE como función objetivo de las ecuaciones (12-14) es su diferenciabilidad, que entrega un gradiente analítico que puede ser utilizado en softwares de optimización para resolver la ecuación (10) de una manera más eficiente (Warner, 2018), y es efectivamente el utilizado en esta investigación.

4.4. Expansión Karhunen-Loève

Los escenarios de ruptura y la simulación del movimiento del suelo son herramientas importantes para estudios de terremotos y tsunamis potenciales en eventos futuros. Esto es particularmente importante para eventos grandes ($M_w \geq 8,0$) y eventos muy grandes ($M_w \geq 8,5$), los cuales tienen observaciones limitadas (Melgar et al., 2016). Es debido a esto que los análisis probabilísticos tienen una ventaja por sobre los determinísticos, ya que al poder generar escenarios de ruptura con distribuciones de deslizamiento aleatorias se puede contar con una mayor cantidad de escenarios de tsunami que consultando registros históricos. La expansión Karhunen-Loève (LeVeque et al., 2016) es un modelo que se puede utilizar en la generación de escenarios de ruptura estocásticos sobre campos gaussianos (Sepúlveda et al., 2017), permitiendo representar la variabilidad del deslizamiento durante un sismo en un dominio determinado de puntos.

En primera instancia, se determinan las magnitudes objetivo; en el caso de la presente investigación, se generan 40.609 escenarios en total para el rango de M_w 7,5 – 9,5 con espaciamientos de magnitud cada 0,1. Una vez que se tienen las magnitudes definidas, se definen los parámetros de la fuente sísmica; largo L y ancho W de una porción de la zona de subducción que participará en la ruptura. En este caso, se utilizan las relaciones de escala de Blaser et al., 2010 para zonas de ruptura en subducción:

$$\begin{aligned} \log_{10}(L) &= -2,37 + 0,57M_w \\ \log_{10}(W) &= -1,86 + 0,46M_w \end{aligned} \tag{15}$$

Con el fin de evitar que todos los eventos de la misma magnitud tengan las mismas dimensiones y para incluir variabilidad, como se esperarí en la realidad, Blaser et al., 2010 entrega las desviaciones estándar de las relaciones de escala de manera tal que se puede construir una función de densidad de probabilidad lognormal de largos y anchos de falla para extraer números aleatorios a partir de ahí. Luego, se seleccionan subfallas

aleatorias como centroide y se aplican las dimensiones de falla derivadas de las relaciones de escala. Posteriormente, se seleccionan todas las subfallas dentro de ese valor particular de L y W . Los límites de las placas son límites complejos; por lo tanto, si la subfalla está muy cerca de los bordes del modelo, se desliza el largo y el ancho hacia arriba o hacia abajo del dip y a lo largo del strike según sea necesario hasta que se puedan ajustar a las dimensiones aleatoriamente calculadas. Luego de determinar las subfallas que serán parte de un modelo cinemático particular, el siguiente paso es definir las estadísticas de la distribución de deslizamiento. En este punto se asume que el deslizamiento en cada punto está normalmente distribuido con promedio μ_k y desviación estándar σ_k . El vector $\mathbf{s}$ que contiene los deslizamientos se distribuye como:

$$\mathbf{s} \sim \mathcal{N}(\boldsymbol{\mu}, \hat{\mathbf{C}}) \quad (16)$$

donde el vector promedio $\boldsymbol{\mu}$ se prescribe de manera tal que tiene deslizamiento uniforme y suficiente momento escalar para coincidir con la magnitud objetivo. La matriz de covarianza de la distribución, $\hat{\mathbf{C}}$, es una función de la desviación estándar, σ_k , en una determinada subfalla, nominalmente definida como una fracción con un valor que oscila típicamente entre 0,5 y 1,0 del deslizamiento promedio (Graves & Pitarka, 2010), y la correlación C_{ij} entre las subfallas i -ésima y j -ésima tal que:

$$\hat{C}_{ij} = \sigma_i \sigma_j C_{ij} \quad (17)$$

Por lo tanto, la función de correlación entrefalla controla las estadísticas espaciales del deslizamiento. Puede tener muchas formas funcionales, pero estudios han demostrado que la función de correlación de Von Karman $C(r)$ describe de mejor manera los patrones de deslizamiento observado y es una buena opción para la modelación del movimiento del suelo (Melgar et al., 2016). La correlación entre las fallas i -ésima y j -ésima está dada por:

$$C_{ij}(r_{ij}) = \frac{G_H(r_{ij})}{G_0(r_{ij})} \quad (18)$$

donde

$$G_H(r_{ij}) = r_{ij}^H K_H(r_{ij}) \quad (19)$$

K_H es la función de Bessel del segundo tipo modificada, H corresponde al exponente de Hurst, y r_{ij} es la distancia medida entre las subfallas i -ésima y j -ésima que depende del strike, r_s , y la distancia del dip entre subfallas, r_d :

$$r_{ij} = \sqrt{\frac{r_s^2}{a_s} + \frac{r_d^2}{a_d}} \quad (20)$$

Para geometrías de falla curvas, las distancias entre strikes y dips de subfallas son determinadas siguiendo la superficie curva de la placa a una profundidad dada y en dirección hacia abajo del dip, de esta manera, las distancias se miden en la superficie de la falla. Por otro lado, se determina $H = 0,75$ (Melgar et al., 2016), mientras que los parámetros a_s y a_d corresponden a las longitudes de correlación a lo largo del dip y el strike para el evento sísmico. Conceptualmente, las longitudes de correlación determinan el tamaño predominante de las asperezas en el modelo de deslizamiento. Estas escalan con el largo L_{eff} y ancho W_{eff} efectivos de las dimensiones de la falla de la ecuación (15) (Mai & Beroza, 2000, 2002):

$$\begin{aligned} a_s &= 2,0 + \frac{1}{3}L_{eff} \\ a_d &= 1,0 + \frac{1}{3}W_{eff} \end{aligned} \quad (21)$$

Con estos largos de correlación se calcula la matriz de covarianza $\hat{\mathbf{C}}$ de dimensiones $N \times N$, utilizando las ecuaciones (17 - 21), donde N es el número de subfallas seleccionadas para satisfacer los requerimientos de largo y ancho de la ecuación (15).

Dados los valores propios λ_k y los vectores propios $\mathbf{v}_k$ de la matriz de covarianza $\hat{\mathbf{C}}$, la expansión de Karhunen-Loève establece que un campo aleatorio, en este caso el vector de deslizamientos en una determinada subfalla, $\mathbf{s}$, puede ser expresada como la combinación lineal:

$$\mathbf{s} = \boldsymbol{\mu} + \sum_{k=1}^N z_k \mathbf{v}_k \sqrt{\lambda_k} \quad (22)$$

donde z_k son números aleatorios distribuidos normalmente utilizados como ponderaciones para cada modo propio, $\mathbf{v}_k$, tal que:

$$z_k \sim \mathcal{N}(0, 1) \quad (23)$$

Simplemente generando números aleatorios y formando la combinación lineal de modos propios de la matriz de covarianza, se puede obtener cualquier número de distribuciones

de deslizamiento, $\mathbf{s}$, que se muestrean a partir de una función de densidad de probabilidad con la covarianza $\hat{\mathbf{C}}$ deseada (LeVeque et al., 2016) y, por ende, las estadísticas espaciales correctas definidas por el modelador. Un problema en esta formulación es que es posible que los patrones de deslizamientos obtenidos tengan valores positivos y negativos, relativos al ángulo de rake definido. Incluso cuando el promedio está muy por encima de cero, la variabilidad permitida por este enfoque estocástico puede producir algunas subfallas con valores de deslizamiento menores a cero. Es posible fijar estos valores negativos de deslizamiento a cero para así evitar violar la no negatividad. Sin embargo, dependiendo de los resultados del proceso estocástico, es posible que un número importante de fallas tengan deslizamientos negativos. Fijarlos en cero podría entonces violar las suposiciones estadísticas de la expansión K-L, quitando la garantía de que la función de correlación (ecuación (18)) asumida describe el patrón de deslizamiento resultante. Una solución alternativa es utilizar una distribución lognormal que producirá únicamente resultados positivos. LeVeque et al., 2016 muestra que, a partir de un deslizamiento promedio construido $\boldsymbol{\mu}$ y una covarianza $\hat{\mathbf{C}}$, un vector de deslizamientos normalmente distribuidos puede ser formado definiendo el promedio $\boldsymbol{\mu}^g$ y la covarianza $\hat{\mathbf{C}}^g$ como:

$$\begin{aligned}\hat{\mathbf{C}}_{ij}^g &= \log \left(\frac{\hat{\mathbf{C}}_{ij}}{\mu_i \mu_j} + 1 \right) \\ \mu_i^g &= \log(\mu_i) - \frac{1}{2} \hat{\mathbf{C}}_{ii}^g\end{aligned}\tag{24}$$

Luego, la expansión K-L puede ser aplicada como se hizo anteriormente para obtener el nuevo vector

$$\mathbf{s}^g = \boldsymbol{\mu}^g + \sum_{k=1}^N z_k \sqrt{\lambda_k^g} \mathbf{v}_k^g\tag{25}$$

donde λ_k^g y $\mathbf{v}_k^g$ son los valores propios y vectores propios de la covarianza en la ecuación (24). La exponenciación producirá entonces el vector de deslizamientos distribuido lognormalmente:

$$\mathbf{s} = \exp(\mathbf{s}^g)\tag{26}$$

con deslizamiento promedio $\boldsymbol{\mu}$ y covarianza $\hat{\mathbf{C}}$. Este paso final asegura que la distribución de deslizamientos sea estrictamente positiva con las estadísticas espaciales deseadas. Si se realiza suficientes veces este proceso con la expansión K-L, se puede notar que es posible generar distribuciones de deslizamiento que pueden ser consideradas como irreales. Es por esto que se aplica una última restricción geofísica; se fija un valor máximo de deslizamiento.

La placa de Nazca subduce la placa Sudamericana a una tasa de 6,6 *cm* por año (Angermann et al., 1999), y el último gran evento en la zona central fue en Valparaíso en 1730. Esto sugiere un déficit de deslizamiento importante en la zona central. Sin embargo, es desconocido si este déficit de deslizamiento ha sido liberado en eventos posteriores. Estudios paleosísmicos en otras zonas de subducción sugieren un historial complejo de acumulación y liberación de deslizamientos (Sieh et al., 2008). Esto queda claramente demostrado en el deslizamiento cosísmico de más de 60 *m* durante el terremoto M_W 9,0 ocurrido en Tohoku en 2011 (Simons et al., 2011), que sucedió en un lugar donde se pensó que no existía un déficit de deslizamiento significativo (Melgar et al., 2016). Es por esto que, buscando tener un balance entre variabilidad en los escenarios y la tectónica conocida, se fija el límite de deslizamiento en 50 *m*. Si una iteración particular de expansión K-L sobrepasa este valor límite, es descartada.

4.5. Leyes de escala de Blaser

Con la base de escenarios de ruptura generadas a través de distribuciones de deslizamiento estocásticas utilizando expansión K-L, se realiza un filtrado de escenarios para seleccionar los casos de terremotos físicamente plausibles dada la generación aleatoria de zonas de ruptura. Este filtrado se realiza mediante los largos y anchos de ruptura de acuerdo con la ecuación de Blaser et al., 2010 y es un procedimiento que busca asegurar que la totalidad de las rupturas a utilizar sean escenarios con potencial real de ocurrencia. De esta forma, la limitación de los parámetros de ruptura está dada por las siguientes relaciones de escala:

$$\begin{aligned}\log_{10}(L) &= -2,37 + \epsilon_{aL} + (0,57 \pm \epsilon_{bL}) M_w \\ \log_{10}(W) &= -1,86 + \epsilon_{aW} + (0,46 \pm \epsilon_{bW}) M_w\end{aligned}\tag{27}$$

Los parámetros ϵ_i son calculados como el 25 % de la desviación estándar de los parámetros entregados por Blaser et al., 2010. Además, cuando la magnitud es mayor a M_w 8,8, el ancho mínimo de ruptura se define como 130 [*km*], debido al hecho de que escalar las relaciones puede dar anchos de ruptura mayores al máximo posible (Aranguiz et al., 2024). El ancho máximo se define en 180 [*km*] basado en la geometría del plano de falla (Becerra et al., 2020).

4.6. Selección de escenarios mediante SROM

Se utiliza la biblioteca SROMPy en Python (Warner, 2018) con una modificación particular; dentro de la clase SROM se define un atributo que obtenga el vector de errores al

final de cada iteración. De esta forma, en el código general desarrollado en este trabajo que llama a esta biblioteca, se puede fijar un número máximo de iteraciones y, con el vector de errores, guiar estas iteraciones como se estime conveniente. Esto puede ser fijando el número máximo de iteraciones para reducir el costo computacional pero obteniendo errores con distinto orden de magnitud para la CDF, el momento de orden y la matriz de correlación, o bien, utilizando los órdenes de magnitud de los errores como método de optimización buscando que el Orden de magnitud de los errores sea el mismo, como realizan Aranguiz et al., 2024. Este paso se realiza debido a que la ponderación que se le da a cada uno de los errores es desconocida, por defecto, SROMPy utiliza un vector $(1, 1, 1)$. Sin embargo, (Aranguiz et al., 2024) calcula las ponderaciones para cada caso con la condición que sean ≥ 0 y estén normalizados. Entonces, con cada iteración, se obtienen distintas ponderaciones que disminuyen el error general. Gracias a esto, se puede obtener una selección de escenarios que tenga más coincidencias estadísticas con el dataset completo, es decir, sea una mejor representación respecto al total de escenarios desde el punto de vista estadístico.

Para efectos prácticos, en este caso se opta por el enfoque que busca reducir al máximo el costo computacional, pero añadiendo al vector de errores el promedio de los errores. De esta forma, se fija en el código un método que garantiza que las iteraciones vayan disminuyendo el error promedio, es decir, el error general para la CDF, para el momento de orden q y el error de la matriz de correlación. Al llegar al máximo de iteraciones, se busca la iteración que haya llegado al menor error promedio y esa es la ponderación utilizada para calcular CDF y compararla respecto a la curva Monte Carlo. Para la presente investigación, se considera un máximo de 10 iteraciones y el momento de orden considerado es hasta el orden cinco.

Este proceso se realiza para filtrar los escenarios más representativos dado un punto de deslizamiento en la grilla, es decir, se selecciona un punto arbitrario dentro del dominio (Figura 2), y se le aplica el SROM para seleccionar los escenarios más representativos dadas las estadísticas del dataset en ese punto. De esta forma, con distintos puntos a lo largo de toda la costa chilena, se obtienen los escenarios más representativos y se puede analizar el comportamiento de distintos tsunamis potenciales en cualquier localidad de Chile y el sur de Perú.




Figura 2: Área de estudio; contiene el dominio de las posibles áreas de ruptura para los escenarios sísmicos.

Este proceso se realiza tanto para los posibles deslizamientos a lo largo del dominio de ruptura, como para las métricas de interés a lo largo del dominio del tsunami (Figura 3), en este caso, la métrica de interés es la profundidad de flujo dadas sus consecuencias directas en la inundación en tierra.



Figura 3: Área de estudio; contiene el dominio de los puntos de medición para las métricas de tsunami (eta, velocidad, momento de flujo, profundidad de inundación, entre otras).

Dado que el fin de la presente investigación es analizar la convergencia del SROM, se utilizan distintos tamaños de muestras para los escenarios: 25, 50, 100 y 200. El objetivo de esto es determinar cual es el tamaño óptimo para una representación estadística efectiva de la totalidad de escenarios de ruptura. Por lo tanto, se aplica SROM para todos los puntos que se observan en la Figura 4.




Figura 4: Puntos del dominio de ruptura donde se aplica SROM.

Por otro lado, en la Figura 5 se observan los puntos de la costa que contienen las métricas de interés a los que se les aplica SROM, de la misma forma que a los puntos de ruptura. El objetivo de esto es analizar si la relación deslizamiento-profundidad de flujo funciona en ambas direcciones y existe correlación de escenarios seleccionados mediante ambos enfoques; *i.e.*, dado un punto de deslizamiento, ¿se pueden obtener buenas predicciones de inundación? y por otro lado, dado un escenario de inundación particular, ¿se puede predecir la distribución de deslizamientos que lo provoca?

Para poder contrastar los resultados obtenidos y poder hacer comparaciones, se escogen distintos puntos de análisis a lo largo de todo Chile que coinciden con las localidades costeras más relevantes frente a amenazas de tsunami que hayan sido cubiertos por investigaciones anteriores (Aranguiz et al., 2024; Becerra et al., 2020; González et al., 2020; Zamora et al., 2021): Arica, Iquique, Antofagasta, La Serena, Viña del Mar, Valparaíso, San Antonio, Talcahuano, Concepción, Coronel, Valdivia, Puerto Montt y Ancud.




Figura 5: Puntos del dominio de tsunami donde se aplicó el SROM para la profundidad de flujo.

5. Resultados

Se realizó la generación, filtrado y selección de escenarios para cada segmento de magnitud. En la Tabla 1 se puede notar el número de escenarios por magnitud luego de realizar el proceso de generación de rupturas sísmicas a través de expansión K-L. Por otro lado, en el filtrado a través de las relaciones de escala de Blaser et al., 2010, se tiene que 2587 escenarios cumplen las condiciones de los parámetros de ruptura. Estos se pueden ver a través de la Tabla 2:

Tabla 1: Escenarios de ruptura por magnitud generados a través de expansión K-L.

M_w	Escenarios	M_w	Escenarios
7,5	1504	8,6	2013
7,6	1910	8,7	2001
7,7	2007	8,8	2019
7,8	2031	8,9	2071
7,9	2012	9,0	2117
8,0	1961	9,1	2238
8,1	2039	9,2	2299
8,2	2028	9,3	2205
8,3	1954	9,4	1606
8,4	2018	9,5	504
8,5	2072	Σ	40609

Tabla 2: Escenarios de ruptura por magnitud luego del filtro a través de relaciones de escala.

M_w	Escenarios	M_w	Escenarios
7,5	40	8,6	122
7,6	65	8,7	115
7,7	64	8,8	177
7,8	79	8,9	183
7,9	62	9,0	200
8,0	66	9,1	213
8,1	73	9,2	243
8,2	110	9,3	228
8,3	99	9,4	176
8,4	106	9,5	49
8,5	117	Σ	2587

La Figura 6 muestra la distribución de deslizamientos para algunas muestras de los eventos seleccionados por SROM. Se puede notar que los eventos M_w 8,0 tienen un deslizamiento máximo en el orden de $9 - 10$ m y tienen áreas de ruptura pequeñas. Por otro lado, en eventos M_w 8,5 las áreas de ruptura son bastante mayores a los eventos anteriores, donde los deslizamientos máximos pueden alcanzar incluso 20 m . También se puede observar que, para eventos $M_w \geq 9,0$, las áreas de ruptura pueden activar una cantidad importante del dominio, llegando a deslizamientos máximos que pueden estar tanto en el área más superficial como en el área más profunda de la ruptura.




Figura 6: Ejemplos de fuentes de tsunami filtradas mediante SROM para distintas magnitudes.

Las muestras obtenidas para cada segmento de magnitud corresponden a las que mantienen las propiedades estadísticas del catálogo completo, por lo que son una buena representación del comportamiento del punto donde se aplica el SROM. Bajo esta premisa se obtuvieron las curvas de distribución acumulada para los puntos de interés en la costa, frente a potenciales inundaciones en distintas localidades a lo largo de todo Chile.




Figura 7: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Arica.

Se puede observar en la Figura 7 que, para eventos bajo M_w 8,6, no existen peligros de inundación evidentes en las costas de Arica dado que las máximas profundidades de flujo alcanzadas no llegan a los 2 m, tanto para puntos de ruptura cercanos o lejanos. Sin embargo, cuando se consideran magnitudes M_w 8,8 – 9,0 se vuelve evidente el potencial peligro de inundación ante distintos puntos de ruptura, llegando a tener profundidades de flujo de hasta 6 m con curvas de distribución que tienden a la Monte Carlo en puntos de ruptura cercanos a Arica y para un punto en la zona central. Sobre M_w 9,2, se tiene un peligro inminente en las costas de la ciudad con profundidades de flujo que llegan hasta los 12 m. Se observa la misma tendencia para los puntos de deslizamiento tanto cercanos como lejanos, mientras mayor es el tamaño del SROM m , la distribución tiende más a la convergencia con la curva de Monte Carlo.




Figura 8: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Iquique.

Para la ciudad de Iquique, se puede observar a través de la Figura 8 que los puntos de deslizamiento seleccionados funcionan como un buen predictor de profundidades de inundación, ya que se observa una tendencia a la convergencia a la curva de Monte Carlo para todas las magnitudes en los eventos con puntos de deslizamientos cercanos a la ciudad, tal como sucede en el caso de Arica. Las profundidades de inundación aumentan considerablemente con el incremento de M_w , por ejemplo, para M_w 8,6, se tiene una profundidad de flujo máxima de 3 m, que ya supone un peligro para la población cercana. Es más, desde M_w 8,8 las profundidades de flujo comienzan a tomar valores máximos que llegan a 7 m y pueden llegar hasta 14 m para eventos $M_w \geq 9,0$. Por otro lado, se puede observar que las curvas pierden precisión para magnitudes altas M_w 9,2, llegando rápidamente a la probabilidad acumulada máxima por lo que se pierde información sobre la inundación.




Figura 9: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Antofagasta.

En Antofagasta, se puede observar mediante la Figura 9 que ya desde sismos M_w 8,6 existe un gran peligro de tsunamis, teniendo profundidades de flujo de casi 6 m y con curvas de distribución que se acercan a la Monte Carlo para todos los puntos de deslizamiento escogidos, incluso en los puntos con SROM aplicado en la zona central. Un comportamiento distinto ocurre para M_w 8,8, donde se tienen profundidades de inundación de casi 14 m pero sólo las curvas del punto 5975 convergen a la Monte Carlo. Esto parece indicar que pueden haber otros factores que afectan también a la estimación de la inundación y propagan incertidumbre en la convergencia a la Monte Carlo. Para magnitudes $M_w > 8,8$, se puede observar una clara convergencia a la curva de Monte Carlo, pudiendo coincidir muy bien en las profundidades de inundación estimadas. Esto se puede ver en los escenarios de ruptura cercanos a Antofagasta, llegando a profundidades de flujo de casi 12 m para eventos de M_w 9,0 y prácticamente 20 m en eventos M_w 9,2, lo que supone un peligro grave en las costas, ya que esto podría suponer la entrada del mar en cientos de metros. Se puede observar que para un tamaño de muestras de $m = 200$ se tiene una precisión bastante apegada a la Monte Carlo, pero también esto ocurre a partir de tamaños de muestra $m \geq 50$.




Figura 10: Curvas de distribución acumulada de profundidad de flujo para la ciudad de La Serena.

En La Serena, la Figura 10 muestra que a medida que aumentan los tamaños de muestreo para las rupturas cercanas a la ciudad de estudio, aumenta la convergencia sobre la Monte Carlo. Sin embargo, para el punto de deslizamiento 4532, al aumentar el tamaño de muestreo el comportamiento es que se aleja de la Monte Carlo teniendo el caso en que un muestreo menor se apega mejor a la curva de profundidad de flujo. Para M_w 8,6, ya se tienen grandes profundidades de flujo que sobrepasan 4 m. Para eventos entre M_w 8,8–9,0 se tiene que las profundidades de flujo estimadas oscilan entre 5–7 m. Finalmente, para eventos $M_w \geq 9,2$, se tienen profundidades de flujo de hasta 11 m con predicciones bastante cercanas a la Monte Carlo para tamaños de muestreo a partir de 100 hasta 200 escenarios considerando puntos de ruptura cercanos a la ciudad.




Figura 11: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Viña del Mar.

En la ciudad de Viña del Mar, la Figura 11 muestra que para eventos M_w 8,6, solo el punto de deslizamiento 3872 converge a la Monte Carlo para tamaños de muestra $m \geq 50$. Se estiman profundidades de flujo de hasta 4,5 m, lo cual es una gran alerta debido a que la geografía de Viña del Mar permite la entrada del mar con facilidad en grandes distancias. Para magnitudes $M_w > 8,8$, las curvas de distribución de los deslizamientos tienden a la convergencia pero es un comportamiento que se da únicamente en las colas de la curva de distribución. Existe un grave peligro de inundación en la zona de Viña del Mar con profundidades de flujo de hasta 16 m.




Figura 12: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Valparaíso.

La Figura 12 muestra que en Valparaíso se tiene el mismo comportamiento en las curvas de distribución para todas las magnitudes y tamaños de muestreo que en Viña del Mar. Para eventos con magnitud M_w 8,6, se pueden esperar valores máximos de profundidad de flujo no mayores a 5 m; sin embargo, se debe recordar que estos valores son probabilidades de no excedencia, por lo que eventos con probabilidad de excedencia muy baja pueden generar valores de inundación máximos y atípicos. Para eventos M_w 8,8, se tienen valores máximos esperables de 6 m, mientras que para M_w 9,0 se tienen valores que sobrepasan 18 m, esto es un indicador clave de alerta ya que para eventos con baja probabilidad de excedencia pueden generarse valores mucho mayores. Sin embargo, Valparaíso tiene una ventaja respecto a Viña del Mar acá, ya que la geografía de Valparaíso impide el avance agresivo del mar en una potencial inundación.




Figura 13: Curvas de distribución acumulada de profundidad de flujo para la ciudad de San Antonio.

Para el puerto de San Antonio, la Figura 13 muestra que a medida que aumenta la magnitud M_w de la ruptura, aumenta también la convergencia de las curvas de distribución acumulada estimada de los puntos de deslizamiento, sobretodo la de los puntos cercanos a la zona de análisis. Para eventos de M_w 8,6 y 8,8 se tienen profundidades de flujo que no alcanzan 3 m, mientras que para eventos M_w 9,0 se tienen profundidades de inundación que pueden llegar a 7 m y hasta sobre 10 m en eventos M_w 9,2.




Figura 14: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Talcahuano.

En Talcahuano se puede notar, a través de la Figura 14, que las curvas no logran converger a la Monte Carlo, si bien se asemejan en ciertos tramos de la distribución (sobretudo en las colas), no consiguen tener un comportamiento convergente. Para eventos entre M_w 8,6 y 8,8 se tienen profundidades de flujo que pueden llegar hasta 3 m, mientras que en eventos $M_w \geq 9,0$ pueden sobrepasarse los 6 m.




Figura 15: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Concepción.

En la ciudad de Concepción, la Figura 15 muestra que el punto 3872 predice muy bien la curva de Monte Carlo para las profundidades de flujo en eventos M_w 8,6, que no llegan a 1 m. En eventos M_w 8,8–9,0, no se observa una convergencia clara de ninguno de los puntos de deslizamiento en los que se aplicó SROM para predecir la curva de distribución. Sin embargo, las profundidades de flujo en estos eventos no logran superar 1,5 m. Finalmente, para $M_w \geq 9,2$, prácticamente todos los puntos de deslizamiento analizados convergen a la Monte Carlo. Las profundidades de flujo máximas pueden llegar hasta 8 m (en eventos M_w 9.5).




Figura 16: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Coronel.

Para la localidad de Coronel, para las magnitudes registradas en la Figura 16, se puede observar de que no se registran profundidades de flujo para los escenarios de ruptura seleccionados mediante SROM. Sin embargo, para eventos M_w 9,5, se pueden registrar profundidades de flujo máximas de hasta 3 m.




Figura 17: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Valdivia.

En Valdivia, la Figura 17 muestra que existe convergencia a la Monte Carlo, sin embargo, a medida que aumenta la magnitud de los terremotos, se pierde la predicción de los deslizamientos sobre las profundidades de flujo. Para M_w 8,6, se tienen profundidades de flujo que llegan a 3 m. Para M_w 8,8 – 9,0, alcanzan 8 y 5 m, respectivamente. Finalmente, en eventos M_w 9,2, se tienen profundidades de flujo que llegan a superar 9 m.




Figura 18: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Puerto Montt.

En Puerto Montt, la Figura 18 se puede notar una convergencia clara de los eventos cuyos puntos de deslizamiento donde se aplica SROM son cercanos a la ciudad. Incluso en los eventos de campo lejano existe una convergencia en las predicciones de profundidades de flujo a la Monte Carlo, sin embargo, esto cambia para M_w 9,2. Pero los puntos cercanos mantienen su convergencia incluso para magnitudes mayores. Por otro lado, se tiene que las profundidades de flujo en ningún caso sobrepasan 3 m.




Figura 19: Curvas de distribución acumulada de profundidad de flujo para la ciudad de Ancud.

En Ancud, la Figura 19 muestra que sucede el mismo comportamiento que en Valdivia. Las curvas convergen a la curva de Monte Carlo, sin embargo, a medida que aumenta la magnitud, la convergencia se va perdiendo incluso en los puntos de ruptura cercanos a la localidad. Para las profundidades de flujo estimadas, se tiene que para M_w 8,6 – 8,8 alcanzan hasta 3,5 m aproximadamente, mientras que para M_w 9,0 y 9,2 alcanzan 5 m y 3 m, respectivamente.

Para la aplicación de SROM a puntos del dominio de las métricas de tsunamis, en este caso las profundidades de flujo, se realiza el estudio sobre la predicción de deslizamientos en los puntos del dominio como proceso inverso a lo mostrado anteriormente.




Figura 20: Curvas de distribución acumulada de deslizamiento para la ciudad de Antofagasta.

En Antofagasta, la Figura 20 muestra que las profundidades de flujo estiman bien los deslizamientos en un determinado punto del dominio. La distribución converge a la Monte Carlo de deslizamientos y puede predecir el deslizamiento máximo, sobretudo en los puntos cercanos a donde se registró la métrica de tsunamis. Esto se puede apreciar para todas las ciudades costeras, sin embargo, puntos de métrica lejanos tienen problemas para predecir deslizamientos cerca de la ciudad de análisis. Los deslizamientos máximos pueden llegar hasta casi 30 m en terremotos M_w 9,0.




Figura 21: Curvas de distribución acumulada de deslizamiento para la ciudad de La Serena.

En La Serena se puede notar el problema a la convergencia que tienen algunos puntos de métrica de tsunamis que están lejos del punto de deslizamiento de la localidad. La Figura 21 muestra que incluso algunos puntos locales tienen problemas para predecir el deslizamiento, al menos para tamaños de muestreo $m = 50$.

Respecto a la concentración de escenarios de ruptura, se realiza un análisis de estos para ver si existe cierta tendencia a determinados escenarios de ruptura, por lo que se realiza un mapa de deslizamiento promedio a lo largo de todo el dominio para magnitudes M_w 8,6, 8,8, 9,0 y 9,2, como se observa desde la Figura 22-25.




Figura 22: Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 8,6.




Figura 23: Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para M_w 8,8.

Mw 9.0




Figura 24: Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para $M_w 9,0$.

Mw 9.2




Figura 25: Mapa de calor de deslizamientos promedio a lo largo del dominio de ruptura para distintos tamaños de muestreo para $M_w 9,2$.

6. Discusión

Actualmente, los mapas oficiales de tsunami están basados en terremotos históricos, con magnitudes estimadas y recurrencia desconocida debido a la falta de registros. Por otro lado, se tiene que estimaciones propuestas a través de enfoques determinísticos tienden a subestimar el peligro real cuando la cantidad de fuentes sísmicas utilizadas son limitadas (Melgar et al., 2019). No obstante, se está pasando de estudios con enfoques del tipo “peor caso posible” con un escenario de estudio único y una línea global de inundación en un mapa completo como los que son utilizados hoy en día por las autoridades, a mapas de tsunami obtenidos a través de enfoques probabilísticos con miles de escenarios de ruptura distintos capaces de provocar inundaciones en las costas. Esto es una gran ventaja ya que se tienen muchos más casos de análisis que los registros históricos pueden proporcionar.

Gracias a estudios como (Aranguiz et al., 2024; Becerra et al., 2020; Sepúlveda et al., 2017; Zamora et al., 2021), se ha avanzado considerablemente en el entendimiento y la aplicación de análisis probabilísticos de peligro de tsunami en Chile. Si bien la mayor parte de estas investigaciones han sido para solo un caso de estudio, este último extiende el análisis para 11 ciudades costeras de norte a sur, siendo el primer estudio completo de PTHA en la región de subducción de la costa de Chile. Continuando ese enfoque, la presente investigación estudió 13 localidades costeras que se encuentran potencialmente en peligro de inundación por tsunami, analizando si el método utilizado para estimar y generar estos mapas de inundación es suficientemente sólido y fiable para utilizar estos mapas en planes y medidas preventivas de evacuación e incluso en el eventual uso de estos mapas en normativas de diseño de estructuras.

Uno de los principales problemas en la aplicación de PTHA es el costo computacional asociado para realizar las simulaciones de inundación, ya que cada una puede tardar varias horas como se ve en González et al., 2020, es por esto que se requiere de un modelo que sea capaz de seleccionar inteligentemente qué escenarios simular. Sepúlveda et al., 2017 aplica el modelo SROM (Stochastic Reduced Order Model, (Grigoriu, 2009)) ya que resulta ser una versión optimizada del análisis Monte Carlo clásico (Becerra et al., 2020), seleccionando los escenarios de tal manera en que las estadísticas de las muestras se mantienen similares a la base de datos original. Goda, 2022 utiliza 5000 escenarios de ruptura estocásticos entre M_w 8,1 – 9,1, es decir, 500 escenarios cada M_w 0,1. Por otro lado, Aranguiz et al., 2024 reduce el costo computacional utilizando 400 escenarios de ruptura estocásticos entre M_w 8,0 – 9,6, es decir, 50 escenarios cada M_w 0,2 pero no se profundiza acerca de la representatividad del método de reducción de escenarios. Es por esto que, en el presente estudio, mediante SROMPy (Warner, 2018) se aplicó SROM a una base de datos de 2587 escenarios para analizar su convergencia.

Luego de utilizar las ecuaciones de Blaser et al., 2010, se puede notar que un gran porcentaje de los escenarios generados no pasa el filtro. Esto puede deberse a muchas causas en el método de generación de escenarios, ya que existen muchos supuestos para llevar a cabo la modelación; sin embargo, un punto puede ser la deformación del área de ruptura cuando los escenarios están muy cerca de los límites del dominio. Esta deformación o estiramiento del largo y/o el ancho de ruptura pueden generar que, al establecer los rangos mínimos y máximos para L y W mediante las ecuaciones de Blaser, esta condición produzca que sean escenarios considerados como no factibles, y por ende, resulten descartados. Sin embargo, la cantidad de escenarios permite, para ciertas magnitudes, la consideración de tamaños de muestreo de hasta 200 escenarios, por lo que el análisis de convergencia llevado a cabo aún así considera mayores tamaños de muestra que investigaciones anteriores. Mediante SROM se seleccionan los escenarios de manera tal que compartan las propiedades estadísticas con la base de datos de la magnitud a la que pertenecen, para obtener el comportamiento esperado tanto del deslizamiento como de las profundidades de flujo en los puntos de estudio (Figura 2 y Figura 3).

Para los mapas de profundidad de flujo a través del filtrado de puntos de deslizamientos en distintas rupturas, se puede observar que más que el tamaño del vector de muestras en la precisión de la función de distribución acumulada, es el punto de deslizamiento seleccionado el que en primera instancia determina si la curva de distribución acumulada de la profundidad de flujo es convergente a la Monte Carlo. Esto resulta bastante lógico debido a que existe una relación directa entre el deslizamiento en la falla con el movimiento de cuerpos de agua producto de la deformación del suelo marino, cuando este se produce en la zona de estudio. Otro dato clave a recalcar es que los puntos seleccionados mediante SROM no son centroides de ruptura, sino que son puntos del dominio en los que algunos escenarios tienen valores de deslizamiento. Por lo que el análisis considera el comportamiento estadístico de esa grilla, para un determinado tamaño de muestras respecto a la base de datos completa. Es interesante notar que puntos de la grilla que pueden o no participar de la ruptura, así como pueden aportar con grandes valores de deslizamiento o no, tienen características predictivas en métricas de tsunamis. Siguiendo este mismo punto, se puede notar que existen puntos lejanos que funcionan como un buen predictor de profundidad de flujo en eventos de campo lejano, aunque la tendencia muestra que predecir las profundidades de flujo mediante puntos lejanos es muy conservador, ya que tiende a sobrestimar los datos de profundidad (Figura 7-19). Este comportamiento puede ser relevante y es un enfoque merecedor de análisis en investigaciones posteriores para estudiar las causas. Otro comportamiento que se observa en los puntos lejanos, en las mismas figuras anteriormente mencionadas, es que tienen un carácter no convergente para las CDFs de M_w 9,2. Esto ocurre mientras más hacia el norte o más hacia el sur se analice, esto se puede explicar en que, al contar con una cantidad reducida de escenarios como muestras estadísticamente representativas (los centroides de ruptura se concentran

entre entre 24°S y 34°S), puede que el comportamiento estadístico de ese punto del dominio no esté bien cubierto en el catálogo de escenarios de ruptura generados. Por lo tanto, funciona como propagador de incertidumbre en las curvas de distribución de profundidad de flujo donde se quiere analizar, lo que produce la tendencia no convergente a la curva Monte Carlo en algunos de los gráficos mostrados (Figura 7-8, Figura 17-19). Otro punto interesante puede ser que, para magnitudes grandes, el método de generación de deslizamientos de ruptura o las relaciones de escala favorecen distribuciones de deslizamientos que pierden esa correlación con la profundidad de flujo. Por otro lado, puede ser que para esos niveles de ruptura existan otros factores que ganan más preponderancia en el nivel de inundación que la distribución de deslizamientos.

Se puede notar que un tamaño de 200 muestras tiene una convergencia clara a la curva Monte Carlo para las métricas de profundidad de flujo (Figura 7-10, Figura 15-17), dependiendo del punto de deslizamiento en donde se aplicó el SROM. Sin embargo, existen puntos donde con menos muestras, se puede obtener una buena representación de la curva de Monte Carlo, y pueden ser incluso una mejor representación que tamaños de muestra mayores (Figura 11-13, Figura 18-19). Esto se puede producir porque existe un tamaño óptimo que representa las propiedades estadísticas de la base de datos, y, si ese tamaño se supera, la redundancia de escenarios puede empeorar la convergencia a la Monte Carlo. Por lo que, se necesita estudiar mejor este comportamiento para cada zona en particular. Esto es debido a que, como ha señalado en (Aranguiz et al., 2024), estudios específicos para cada sitio son más recomendados en términos de inundación así como en medidas preventivas. En consecuencia, el estudio del tamaño de muestreo óptimo para una convergencia a la curva Monte Carlo de la métrica de tsunami de interés también debe ser realizado para cada ubicación de interés de manera particular. Por otro lado, también juega un rol clave la variabilidad de escenarios de ruptura. Mientras más escenarios de ruptura distintos, mayor variabilidad estadística se tiene, lo que haría más fácil el seleccionar escenarios para mantener al mínimo las diferencias estadísticas con la base de datos original. El comportamiento visto en estas curvas, podría sugerir una poca variabilidad estadística en las rupturas, que es una tendencia que se puede ver desde la Figura 22-25. No obstante, esta tendencia también puede significar que existe una gran cantidad de escenarios de ruptura potenciales en la zona centro-norte de Chile (24°S a 34°S) con potencial de registrar los deslizamientos máximos fijados en la expansión K-L. Esto tiene particular relación con el gran déficit de liberación de energía conocido en la zona central (30°S a 38°S) (Carvajal et al., 2017), ya que la gran parte de los centroides de ruptura se encuentran en esta zona del dominio.

Analizando el SROM aplicado a las profundidades de flujo, se puede observar que existe una relación clara entre deslizamientos y profundidades de flujo, ya que ambos enfoques son convergentes a la Monte Carlo del otro. Esto sugiere que aplicar el SROM a puntos

del dominio de deslizamientos es un enfoque válido para predecir el comportamiento del potencial tsunami generado producto de una determinada ruptura. Sin embargo, un factor que es importante considerar es el costo computacional que representa realizar el SROM a las métricas de tsunami. Los tiempos de cálculo para el SROM en una sola grilla para tamaños de muestra de 100 escenarios o más es de varias horas, en este caso, cumple el propósito de mostrar que existe una convergencia de ambas variables entre sí y que funcionan como predictores de su comportamiento mutuamente. Sin embargo, para investigaciones posteriores, aplicar SROM al dominio de rupturas es el camino a seguir.

Respecto a la veracidad de las profundidades de flujo seleccionadas, se puede observar que los resultados son consistentes con investigaciones anteriores. En Arica, los mapas de Aranguiz et al., 2024 tienen profundidades de flujo de más de 10 *m*, que están en concordancia con los casi 12 *m* observados en las curvas de distribución acumulada del presente estudio (Figura 7). Para la ciudad de Iquique, observando los mapas de inundación de González et al., 2020, se tiene que la profundidad de flujo máxima alcanza entre 10 – 24 *m*, mientras que en los mapas de Aranguiz et al., 2024 alcanzan entre 5 – 10 *m*. Observando la Figura 8, se puede notar que la máxima profundidad de flujo alcanza los 13 *m* aproximadamente, por lo que se encuentra dentro del rango de los resultados de estas investigaciones. En La Serena, Aranguiz et al., 2024 obtiene profundidades de flujo entre 5 – 10 *m*, que es lo observado según la Figura 10 con profundidades de flujo máximas que llegan aproximadamente a 12 *m*. En Viña del Mar, se tiene un máximo de profundidad de flujo 13 *m* (Figura 11), similar a la profundidad de inundación obtenida en Aranguiz et al., 2024 que también supera 10 *m*, y lo obtenido por Zamora et al., 2021 que se encuentra entre 15 – 20 *m*. Para Valparaíso, se tiene un máximo de 18 *m* aproximadamente, que están en concordancia con el rango de 15 – 20 *m* obtenidos en Zamora et al., 2021. En Talcahuano, Aranguiz et al., 2024 obtiene profundidades de flujo entre 3 – 5 *m* de manera generalizada, en este estudio, la Figura 14 muestra profundidades máximas de inundación que llegan a 6 *m* aproximadamente. Finalmente, el hecho de que Coronel no tenga profundidades de flujo para los escenarios de tsunami (Figura 16) es muy consistente con el trabajo realizado por Aranguiz et al., 2024, dado que tienen hallazgos similares. Esto se explica, como bien señalan en su trabajo, dado que es una bahía protegida contra tsunamis debido a su ubicación en el Golfo de Arauco, la presencia del Cañón de Bío Bío y la Isla Santa María, reduciendo impactos de tsunami.

Una de las limitaciones de la presente investigación es no obtener los parámetros de recurrencia G-R, ya que la incertidumbre relacionada a los terremotos que provocan los tsunamis estudiados es algo crucial que se debe tener en consideración. La ley G-R relaciona una magnitud de terremoto con el número de terremotos sobre esa magnitud, siendo la pendiente de esta relación el parámetro *b*. El problema es que dependiendo la metodología utilizada, se afecta considerablemente la distribución de los valores de *b* obtenidos.

Lo anterior tiene como resultado que, en todos los estudios, debido a los catálogos sísmicos generados, los segmentos espaciales y/o temporales utilizados, entre otros factores, se obtienen valores de inundación distintos (Morales-Yáñez et al., 2022). Aranguiz et al., 2024 muestra que los mapas de inundación son bastante sensibles a los valores de b , por lo que es un factor importante que se debe analizar más a profundidad para tener una base sólida para comparar resultados entre investigaciones.

7. Conclusión

El presente estudio tuvo por objetivo evaluar la convergencia de Stochastic Reduced Order Models (SROM) en la estimación del peligro de tsunami a lo largo de las costas chilenas, utilizando una base de datos de 40.609 escenarios sísmicos. A través de la aplicación de SROM mediante SROMPy sobre una base de datos reducida a partir de relaciones de escala, se analizó la capacidad del modelo para representar adecuadamente las propiedades estadísticas del catálogo de escenarios. Esto a través de la obtención de las curvas de distribución acumulada a partir de los deslizamientos de ruptura y también de las profundidades de flujo registradas.

Se observó que el método SROM es un método confiable para seleccionar los escenarios más representativos de un catálogo de terremotos sin perder su variabilidad estadística a través de los deslizamientos de ruptura. Por otro lado, al utilizar estos escenarios para estimar las profundidades de flujo de tsunami se puede notar una tendencia a la convergencia hacia los resultados obtenidos por Monte Carlo. Sin embargo, dicha convergencia depende del punto de análisis dentro del dominio y del tamaño de muestra seleccionado, existiendo casos donde un número intermedio de muestras ofrece una mejor representación que tamaños mayores. Esto sugiere la existencia de un tamaño óptimo de muestra que debería determinarse para cada sitio de estudio en particular, o en su defecto, una señal de que se deben optimizar los métodos de generación y filtrado de escenarios para obtener una mayor variabilidad; de esta forma, la tendencia a la convergencia puede ser más rápida para un tamaño de muestras dado. Por otro lado, se debe analizar la influencia de otras variables que pueden propagar incertidumbre en la predicción de las profundidades de flujo a través de escenarios de ruptura; tales como la geomorfología del lugar de estudio, la batimetría, la influencia de la marea, la consideración de eventos de campo lejano, el régimen de ola considerado, el método de generación de escenarios, las propias relaciones de escala, entre otras.

Adicionalmente, se verificó la posibilidad de que los deslizamientos de ruptura puedan actuar como predictores del comportamiento de las métricas de tsunami, demostrando que la aplicación del SROM al dominio de rupturas constituye una alternativa eficiente

para la reducción de escenarios sin pérdida de precisión estadística. Pese a ello, se reconoce que el costo computacional asociado al método aún representa una limitante práctica para su aplicación a gran escala. Del mismo modo, se corroboró que existe una correlación directa entre deslizamiento y profundidad de flujo. Cuando el primero aumenta, el segundo también y viceversa. Además, este comportamiento se puede observar realizando el procedimiento en cualquier dirección de análisis. Un enfoque interesante para estudios posteriores es analizar si la distribución del deslizamiento tiene este comportamiento con otras métricas de tsunamis.

Finalmente, los resultados obtenidos son consistentes con investigaciones previas en Chile en términos de profundidades de flujo obtenidas, lo que refuerza la validez del enfoque propuesto y sugiere que es una metodología con futuro en medidas de prevención y seguridad. Sin embargo, futuras investigaciones deberán incorporar la incertidumbre asociada a los parámetros de recurrencia sísmica, como lo es el parámetro b de la ley Gutenberg-Richter, dado su impacto directo en la caracterización probabilística del peligro de tsunamis. De esta forma, el uso de SROM en estudios de peligro de tsunamis se consolida como una herramienta útil para la generación eficiente y estadísticamente robusta de mapas de inundación probabilísticos, contribuyendo al desarrollo de metodologías eficaces para la gestión del riesgo y el eventual decreto de normativas de diseño de estructuras críticas en la zona costera a lo largo de todo Chile.

Referencias

- Adriano, B., Mas, E., Koshimura, S., Fujii, Y., Yauri Condo, S. A., Jimenez, C., & Yanagisawa, H. (2013). Tsunami inundation mapping in Lima, for two tsunami source scenarios.
- An, C., Sepúlveda, I., & Liu, P. L.-F. (2014). Tsunami source and its validation of the 2014 Iquique, Chile, earthquake. *Geophysical Research Letters*, *41*(11), 3988-3994.
- Angermann, D., Klotz, J., & Reigber, C. (1999). Space-geodetic estimation of the Nazca-South America Euler vector. *Earth and Planetary Science Letters*, *171*(3), 329-334.
- Aranguiz, R., Ramos, M., Sepúlveda, I., & Villagra, P. (2024). A new generation of tsunami inundation maps of Chilean cities: tsunami source database and probabilistic hazard analysis. *Coastal Engineering Journal*, *66*(2), 361-379.
- Argus, D. F., Gordon, R. G., Heflin, M. B., Ma, C., Eanes, R. J., Willis, P., Peltier, W. R., & Owen, S. E. (2010). The angular velocities of the plates and the velocity of Earth's centre from space geodesy. *Geophysical Journal International*, *180*(3), 913-960.
- Basili, R., Brizuela, B., Herrero, A., Iqbal, S., Lorito, S., Maesano, F. E., Murphy, S., Perfetti, P., Romano, F., Scala, A., et al. (2021). The making of the NEAM tsunami hazard model 2018 (NEAMTHM18). *Frontiers in Earth Science*, *8*, 616594.
- Becerra, I., Aránguiz, R., González, J., & Benavente, R. (2020). An improvement of tsunami hazard analysis in Central Chile based on stochastic rupture scenarios. *Coastal Engineering Journal*, *62*(4), 473-488.
- Behrens, J., Løvholt, F., Jalayer, F., Lorito, S., Salgado-Gálvez, M. A., Sørensen, M., Abadie, S., Aguirre-Ayerbe, I., Aniel-Quiroga, I., Babeyko, A., et al. (2021). Probabilistic tsunami hazard and risk analysis: A review of research gaps. *Frontiers in Earth Science*, *9*, 628772.
- Benson, W. E., & Berg Jr, J. W. (1988). *Probabilistic Seismic Hazard Analysis* (inf. téc.).
- Blaser, L., Krüger, F., Ohrnberger, M., & Scherbaum, F. (2010). Scaling relations of earthquake source parameter estimates with special focus on subduction environment. *Bulletin of the Seismological Society of America*, *100*(6), 2914-2926.
- Boore, D. M., Joyner, W. B., & Fumal, T. E. (1997). Equations for estimating horizontal response spectra and peak acceleration from western North American earthquakes: A summary of recent work. *Seismological research letters*, *68*(1), 128-153.
- Budnitz, R., Apostolakis, G., & Boore, D. M. (1997). *Recommendations for probabilistic seismic hazard analysis: guidance on uncertainty and use of experts* (inf. téc.). US Nuclear Regulatory Commission (NRC), Washington, DC (United States). Div . . .
- Carvajal, M., Cisternas, M., & Catalán, P. (2017). Source of the 1730 Chilean earthquake from historical records: Implications for the future tsunami hazard on the

-
- coast of Metropolitan Chile. *Journal of Geophysical Research: Solid Earth*, 122(5), 3648-3660.
- Catalán, P. A., Aránguiz, R., González, G., Tomita, T., Cienfuegos, R., González, J., Shrivastava, M. N., Kumagai, K., Mokrani, C., Cortés, P., et al. (2015). The 1 April 2014 Pisagua tsunami: observations and modeling. *Geophysical Research Letters*, 42(8), 2918-2925.
- Catalan, P. A., Gubler, A., Cañas, J., Zuñiga, C., Zelaya, C., Pizarro, L., Valdes, C., Mena, R., Toledo, E., & Cienfuegos, R. (2020). Design and operational implementation of the integrated tsunami forecast and warning system in Chile (SIPAT). *Coastal Engineering Journal*, 62(3), 373-388.
- Cheung, K. F., Bai, Y., & Yamazaki, Y. (2013). Surges around the Hawaiian Islands from the 2011 Tohoku tsunami. *Journal of Geophysical Research: Oceans*, 118(10), 5703-5719.
- Cho, Y.-S., Hwang, H.-S., Kim, J.-Y., & Kwon, H.-H. (2016). Development of Hazard Map with probable maximum tsunamis. *Journal of Coastal Research*, (75), 1057-1061.
- Cornell, C. (1976). Engineering seismic risk analysis, Bulletin of the Seismological Society of America.
- Council, N. R., on Earth, D., on Earth Sciences, B., on Geosciences, C., on Seismology, C., & on Seismic Hazard Evaluation, P. (1997). *Review of recommendations for probabilistic seismic hazard analysis: Guidance on uncertainty and use of experts*. National Academies Press.
- De Risi, R., & Goda, K. (2016). Probabilistic earthquake–tsunami multi-hazard analysis: Application to the Tohoku region, Japan. *Frontiers in Built Environment*, 2, 25.
- Gebco, B. (2019). The GEBCO_2019 Grid—a Continuous Terrain Model of the Global Oceans and Land. *BODC [data set]*.
- Geist, E. L., & Lynett, P. J. (2014). Source processes for the probabilistic assessment of tsunami hazards. *Oceanography*, 27(2), 86-93.
- Geist, E. L., & Parsons, T. (2006). Probabilistic analysis of tsunami hazards. *Natural Hazards*, 37(3), 277-314.
- Goda, K. (2022). Stochastic source modeling and tsunami simulations of Cascadia subduction earthquakes for Canadian Pacific coast. *Coastal Engineering Journal*, 64(4), 575-596.
- Goda, K., Yasuda, T., Mori, N., & Maruyama, T. (2016). New scaling relationships of earthquake source parameters for stochastic tsunami simulation. *Coastal Engineering Journal*, 58(3), 1650010-1.
- González, J., González, G., Aránguiz, R., Melgar, D., Zamora, N., Shrivastava, M. N., Das, R., Catalan, P. A., & Cienfuegos, R. (2020). A hybrid deterministic and stochastic approach for tsunami hazard assessment in Iquique, Chile. *Natural Hazards*, 100(1), 231-254.

-
- Graves, R. W., & Pitarka, A. (2010). Broadband ground-motion simulation using a hybrid approach. *Bulletin of the Seismological Society of America*, 100(5A), 2095-2123.
- Grezio, A., Babeyko, A., Baptista, M. A., Behrens, J., Costa, A., Davies, G., Geist, E. L., Glimsdal, S., González, F. I., Griffin, J., et al. (2017). Probabilistic tsunami hazard analysis: multiple sources and global applications. *Reviews of Geophysics*, 55(4), 1158-1198.
- Grigoriu, M. (2009). Reduced order models for random functions. Application to stochastic problems. *Applied Mathematical Modelling*, 33(1), 161-175.
- Gusman, A. R., Murotani, S., Satake, K., Heidarzadeh, M., Gunawan, E., Watada, S., & Schurr, B. (2015). Fault slip distribution of the 2014 Iquique, Chile, earthquake estimated from ocean-wide tsunami waveforms and GPS data. *Geophysical Research Letters*, 42(4), 1053-1060.
- Gutenberg, B., & Richter, C. F. (1944). Frequency of earthquakes in California. *Bulletin of the Seismological society of America*, 34(4), 185-188.
- Hayes, G. P., Moore, G. L., Portner, D. E., Hearne, M., Flamme, H., Furtney, M., & Smoczyk, G. M. (2018). Slab2, a comprehensive subduction zone geometry model. *Science*, 362(6410), 58-61.
- Hayes, G. P., Wald, D. J., & Johnson, R. L. (2012). Slab1. 0: A three-dimensional model of global subduction zone geometries. *Journal of Geophysical Research: Solid Earth*, 117(B1).
- Kajiura, K. (1970). 45. Tsunami source, energy and the directivity of wave radiation. *Bulletin of the Earthquake Research Institute*.
- Kozdon, J. E., & Dunham, E. M. (2013). Rupture to the trench: Dynamic rupture simulations of the 11 March 2011 Tohoku earthquake. *Bulletin of the Seismological Society of America*, 103(2B), 1275-1289.
- Kramer, S. L. (2014). Performance-based design methodologies for geotechnical earthquake engineering. *Bulletin of Earthquake Engineering*, 12(3), 1049-1070.
- Lay, T. (2015). The surge of great earthquakes from 2004 to 2014. *Earth and Planetary Science Letters*, 409, 133-146.
- Lay, T., Kanamori, H., Ammon, C. J., Koper, K. D., Hutko, A. R., Ye, L., Yue, H., & Rushing, T. M. (2012). Depth-varying rupture properties of subduction zone megathrust faults. *Journal of Geophysical Research: Solid Earth*, 117(B4).
- Lay, T., Yue, H., Brodsky, E. E., & An, C. (2014). The 1 April 2014 Iquique, Chile, mw 8.1 earthquake rupture sequence. *Geophysical Research Letters*, 41(11), 3818-3825.
- LeVeque, R. J., Waagan, K., González, F. I., Rim, D., & Lin, G. (2016). Generating random earthquake events for probabilistic tsunami hazard assessment. En *Global Tsunami Science: Past and Future, Volume I* (pp. 3671-3692). Springer.

-
- Lorito, S., Selva, J., Basili, R., Romano, F., Tiberti, M., & Piatanesi, A. (2015). Probabilistic hazard for seismically induced tsunamis: accuracy and feasibility of inundation maps. *Geophysical Journal International*, 200(1), 574-588.
- Macías, J., Castro, M. J., Ortega, S., Escalante, C., & González-Vida, J. M. (2017). Performance benchmarking of tsunami-HySEA model for NTHMP's inundation mapping activities. *Pure and Applied Geophysics*, 174(8), 3147-3183.
- Mai, P. M., & Beroza, G. C. (2000). Source scaling properties from finite-fault-rupture models. *Bulletin of the Seismological Society of America*, 90(3), 604-615.
- Mai, P. M., & Beroza, G. C. (2002). A spatial random field model to characterize complexity in earthquake slip. *Journal of Geophysical Research: Solid Earth*, 107(B11), ESE-10.
- Mai, P. M., & Thingbaijam, K. (2014). SRCMOD: An online database of finite-fault rupture models. *Seismological Research Letters*, 85(6), 1348-1357.
- Meinig, C., Stalin, S. E., Nakamura, A. I., & Milburn, H. B. (2005). Real-time deep-ocean tsunami measuring, monitoring, and reporting system: The NOAA DART II description and disclosure. *NOAA, Pacific Marine Environmental Laboratory (PMEL)*, 1-15.
- Melgar, D., LeVeque, R. J., Dreger, D. S., & Allen, R. M. (2016). Kinematic rupture scenarios and synthetic displacement data: An example application to the Cascadia subduction zone. *Journal of Geophysical Research: Solid Earth*, 121(9), 6658-6674.
- Melgar, D., & Ruiz-Angulo, A. (2018). Long-lived tsunami edge waves and shelf resonance from the M8. 2 Tehuantepec earthquake. *Geophysical Research Letters*, 45(22), 12-414.
- Melgar, D., Williamson, A. L., & Salazar-Monroy, E. F. (2019). Differences between heterogeneous and homogeneous slip in regional tsunami hazards modelling. *Geophysical Journal International*, 219(1), 553-562.
- Morales-Yáñez, C., Bustamante, L., Benavente, R., Sippl, C., & Moreno, M. (2022). B-value variations in the Central Chile seismic gap assessed by a Bayesian transdimensional approach. *Scientific Reports*, 12(1), 21710.
- Mueller, C., Power, W., Fraser, S., & Wang, X. (2015). Effects of rupture complexity on local tsunami inundation: Implications for probabilistic tsunami hazard assessment by example. *Journal of Geophysical Research: Solid Earth*, 120(1), 488-502.
- Naim, N. N. N., Mardi, N. H., Malek, M. A., Teh, S. Y., Wil, M. A., Shuja, A. H., & Ahmed, A. N. (2021). Tsunami inundation maps for the northwest of Peninsular Malaysia and demarcation of affected electrical assets. *Environmental monitoring and assessment*, 193(7), 405.
- Núñez, I., Boroschek, R., Comte, D., & Contreras, V. (2014). Nuevo peligro sísmico para Chile. *Engineering Thesis*, 386.

-
- Plafker, G. (1997). Catastrophic tsunami generated by submarine slides and backarc thrusting during the 1992 earthquake on eastern Flores I., Indonesia. *Geological society of america, cordilleran section, 93rd annual meeting*, 29(5), 57.
- Poulos, A., Monsalve, M., Zamora, N., & de la Llera, J. C. (2019). An updated recurrence model for Chilean subduction seismicity and statistical validation of its Poisson nature. *Bulletin of the Seismological Society of America*, 109(1), 66-74.
- Raghukanth, S., & Sangeetha, S. (2016). A stochastic model for earthquake slip distribution of large events. *Geomatics, Natural Hazards and Risk*, 7(2), 493-521.
- Rosenau, M., Nerlich, R., Brune, S., & Oncken, O. (2010). Experimental insights into the scaling and variability of local tsunamis triggered by giant subduction megathrust earthquakes. *Journal of Geophysical Research: Solid Earth*, 115(B9).
- Ruiz, J., Fuentes, M., Riquelme, S., Campos, J., & Cisternas, A. (2015). Numerical simulation of tsunami runup in northern Chile based on non-uniform k-2 slip distributions. *Natural Hazards*, 79(2), 1177-1198.
- Saillard, M., Audin, L., Rousset, B., Avouac, J.-P., Chlieh, M., Hall, S. R., Husson, L., & Farber, D. (2017). From the seismic cycle to long-term deformation: Linking seismic coupling and Quaternary coastal geomorphology along the Andean megathrust. *Tectonics*, 36(2), 241-256.
- Satake, K., & Atwater, B. F. (2007). Long-term perspectives on giant earthquakes and tsunamis at subduction zones. *Annu. Rev. Earth Planet. Sci.*, 35(1), 349-374.
- Scholz, C. H. (2019). *The mechanics of earthquakes and faulting*. Cambridge university press.
- Scholz, C. H., & Campos, J. (2012). The seismic coupling of subduction zones revisited. *Journal of Geophysical Research: Solid Earth*, 117(B5).
- Sepúlveda, I., Liu, P. L.-F., Grigoriu, M., & Pritchard, M. (2017). Tsunami hazard assessments with consideration of uncertain earthquake slip distribution and location. *Journal of Geophysical Research: Solid Earth*, 122(9), 7252-7271.
- SHOA. (2012). Carta de inundación por tsunami (CITSU) de Valparaíso y Viña del Mar.
- SHOA. (2015). Pub. SHOA N° 3204: Instrucciones Oceanográficas N° 4," Especificaciones Técnicas para la Elaboración de Cartas de Inundación pot Tsunami (CITSU)". 1st ed.
- Sieh, K., Natawidjaja, D. H., Meltzner, A. J., Shen, C.-C., Cheng, H., Li, K.-S., Suwargadi, B. W., Galetzka, J., Philiposian, B., & Edwards, R. L. (2008). Earthquake supercycles inferred from sea-level changes recorded in the corals of west Sumatra. *Science*, 322(5908), 1674-1678.
- Simons, M., Minson, S. E., Sladen, A., Ortega, F., Jiang, J., Owen, S. E., Meng, L., Ampuero, J.-P., Wei, S., Chu, R., et al. (2011). The 2011 magnitude 9.0 Tohoku-Oki earthquake: Mosaicking the megathrust from seconds to centuries. *science*, 332(6036), 1421-1425.

-
- Sippl, C., Moreno, M., & Benavente, R. (2021). Microseismicity appears to outline highly coupled regions on the Central Chile megathrust. *Journal of Geophysical Research: Solid Earth*, 126(11), e2021JB022252.
- Strasser, F. O., Arango, M., & Bommer, J. J. (2010). Scaling of the source dimensions of interface and intraslab subduction-zone earthquakes with moment magnitude. *Seismological Research Letters*, 81(6), 941-950.
- Synolakis, C. E., & Bernard, E. N. (2006). Tsunami science before and beyond Boxing Day 2004. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 364(1845), 2231-2265.
- Tadono, T., et al. (2014). Precise Global DEM Generation by ALOS PRISM. ISPRS Annals Photogramm. Remote. Sens. Spatial Inf. Sci, 10.
- Valdivia Cáceres, V. (2019). *Mapa probabilístico de inundación por tsunami en el sector Bellavista, Tomé* [Tesis doctoral, Universidad Católica de la Santísima Concepción].
- Warner, J. E. (2018). *Stochastic reduced order models with python (SROMPpy)* (inf. téc.).
- Warner, J. E., Grigoriu, M., & Aquino, W. (2013). Stochastic reduced order models for random vectors: Application to random eigenvalue problems. *Probabilistic Engineering Mechanics*, 31, 1-11.
- Welch, B. L. (1951). On the comparison of several mean values: an alternative approach. *Biometrika*, 38(3/4), 330-336.
- Xiu, D. (2010). *Numerical methods for stochastic computations: a spectral method approach*. Princeton university press.
- Yamazaki, Y., Cheung, K. F., & Kowalik, Z. (2011). Depth-integrated, non-hydrostatic model with grid nesting for tsunami generation, propagation, and run-up. *International Journal for Numerical Methods in Fluids*, 67(12), 2081-2107.
- Yamazaki, Y., Cheung, K. F., & Lay, T. (2013). Modeling of the 2011 Tohoku near-field tsunami from finite-fault inversion of seismic waves. *Bulletin of the Seismological Society of America*, 103(2B), 1444-1455.
- Zamora, N., Catalán, P. A., Gubler, A., & Carvajal, M. (2021). Microzoning tsunami hazard by combining flow depths and arrival times. *Frontiers in Earth Science*, 8, 591514.