



Facultad de ingeniería
Escuela de ingeniería civil y geomática

Trabajo de Investigación:

Selección de modelos de movimiento del terreno para Colombia mediante criterios Bayesianos

Para optar al título de:

Magíster en Ingeniería, énfasis en Ingeniería Civil

Estudiante:

Bayron Salazar Manrique

bayron.salazar@correounivalle.edu.co

Tutores:

Albert Ortiz, Ph.D.

albert.ortiz@correounivalle.edu.co

Johannio Marulanda Casas, Ph.D.

johannio.marulanda@correounivalle.edu.co

República de Colombia

Santiago de Cali

Octubre - 2024

Agradecimientos

A mi familia. A mi madre Mariela Manrique y a mi tío Albeiro Manrique por su apoyo incondicional durante mis estudios de pregrado y posgrado. A Viviana, por su apoyo, cariño y paciencia,

A mis tutores. Al profesor Albert Ortiz por abrirme las puertas del grupo de investigación G7, por la confianza depositada en mí, por su paciencia y su apoyo durante el desarrollo de la maestría. Por haberme enseñado la importancia de la labor investigativa con ética y profesionalismo al servicio de la sociedad. Al profesor Johannio Marulanda Casas por su gestión para la financiación del proyecto que hizo posible esta investigación,

A mis asesores, la Dra. Mónica Arcila y al Ing. Julián Montejó por sus valiosísimos aportes teóricos y metodológicos. Por el tiempo dedicado para que esta investigación tuviera un mayor alcance e impacto. También por sus aportes para la divulgación de esta investigación en las XL Jornadas Sudamericanas de Ingeniería Estructural y el XI Congreso Nacional de Ingeniería Sísmica,

A los profesores Eimar Sandoval y Alejandro Cruz, por su apoyo moral durante mi presentación en la World Conference on Earthquake Engineering en Milán, Italia el 03/07/2024,

A mis profesores y a mis compañeros durante estos dos años de maestría en la Universidad del Valle.

Un agradecimiento especial al Ministerio de Ciencia, Tecnología e Innovación MINCIENCIAS por financiar mis estudios de Maestría mediante el proyecto “FORMACIÓN E INSERCIÓN DE CAPITAL HUMANO DE ALTO NIVEL PARA LAS REGIONES BIENIO 2021-2022 UNIVERSIDAD DEL VALLE, VALLE DEL CAUCA”

Tabla de Contenido

	Página
1. Introducción	1
1.1. Problema de investigación	1
2. Objetivos	4
3. Revisión de literatura	5
3.1. Ambiente tectónico	5
3.2. Modelos de movimiento del terreno	6
3.3. Modelos para fuentes corticales	9
3.3.1. Modelo de Arteta et al (2023)	9
3.3.2. Modelo de Idriss (2014)	10
3.3.3. Modelo de Cauzzi et al (2014)	10
3.4. Modelos para fuentes de subducción	11
3.4.1. Modelo de Arteta et al (2021)	11
3.4.2. Modelo de Montalva et al (2017)	12
3.4.3. Modelo de Zhao et al (2006)	13
3.5. Bayesian Model Updating	14
3.6. Bayesian Model Selection	16
4. Metodología	19
4.1. Base da datos de movimiento fuerte	19
4.2. Implementación computacional del BMU	19
4.2.1. Distribuciones Prior	19
4.2.2. Likelihood	22
4.3. Implementación computacional del BMS	23
5. Resultados	25
5.1. BMU para GMMs corticales	25
5.2. BMS para GMMs corticales	33
5.3. BMU para GMMs de subducción interplaca	35
5.4. BMS para GMMs de subducción interplaca	46
5.5. BMU para GMMs de subducción intraplaca	47
5.6. BMS para GMMs de subducción intraplaca	54
5.7. Discusión	56
6. Conclusiones	60

Índice de figuras

1.	Bases de datos de eventos de subducción en el Pacífico Colombiano y Ecuador para BMU y BMS.	20
2.	Bases de datos de eventos corticales para BMU y BMS.	21
3.	Diagrama del BMU en PyMC integrando datos, Priors y Likelihood.	23
4.	Gráfico hecho con la librería Arviz del proceso de muestreo para el modelo de ArtetaEtAl2023.	27
5.	Distribuciones Posterior obtenidas como resultado del BMU para el modelo de ArtetaEtAl2023 con un periodo espectral de 0,01 segundos (PGA).	28
6.	Distribuciones Posterior de BMU para CauzziEtAl2014 con un periodo espectral de 0,01 segundos.	29
7.	Distribuciones Posterior de BMU para Idriss2014 con un periodo espectral de 0,01 segundos.	29
8.	Desviaciones estándar totales de GMMs corticales regionalizados con BMU en función del periodo espectral.	30
9.	Posterior Predictive Check del modelo actualizado de ArtetaEtAl2023 con datos del sismo de Armenia 1999.	31
10.	Posterior Predictive Check del modelo actualizado de CauzziEtAl2014 con datos del sismo de Armenia 1999.	32
11.	Posterior Predictive Check del modelo actualizado de Idriss2014 con datos del sismo de Armenia 1999.	33
12.	Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 0,01 segundos (PGA). Fuente: autor. Software: Arviz-Python.	34
13.	Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 0,3 segundos.	35
14.	Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 5 segundos.	35
15.	Distribuciones Posterior de los coeficientes del GMM de AbrahamsonEtAl2015SInter para un periodo espectral de 0,01 segundos.	38
16.	Distribuciones Posterior de los coeficientes del GMM de ArtetaEtAl2021Inter para un periodo espectral de 0,01 segundos.	39
17.	Distribuciones Posterior de los coeficientes del GMM de MontalvaEtAl2017SInter para un periodo espectral de 0,01 segundos.	40
18.	Distribuciones Posterior de los coeficientes del GMM de ZhaoEtAl2006SInterNSHMP2008 para un periodo espectral de 0,01 segundos.	41
19.	Desviaciones estándar totales para GMMs de subducción interplaca regionalizados con BMU en función del periodo espectral.	42
20.	Posterior Predictive Checks del modelo AbrahamsonEtAl2015SInter para los eventos de subducción interplaca en la costa de Ecuador.	43
21.	Posterior Predictive Checks del modelo ArtetaEtAl2021Inter para los eventos de subducción interplaca en la costa de Ecuador.	43

22.	Posterior Predictive Checks del modelo MontalvaEtAl2017SInter para los eventos de subducción interplaca en la costa de Ecuador.	44
23.	Posterior Predictive Checks del modelo ZhaoEtAl2006SInterNSHMP2008 para los eventos de subducción interplaca en la costa de Ecuador.	44
24.	BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 0,01 segundos equivalente a PGA.	47
25.	BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 0,3 segundos.	47
26.	BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 5 segundos.	47
27.	Desviaciones estándar totales de GMMs para subducción intraplaca regionalizados con BMU en función del periodo espectral.	50
28.	Posterior Predictive Checks del modelo AbrahamsonEtAl2015SSlab con el sismo de Ansermanuevo.	51
29.	Posterior Predictive Checks del modelo ArtetaEtAl2021Slab con el sismo de Ansermanuevo.	52
31.	Posterior Predictive Checks del modelo ZhaoEtAl2006SSlabNSHMP2014 con el sismo de Ansermanuevo.	52
30.	Posterior Predictive Checks del modelo MontalvaEtAl2017SSlab con el sismo de Ansermanuevo.	53
32.	Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 0,01 segundos (PGA). Gráfico obtenido mediante Arviz.	55
33.	Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 0,3 segundos.	55
34.	Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 5 segundos.	55

Índice de tablas

1.	Pesos de los modelos de movimiento del terreno para cada ambiente tectónico en el Modelo Nacional de Amenaza Sísmica para Colombia (Arcila et al., 2020).	8
2.	Resumen de parámetros de entrada de los GMMs para fuentes de subducción.	14
3.	Resumen de la base de datos de movimiento fuerte utilizada en este estudio.	20
4.	Resultados de BMU para GMMs de fuentes corticales con periodo espectral de 0,01 segundos equivalente a PGA.	26
5.	Resultados de BMS con WAIC para GMMs de fuentes corticales.	34
6.	Resultados de BMU para el modelo AbrahamsonEtAl2015SInter con un periodo espectral de 0,01 segundos equivalente a PGA.	36
7.	Resultados de BMU para el modelo ArtetaEtAl2021Inter con un periodo espectral de 0.01 segundos.	36

8.	Resultados de BMU para el modelo MontalvaEtAl2017SInter con un periodo espectral de 0,01 segundos.	37
9.	Resultados de BMU para el modelo ZhaoEtAl2006SInterNSHMP2008 con un periodo espectral de 0,01 segundos.	37
10.	Resultados de BMS con WAIC para GMMs de subducción interplaca.	46
11.	Resultados de BMU para el modelo de AbrahamsonEtAl2015SSlab con un periodo espectral de 0,01 segundos (PGA).	48
12.	Resultados de BMU para el modelo de ArtetaEtAl2021Slab con un periodo espectral de 0,01 segundos (PGA).	48
13.	Resultados de BMU para el modelo de MontalvaEtAl2017SSlab con un periodo espectral de 0,01 segundos (PGA).	49
14.	Resultados de BMU para el modelo de ZhaoEtAl2006SSlabNSHMP2014 con un periodo espectral de 0,01 segundos (PGA).	49
15.	Resultados de BMS con WAIC para GMMs de subducción intraplaca.	54

Resumen

Los modelos de movimiento del terreno (Ground Motion Models GMM) tienen como objetivo calcular, de manera aproximada, la intensidad del movimiento generado por un sismo en función de las propiedades de la ruptura, la trayectoria de propagación de las ondas y los efectos de sitio. Estos modelos son parte fundamental del análisis probabilista de la amenaza sísmica (Probabilistic Seismic Hazard Analysis PSHA) y estudios de riesgo sísmico. Para la zona de subducción interplaca e intraplaca del occidente colombiano y para los eventos corticales, existen un largo listado de GMM globales y locales que han sido ampliamente usados en estudios de amenaza sísmica. Ante la pregunta de cuáles son los GMMs que tienen mayor probabilidad de representar las intensidades del movimiento registradas en Colombia, este trabajo propone una metodología que incluye el Bayesian Model Updating BMU y el Bayesian Model Selection BMS. Este método resulta conveniente en países como Colombia donde se cuenta con pocos datos de sismicidad asociada a distancias cortas y grandes magnitudes, fundamentales para PSHA. El BMU consiste en regionalizar los GMM globales con datos de sismicidad local, obteniendo distribuciones de probabilidad para los coeficientes de regresión y para la desviación estándar total. Los modelos regionalizados son comparados entre sí mediante BMS, usando el Watanabe-Akaike Information Criterion WAIC, que permite calificar el desempeño relativo de un modelo para realizar predicciones por fuera de los datos usados para el BMU. Los resultados muestran que los GMMs desarrollados a partir de datos locales tienen mejor calificación con el WAIC respecto a GMMs globales que se han usado en Colombia bajo el principio ergódico. Estos resultados permitirían estimar los pesos de los GMMs en un árbol lógico para PSHA, de forma que se obtengan resultados más precisos en los estudios de amenaza y riesgo sísmico en Colombia.

Palabras clave: Modelos de Movimiento del Terreno, Subducción, Norte de Sudamérica, PSHA, PSRA, Inferencia Bayesiana, WAIC.

Abstract

Ground Motion Models (GMMs) aim to estimate the motion intensity generated by earthquakes as a function of rupture properties, wave propagation and site effects. These models are fundamental for Probabilistic Seismic Hazard Analysis PSHA and Seismic Risk studies. A long list of global and regional models has been used for Seismic Hazard studies on subduction interface, intraslab earthquakes in the west of Colombia and for crustal earthquakes. However, there is still the need to determine which are the GMMs that have a better probability to represent the Ground-motion intensity measures in Colombia. To answer that question, this study proposes a method that includes Bayesian Model Updating BMU and Bayesian Model Selection BMS. This approach is particularly valuable in regions like Colombia, where data from large-magnitude earthquakes at short distances are scarce. This kind of data is fundamental for PSHA. The BMU regionalizes the global GMMs according to local data, obtaining probability distributions for both model parameters and total standard deviation. Then, the GMMs are compared with the BMS via Watanabe-Akaike Information Criterion (WAIC). This evaluation gives a rank of models according to their capabilities to make predictions beyond the dataset used for BMU. Results show that regional GMMs have better ranking in WAIC than global GMMs that have been used in Colombia under the ergodic assumption. The results indicate that regional GMMs achieve better WAIC rankings than global GMMs applied under the ergodic assumption in Colombia. These findings can inform the weighting of GMMs in the Logic Tree for PSHA, leading to more accurate hazard and risk assessments for Colombia.

Keywords: Ground Motion Models, Subduction, North Western South America, PSHA, PSRA, Bayesian Model Updating, Bayesian Model Selection, WAIC.

1. Introducción

La República de Colombia está ubicada al norte de Sudamérica, en una región de alta actividad sísmica. La población y la infraestructura civil colombiana han sufrido terremotos catastróficos, como el ocurrido en Armenia el 25 de enero de 1999 con una magnitud de momento M_W de 6,1. Este terremoto causó aproximadamente 1185 muertos, 8536 heridos, 35 972 viviendas totalmente destruidas o inhabitables, 6408 fincas cafeteras dañadas y pérdidas económicas estimadas en \$2,7 billones de pesos, equivalente al 2,2 % del PIB de 1998 (Sarabia Gómez et al., 2022).

Teniendo en cuenta este contexto, los ingenieros civiles en Colombia deben enfrentar el reto de diseñar y construir infraestructura resiliente. Los códigos de construcción sismorresistente, como el NSR-10 vigente en Colombia (Ministerio de Ambiente, 2010), se formulan a partir de modelos de amenaza sísmica. Éste se compone de un modelo de fuentes sísmicas, cuyo objetivo es establecer la frecuencia de ocurrencia de los eventos sísmicos y sus magnitudes esperadas. El modelo de amenaza también se compone de un conjunto de modelos de movimiento del terreno (Ground Motion Models GMM), los cuales permiten calcular de forma aproximada la intensidad del movimiento del suelo en un lugar de interés cuando ha ocurrido un terremoto. Tanto el modelo de fuentes sísmicas como los GMMs se integran dentro de un Análisis Probabilístico de la Amenaza Sísmica (Probabilistic Seismic Hazard Analysis PSHA en inglés). El objetivo del PSHA es calcular la tasa anual de excedencia de cierto parámetro de intensidad de movimiento del terreno, por ejemplo, la aceleración máxima del suelo (Peak Ground Acceleration PGA) para un determinado lugar.

Adicionalmente, un Análisis Probabilista del Riesgo Sísmico (Probabilistic Seismic Risk Analysis PSRA) calcula las probabilidades de pérdidas de vidas humanas, colapso de edificaciones y pérdidas económicas como producto de eventos sísmicos. El PSRA se compone de un modelo de amenaza sísmica, un modelo de exposición donde se caracteriza la población y las tipologías constructivas que están ubicadas en regiones susceptibles de terremotos, y un modelo de vulnerabilidad de las estructuras expuestas (Baker et al., 2021). Tanto en el PSHA como en el PSRA, los GMMs juegan un papel muy importante, pues son los que predicen el movimiento del terreno y a partir de esas estimaciones se calculan las probabilidades de ocurrencia de las consecuencias adversas en los elementos expuestos.

1.1. Problema de investigación

Los GMMs son desarrollados a partir de registros acelerográficos de la región estudiada. Sin embargo, en el contexto colombiano, hay escasez de registros acelerográficos de eventos sísmicos de grandes magnitudes a distancias cortas, pues la red sismológica nacional inició operaciones en 1993 (Servicio Geológico Colombiano, 1993). Este tipo de registros son fundamentales para desarrollar GMMs con capacidades predictivas para cálculos de PSHA y PSRA. La falta de registros sísmicos en intervalos específicos de magnitud-distancia en una región determinada depende no solo del lapso de tiempo de registro sino también de la distribución geométrica de las estaciones de registro (Baker et al., 2021). Estas razones hacen que sea un problema

común a nivel mundial, y normalmente se aborda utilizando el principio ergódico, donde los modelos se desarrollan utilizando datos de diferentes regiones del mundo (Anderson y Brune, 1999).

Ante este escenario, algunos autores han propuesto el enfoque de regionalización para armonizar los modelos globales con los datos locales. La idea central de la regionalización es que los parámetros que controlan las predicciones para grandes magnitudes y distancias cortas se toman prestados del modelo global, y el escalamiento para grandes distancias y magnitudes moderadas estará definido por los datos regionales (Akkar y Cagnan, 2010; Gülerce et al., 2016; Montalva et al., 2017; Scasserra et al., 2009). Recientemente, se han desarrollado algunos modelos mediante la regionalización de modelos globales para terremotos de subducción y corticales en Colombia (Arteta et al., 2021, 2023), así como para el Nido Sísmico de Bucaramanga (Pájaro et al., 2024).

Cuando se seleccionan los GMMs para el PSHA, es esencial considerar tanto la incertidumbre aleatoria como la epistémica (Scherbaum et al., 2005). La incertidumbre aleatoria se refiere a la aleatoriedad inherente en la generación del movimiento del suelo y normalmente se modela como un proceso aleatorio log-normal cuyas desviaciones estándar se definen dentro de los GMMs. Mientras que la incertidumbre epistémica surge de nuestra comprensión incompleta del proceso tectónico involucrado, y se puede abordar considerando diferentes modelos y asignando diferentes pesos a cada uno en función de nuestro conocimiento o datos actuales. Para esto, se define un listado de GMMs y se incorporan en un árbol lógico (Logic Tree) donde se le asigna un peso a cada uno para tener en cuenta la incertidumbre epistémica asociada a la predicción del movimiento del terreno (McGuire, 2004). Sin embargo, la cuestión de qué modelos utilizar, y específicamente cómo asignar pesos a cada modelo en el árbol lógico para el PSHA, sigue siendo materia de investigación.

Para asignar pesos a los GMM en el árbol lógico, es importante tener en cuenta, en primer lugar, que los pesos se aplican generalmente a los GMM en sí, no a las intensidades que estos GMM predicen (Bommer y Scherbaum, 2008; Scherbaum et al., 2005). En segundo lugar, las ramas del árbol lógico representan una distribución de probabilidad completa y no son una medida de qué tan bien o mal una rama en particular se ajusta a los datos para la región estudiada (Baker et al., 2021).

Considerando los argumentos mencionados anteriormente, este estudio propone un método basado en un marco probabilístico Bayesiano para seleccionar GMMs para las fuentes sísmicas corticales y de subducción en Colombia. El método incluye la Actualización Bayesiana de Modelos (Bayesian Model Updating BMU) y la Selección Bayesiana de Modelos (Bayesian Model Selection BMS). El BMU regionaliza los GMM globales utilizando una base de datos local de movimiento fuerte del suelo. El BMS compara los GMM regionalizados utilizando el Watanabe-Akaike Information Criterion (WAIC).

Este documento está dividido en las siguientes secciones:

- Objetivos: se presenta el objetivo general y los específicos.
- Revisión de literatura: Se aborda el ambiente tectónico colombiano, el desarrollo de GMMs y el método de BMU y BMS.

- Metodología: Se presenta la base de datos de movimiento fuerte y se explica la implementación de los métodos de BMU y BMS para las distintas fuentes sísmicas y GMMs escogidos para este trabajo.
- Resultados y discusión: Se presenta un análisis de los resultados obtenidos en este estudio y un análisis comparativo con relación a lo reportado en la literatura por otros autores.
- Conclusiones y recomendaciones.

Nota importante

Mientras se redactaba este documento de tesis también se estaban enviando para publicación dos artículos con los resultados de esta investigación. El primero se envió a la revista *Earthquake Spectra* y se titula *Bayesian Model Updating and Model Selection of Ground Motion Models for Crustal Earthquakes in Colombia*. Como su nombre lo indica, contiene los resultados para los GMMs de fuentes corticales. El segundo artículo fue enviado a la revista *Bulletin of Earthquake Engineering* y se titula *Bayesian Model Updating and Model Selection of Ground Motion Models for subduction earthquakes in Colombia* y contiene los resultados para GMMs de subducción interplaca e intraplaca. Por esta razón, es probable que los evaluadores de los artículos formulen correcciones y observaciones que serán incorporados a este trabajo tan pronto como sea posible.

2. Objetivos

Objetivo general

Proponer un método para seleccionar modelos de movimiento del terreno para PSHA en el territorio colombiano.

Objetivos específicos

1. Realizar una revisión de literatura de los GMMs utilizados en Colombia.
2. Recopilar una base de datos de movimiento fuerte del terreno para las fuentes sísmicas corticales y de subducción en Colombia.
3. Ajustar los GMMs para Colombia usando la base de datos del paso anterior mediante metodologías Bayesianas.
4. Seleccionar los modelos de atenuación más convenientes para el entorno Colombiano utilizando técnicas probabilísticas Bayesianas de selección de modelos.

3. Revisión de literatura

3.1. Ambiente tectónico

En el territorio colombiano se han estudiado al menos cuatro fuentes sísmicas principales: la zona de subducción interplaca en la costa del Pacífico, la zona de subducción intraplaca (también conocida como zona de Benioff), el Nido de Bucaramanga y las fuentes corticales (Arcila et al., 2020). Estas fuentes sísmicas están relacionadas con varios procesos geodinámicos: la convergencia de las placas de Nazca y Caribe hacia la placa Sudamericana; el desplazamiento del Bloque de Panamá en dirección O-E hacia la placa Sudamericana; y el desplazamiento del Bloque de los Andes en dirección SSO-NNE (Taboada et al., 2000). La actividad sísmica cortical está delimitada por el límite corteza-manto superior o discontinuidad de Mohorovičić (Moho), que se asocia a profundidades de hasta 70 km de acuerdo con Arcila et al. (2020).

Dada la interacción entre diferentes placas y bloques, Colombia se encuentra bajo la presencia de importantes sistemas de fallas como el Sistema de Fallas de Boconó, el Sistema de Cabalgamiento Frontal Oriental, el Sistema de Fallas de Guaicáramo, el Sistema de Fallas de Algeciras y el Sistema de Fallas Romeral, en la Frontera Amazónica (Costa et al., 2020).

En consecuencia, se han reportado varios terremotos destructivos en Colombia. Entre ellos se destacan el terremoto de M_W 6,1 Armenia – región cafetalera (1999), el terremoto de M_W 5,6 Popayán (1983), que afectó la ciudad de Popayán con más de 200 muertos y alrededor de USD 500 millones en pérdidas económicas (Lomnitz y Hashizume, 1985). Otros terremotos importantes incluyen el terremoto de Altamira de M_W 7,1 (1827), el terremoto de Cúcuta de M_W 6,8 (1875), el terremoto de Colombia de M_W 7,0 y el terremoto de Murindó de M_W 7,1 (1992), todos estos eventos tuvieron una intensidad macrosísmica de X en la escala EMS-98, lo que indica un gran daño (Sarabia Gómez et al., 2022).

Por otro lado, en la región del Pacífico sudamericano, la placa de Nazca subduce bajo la placa Sudamericana a una tasa de aproximadamente 6 cm por año, un proceso geodinámico que afecta la costa del Pacífico colombiano (Taboada et al., 2000). Este fenómeno genera una zona de subducción interplaca, resultado de la interacción entre ambas placas, donde son abundantes los terremotos inversos (Arcila et al., 2020). El terremoto con la mayor magnitud de momento (entre 8,4 y 8,8 según Yamanaka y Tanioka (2021)) registrado en la zona de subducción interplaca del Pacífico colombiano ocurrió el 31 de enero de 1906 (Lat. 0,99, Long. 79,35) (Chlieh et al., 2021; Pulido et al., 2020). Este evento alcanzó una intensidad de X en la escala macrosísmica EMS-98 (Sarabia Gómez et al., 2022) y generó un tsunami con olas de hasta 5 metros, impactando localidades costeras colombianas como Tumaco, Francisco Pizarro, Mosquera, La Tola, El Charco, Guapi, Timbiquí y López de Micay. Las autoridades colombianas reportaron más de 600 fallecidos, la mayoría debido al tsunami, junto con daños significativos en edificaciones por licuación y subsidencia en la costa sur del Pacífico colombiano (Sarabia Gómez et al., 2022). Otro ejemplo es el terremoto del 12 de diciembre de 1979, con una magnitud de momento de 8,1 y epicentro cerca de Tumaco, Nariño, en la costa del Pacífico de Colombia. Este evento causó más de 500 muertes, generó un tsunami

con olas de aproximadamente 3 metros y provocó grietas en el suelo, licuación y subsidencia (Sarabia Gómez et al., 2022).

Además, la placa de Nazca se flexiona mientras interactúa con el manto circundante, lo que genera fracturas en su superficie superior y produce terremotos intraplaca, caracterizados por mecanismos focales compuestos o normales (Lay y Wallace, 1995; Taboada et al., 2000; Thingbaijam et al., 2017). Estos eventos intraplaca suelen tener epicentros ubicados hasta 300 km tierra adentro a profundidades mayores de 60 km, lo cual puede influir significativamente en las evaluaciones de amenaza sísmica para ciudades del suroccidente colombiano como Cali y Popayán (Arcila et al., 2020). Entre 1938 y 1995 se registraron cinco eventos intraplaca con una intensidad de VIII o superior en la escala macrosísmica europea EMS-98, los cuales resultaron en aproximadamente 160 muertes, 1300 heridos y 900 edificaciones destruidas (Sarabia Gómez et al., 2022). Esto destaca la importancia de integrar GMMs para terremotos intraplaca en los estudios de amenaza sísmica en Colombia.

3.2. Modelos de movimiento del terreno

Los GMMs se expresan, generalmente, como una ecuación que calcula algún parámetro de intensidad (Intensity Measure IM) de movimiento del terreno en función de las propiedades de la ruptura, las propiedades del sitio de interés y los coeficientes de regresión del modelo.

Algunos de estos parámetros de intensidad (IM) son:

- La aceleración máxima del suelo (PGA),
- la media geométrica de la aceleración espectral Sa con 5 % de amortiguamiento para determinado periodo de vibración en las dos componentes horizontales principales,
- la aceleración espectral RotD50 con 5 % de amortiguamiento (Boore, 2010).

De acuerdo con los registros acelerográficos recolectados a nivel mundial, se ha establecido el criterio de que estos parámetros de intensidad siguen una distribución log-normal (Baker et al., 2021). Por tanto, la forma funcional del GMM se puede expresar por medio de una ecuación logarítmica:

$$\ln(IM) \sim N(\mu, \sigma) \quad (1)$$

donde:

$$\mu = f(rup, site, \theta) \quad (2)$$

μ es la mediana del parámetro de intensidad IM , σ es la desviación estándar total del modelo y θ son coeficientes de regresión del modelo. Las propiedades de la ruptura (rup) vienen dadas, por lo general, por la magnitud de momento M_W y en ocasiones se incluye un término referente al mecanismo focal (Style of fault). Las propiedades del sitio ($site$) vienen dadas por la distancia del sitio de interés al lugar donde se origina el terremoto. Métricas

comunes de distancia son la distancia más cercana a la ruptura R_{rup} y la distancia hipocentral R_{hypo} . Otra propiedad del sitio de interés es la caracterización de los efectos de sitio, para lo cual se suele usar la velocidad promedio de la onda de corte en los primeros 30 metros del depósito de suelo V_{S30} . Algunos modelos han implementado el periodo natural del depósito de suelo T_n para caracterizar los efectos de sitio (Mercado et al., 2023; Zhao et al., 2006).

En el contexto colombiano, diversos autores han contribuido a la evaluación de la amenaza sísmica, centrándose principalmente en el desarrollo de códigos sísmicos para el diseño de infraestructura. Los dos primeros mapas sísmicos fueron probablemente los desarrollados por la Asociación Colombiana de Ingeniería Sísmica AIS (Asociación Colombiana de Ingeniería Sísmica AIS, 1984, 1996) correspondientes a las primeras disposiciones sísmicas colombianas, el Decreto 1400 de 1984 y el NSR-98 (Decreto 33/1998). Estos mapas utilizaron los GMMs propuestos por Donovan (Donovan, 1973; Wright et al., 1973) y McGuire (1974), reconociendo la disponibilidad limitada de datos de movimiento fuerte para desarrollar un GMM regional o incluso validar los adoptados.

Martínez y Chica (1997) propusieron un GMM para Colombia a partir de sismos registrados entre 1993 y 1995 por la red nacional. La ecuación que describe el modelo es:

$$a = 260,26 \times e^{0,964M} (R + 25)^{-1,5828} \quad (3)$$

donde a es la aceleración en cm/s^2 , M es la magnitud local y debe estar entre 4.1 y 6.6, y R es la distancia hipocentral, entre 100 y 350 km.

Ojeda y Martínez (1998) desarrollaron un modelo a partir de registros sísmicos entre 1993 y 1996 de la red nacional, el cual tiene en cuenta valores de la magnitud M_s entre 3,1 y 6,6 y distancias hipocentrales R_h entre 20 y 400 km. Ya para entonces los autores pudieron identificar dos regiones sísmicas diferentes, una que denominaron activa y otra de subducción. Las ecuaciones respectivas son:

$$\begin{aligned} \ln(PGA) &= 5,3318 + 0,4779M_s - 1,157 \ln(R_h + 25) \\ \ln(PGA) &= 9,2487 + 0,4724M_s - 1,696 \ln(R_h + 25) \end{aligned} \quad (4)$$

Más recientemente, la AIS realizó un estudio de amenaza sísmica en 2009 para crear un mapa de amenaza sísmica para el país (Asociación Colombiana de Ingeniería Sísmica AIS, Comité AIS-300, 2009), que sirvió como un insumo crucial para el desarrollo del código de construcción actual de Colombia, NSR-10 (Ministerio de Ambiente, 2010). En este estudio, el AIS realizó un análisis de residuales sobre los modelos propuestos por Campbell-Strike (Campbell, 1997), Gallego-Active (Gallego, 2000) y Sadigh et al. (1997), comparando estos GMM con datos colombianos recolectados de la red sísmica nacional. El Campbell-Strike 1997 obtuvo el mejor desempeño en el análisis de residuales para sismos corticales en Colombia.

Posteriormente, Salgado-Gálvez et al. (2016) implementaron nuevos GMM utilizando registros de movimientos fuertes registrados en Colombia para realizar un nuevo PSHA con respecto al código sísmico CCP-14 para diseño de puentes.

Más recientemente, en el Modelo Nacional de Amenaza Sísmica para Colombia, Arcila et al. (2020) emplearon un método de tres pasos para seleccionar GMMs. Primero, realizaron una

preselección de GMMs considerando factores como rango de frecuencia, forma funcional del modelo y métodos de regresión apropiados. En segundo lugar, evaluaron el desempeño de los GMMs utilizando datos locales a través del análisis de residuales, el modelo de verosimilitud (LH), el modelo de verosimilitud logarítmica (LLH) y la calificación de distancia euclidiana (EDR). En tercer lugar, la calificación final (peso) asignado a cada modelo se basó en la calificación LLH (Scherbaum et al., 2009). La siguiente tabla muestra los pesos de los GMMs para cada fuente sísmica. La nomenclatura de los GMMs es la del motor de cálculo de OpenQuake Engine (Pagani et al., 2014).

Tabla 1: Pesos de los modelos de movimiento del terreno para cada ambiente tectónico en el Modelo Nacional de Amenaza Sísmica para Colombia (Arcila et al., 2020).

Ambiente tectónico	Modelo	Peso
Cortical	Idriss2014	0,399
	CauzziEtAl2014	0,389
	AbrahamsonEtAl2014	0,211
Subducción interplaca	AbrahamsonEtAl2015SInter	0,437
	ZhaoEtAl2006SInterNSHMP2008	0,348
	MontalvaEtAl2016SInter	0,215
Subducción intraplaca	MontalvaEtAl2016SSlab	0,424
	AbrahamsonEtAl2015SSlab	0,365
	ZhaoEtAl2006SSlabNSHMP2014	0,210

En este trabajo, se utilizaron los GMMs de la tabla 1 agregando los modelos de Arteta et al. (2021) para fuentes de subducción y Arteta et al. (2023) para fuentes corticales. A continuación se muestra cada uno de los GMMs usados en este estudio.

Los GMMs usualmente tienen coeficientes de regresión constantes y sus predicciones son la mediana de una distribución log-normal acotada por la desviación estándar total del modelo. Por esto, es una práctica común introducir modificaciones en los GMMs para tratar de capturar algún aspecto de la incertidumbre epistémica. Por ejemplo, para el modelo de amenaza sísmica propuesto por el USGS en 2008, se propuso un árbol lógico donde el GMM de B.-J. Chiou y Youngs (2008) fue modificado y dividido en tres ramas diferentes, cada rama con un peso diferente (Petersen et al., 2008). Estas modificaciones se hacen para tener en cuenta la incertidumbre epistémica que el modelo original es incapaz de capturar. Esto es especialmente cierto cuando los GMMs fueron calibrados a partir de conjuntos de datos similares o con GMMs cuya forma funcional es similar. Cuando eso sucede, es poco probable que ese conjunto de GMMs represente la incertidumbre epistémica completa asociada con la predicción del movimiento del suelo (Baker et al., 2021). La selección del listado de GMMs para el PSHA, así como la definición de sus respectivos pesos en el árbol lógico sigue siendo un tema ampliamente debatido e investigado.

3.3. Modelos para fuentes corticales

3.3.1. Modelo de Arteta et al (2023)

Este modelo es una regionalización del modelo ASK14 (N. A. Abrahamson et al., 2014) para el norte de Sudamérica e incorpora un término para los efectos de sitio basado en el período natural T_n y la amplitud de los espectros HVRSR. Más detalles sobre la caracterización del suelo en las estaciones de la red de Colombia se pueden encontrar en Mercado et al. (2023). Este modelo predice la aceleración espectral Sa RotD50 amortiguada al 5 % para períodos espectrales desde 0.01 a 10 segundos en unidades de gravedad g . La forma funcional del modelo es:

$$\ln(Sa) = \theta_1 + f_{\text{magGL}} + \theta_3(8,5 - M_W)^2 + [\theta_4 + 0,275(M_W - M_1)] \ln(\sqrt{R_{\text{rup}}^2 + 4,5^2}) + \theta_5 R_{\text{rup}} + \theta_6 R_{\text{volc}} + \theta_7 Z_h + f_{\text{soil}} \quad (5)$$

$$f_{\text{magGL}} = \begin{cases} \theta_2(M_W - M_1) & \text{si } M \leq M_1 \\ 0 & \text{si } M > M_1 \end{cases} \quad (6)$$

$$f_{\text{soil}} = C_k(T_n) \ln(P^*) \quad (7)$$

donde M_W es la magnitud de momento, R_{rup} es la distancia más cercana a la ruptura, R_{volc} es la porción del rayo de trayectoria que cruza la región volcánica, Z_h es la profundidad hipocentral. f_{soil} es el término de efectos de sitio, donde $C_k(T_n)$ es un coeficiente que depende del periodo natural del depósito de suelo, mientras que P^* es la amplitud máxima de la media del Horizontal to Vertical Response Spectra Ratio (HVRSR) con 5 % de amortiguamiento determinado para cada estación (Mercado et al., 2023). Es importante señalar que los coeficientes $C_k(T_n)$ y P^* fueron obtenidos independientemente del proceso que se usó para obtener los coeficientes de regresión θ . En Mercado et al. (2023) se definieron 5 categorías de suelo, cada una con su valor correspondiente de C_k para cada periodo espectral, donde la categoría S_2 corresponde a una roca con $V_{S30} \geq 600$ m/s y la categoría S_5 es un suelo blando con $V_{S30} \leq 230$ m/s.

Los parámetros globales son θ_2 y θ_4 , los cuales se toman del modelo ASK14. Consecuentemente, θ_1 , θ_3 , θ_5 , θ_6 y θ_7 son los coeficientes de regresión. La magnitud de momento puede tomar valores en el intervalo de 4.5 a 8.0, y R_{rup} en el intervalo de 10 a 350 km (Arteta et al., 2023). Para obtener los coeficientes de regresión θ , se utilizó el modelo de regresión de efectos mixtos (mixed-effects) de N. A. Abrahamson y Youngs (1992), cuya forma general es:

$$\ln(Sa_{ij}) = f(M_i, r_{ij}, \theta) + \eta_i + \varepsilon_{ij} \quad (8)$$

donde Sa es la aceleración espectral para un determinado periodo, M_i es la magnitud del evento i -ésimo, r_{ij} es la distancia a la cual se tomó el j -ésimo registro del i -ésimo evento y θ es el vector de coeficientes de regresión del modelo. El término η_i representa la variación inter-evento y ε_{ij} la variación intra-evento. η_i y ε_{ij} son independientes entre sí y siguen una

distribución normal, con varianzas τ y ϕ respectivamente (Al Atik et al., 2010). La desviación estándar total del GMM σ se calcula como:

$$\sigma = \sqrt{\tau^2 + \phi^2} \quad (9)$$

3.3.2. Modelo de Idriss (2014)

El parámetro de intensidad que predice este modelo es la aceleración espectral RotD50 con 5 % de amortiguamiento en unidades de gravedad g . El rango de periodos espectrales va desde 0.01 hasta 10 segundos. Por sugerencias del autor de este GMM, el modelo debería restringirse a $M_W \geq 5,0$, $R_{rup} \leq 150$ km y $V_{S30} \geq 450$ m/s, debido a que no incluye el comportamiento no lineal característico de los suelos blandos (Idriss, 2014). La forma funcional del modelo es:

$$\ln(Sa) = \alpha_1 + \alpha_2 M_W + \alpha_3 (8,5 - M_W)^2 - [\beta_1 + \beta_2 M_W] \ln(R_{rup} + 10) + \quad (10)$$

$$\xi \ln(V_{S30}) + \gamma R_{rup} + \phi F \quad (11)$$

donde F es una variable que tiene en cuenta el mecanismo focal y es igual a 1 para mecanismo inverso y 0 en cualquier otro caso. Para aquellas estaciones de la red sismológica nacional de las cuales no se cuenta con el V_{S30} pero sí con el periodo natural T_n , se usó la Ecuación (1) de Arteta et al. (2023) para obtener el V_{S30} aproximado:

$$\log_{10}(V_{S30}) = \begin{cases} 2,2 + 0,63 \log_{10}(1/T_n) & \text{si } T_n < 1,09 \text{ s} \\ \log_{10}(150) & \text{si } T_n \geq 1,09 \text{ s} \end{cases} \quad (12)$$

El autor no menciona cuál fue el método que usó para el análisis de regresión del modelo. La desviación estándar total del modelo, expresada por el autor como Standard Error SE se calcula con:

$$SE = 1,18 + 0,035 \ln(T) - 0,06 M_W \quad (13)$$

donde T es el periodo espectral. Para valores de $M_W < 5$ se asumen los mismos valores de SE que se obtienen para $M_W = 5$. Para $M_W > 7,5$ se asumen los de $M_W = 7,5$. De forma análoga, para $T < 0,05$ se asumen los correspondientes a $T = 0,05$ segundos, y para $T > 3$ segundos los de $T = 3$ segundos.

3.3.3. Modelo de Cauzzi et al (2014)

El parámetro de intensidad que predice es el desplazamiento espectral (DRS) con 5 % de amortiguamiento en cm. La forma funcional es:

$$\log_{10}(DRS) = f_M + f_R + f_S + f_{SOF} \quad (14)$$

donde:

$$f_M = c_1 + m_1 M_W + m_2 M_W^2 \quad (15)$$

$$f_R = (r_1 + r_2 M_W) \log_{10}(R_{rup} + r_3) \quad (16)$$

$$f_S = b_V \log_{10}(V_{S30}/V_A) \quad (17)$$

$$f_{SOF} = f_N F_N + f_R F_R + f_{SS} F_{SS} \quad (18)$$

Cauzzi et al. (2015) señala que se puede obtener la aceleración espectral con 5% de amortiguamiento (media geométrica de las componentes horizontales) en unidades de cm/s^2 por medio de:

$$Sa = DRS \times 4\pi^2/T^2 \quad (19)$$

Los coeficientes de regresión del modelo se obtuvieron mediante el método de Joyner y Boore (1993, 1994). La desviación estándar total del modelo σ se obtuvo mediante el análisis de residuales de la ecuación 9.

3.4. Modelos para fuentes de subducción

3.4.1. Modelo de Arteta et al (2021)

Arteta et al. (2021) desarrollaron un GMM para fuentes sísmicas de subducción en el norte de Sudamérica, que contempla tanto la subducción interplaca como la intraplaca. El modelo es una regionalización del modelo global AG2020 de N. Abrahamson y Gülerce (2020) y tiene validez para Colombia y Ecuador. De acuerdo con Arteta et al. (2021), la atenuación del movimiento del suelo para eventos de subducción en el norte de Sudamérica es mayor que en otras regiones. Por esta razón, los GMMs globales, como el AG2020, tienden a sobre estimar las intensidades del movimiento del suelo. El parámetro de predicción es la aceleración espectral RotD50 para periodos espectrales $T \leq 10$ s en unidades de gravedad g . La forma funcional es:

$$\ln(Sa) = \theta_1 + f_{\text{magGL}}(M) + f_{\text{magREG}}(M) + f_{\text{pathGL}}(M, R) + f_{\text{pathREG}} + \quad (20)$$

$$f_{\text{soil}} + \theta_6 F_{\text{FABA}} \quad (21)$$

donde M_W es la magnitud de momento, R es la distancia más cercana a la ruptura R_{rup} para eventos interplaca, o la distancia hipocentral R_{hypo} para eventos intraplaca. El rango de aplicación de M_W va desde 4,5 hasta 9,5 para interplaca, y desde 4,5 hasta 8,0 para intraplaca. El rango de R_{rup} está entre 10 y 450 km para interplaca y el de R_{hypo} entre 70 y 450 km para intraplaca.

$$f_{\text{magGL}}(M) = \begin{cases} \theta_2(M - C_1) & \text{si } M \leq C_1 \\ 0, & \text{en otro caso} \end{cases} \quad (22)$$

C_1 es igual a 6.5 para eventos intraplaca, mientras que para interplaca depende del periodo espectral.

$$f_{\text{magREG}}(M) = \theta_3(10 - M)^2 \quad (23)$$

$$f_{\text{pathGL}}(M, R) = [\theta_4 + 0,1(M - 7)] \ln(R + 10e^{0,4(M-6)}) \quad (24)$$

$$f_{\text{pathREG}} = \theta_5 R \quad (25)$$

Los términos f_{magGL} y f_{pathGL} se toman del modelo AG2020, mientras que f_{magREG} y f_{pathREG} se obtienen mediante el análisis de regresión con datos locales. F_{FABA} es igual a 1 para sitios detrás del arco volcánico (Backarc sites) en eventos intraplaca, y es igual a cero en cualquier otro escenario. El efecto de sitio f_{soil} se calcula con la ecuación que proviene del modelo de Mercado et al. (2023) (ecuación 7). En este caso, los coeficientes C_k dependen del tipo de fuente sísmica (interplaca o intraplaca), del periodo espectral y de la categoría de suelo.

El análisis de regresión para obtener los coeficientes θ se realizó mediante el método de N. A. Abrahamson y Youngs (1992) y la desviación estándar total del GMM σ se obtuvo mediante el análisis de residuales de la ecuación 9. De acuerdo con Arteta et al. (2021), los datos de sismicidad del norte de Sudamérica reflejan una gran variabilidad en la propagación de las ondas sísmicas y en la amplificación de sitio, por lo que los valores de ϕ tienden a ser mayores. Para tener esto en cuenta, Arteta et al. (2021) describen el parámetro ϕ como se hizo en N. Abrahamson y Gülerce (2020) como función de la distancia:

$$\phi = \begin{cases} \phi_1 & \text{si } R \leq 150 \\ \phi_1 + \frac{\phi_2 - \phi_1}{50}(R - 150) & \text{si } 150 < R \leq 200 \\ \phi_2 & \text{si } R > 200 \end{cases} \quad (26)$$

Los valores de ϕ_1 y ϕ_2 generan valores de σ_1 y σ_2 respectivamente (ecuación 9) y sus valores están consignados en las tablas 4 y 5 de Arteta et al. (2021).

3.4.2. Modelo de Montalva et al (2017)

Este modelo es una regionalización del modelo de N. Abrahamson et al. (2016) usando datos de Chile, por lo que las formas funcionales de Montalva et al. (2017) y N. Abrahamson et al. (2016) son muy similares. Por brevedad, solo se ilustrará la forma funcional de Montalva et al. (2017):

$$\ln(Sa) = \theta_1 + f_{\text{source}} + f_{\text{path}} + f_{\text{event/depth}} + f_{\text{site}} + f_{\text{FABA}} \quad (27)$$

donde Sa es la aceleración espectral con 5 % de amortiguamiento (media geométrica de las componentes horizontales) en unidades de gravedad g , y:

$$f_{\text{source}} = \theta_4 \Delta C_1 + f_{\text{mag}}(M_W) \quad (28)$$

$$f_{\text{mag}}(M_W) = \begin{cases} \theta_4(M_W - (C_1 + \Delta C_1)), & \text{if } M \leq (C_1 + \Delta C_1) \\ \theta_5(M_W - (C_1 + \Delta C_1)), & \text{if } M > (C_1 + \Delta C_1) \end{cases} \quad (29)$$

$$[\theta_2 + \theta_1 4F_{\text{event}} + \theta_3(M_W - 7,8)] \times \ln(R + C_4 \exp(\theta_9(M_W - 6))) + \theta_6 R \quad (30)$$

$$f_{\text{event/depth}} = [\theta_{10} + \theta_{11}(\min(Z_h, 120) - 60)]F_{\text{event}} \quad (31)$$

donde Z_h es la profundidad hipocentral en km y F_{event} es 1 para eventos intraplaca y 0 para interplaca.

$$f_{\text{site}} = \begin{cases} \theta_{12} \ln(V_S^*/V_{\text{lin}}) - b \ln(PGA_{1000} + c) \\ + b \ln(PGA_{1000} + c(V_S^*/V_{\text{lin}})^n), & \text{if } V_{S30} < V_{\text{lin}} \\ \theta_{12} \ln(V_S^*/V_{\text{lin}}) + b \ln(V_S^*/V_{\text{lin}}), & \text{if } V_{S30} \geq V_{\text{lin}} \end{cases} \quad (32)$$

donde $V_S^* = \min(V_{S30}, 1000)$ y PGA_{1000} es la PGA calculada para un sitio con $V_{S30} = 1000 \text{ m/s}$.

$$f_{\text{FABA}} = \begin{cases} (\theta_7 + \theta_8 \ln(\max(R, 85)/40)) \times F_{\text{FABA}}, & \text{if } F_{\text{event}} = 1 \\ (\theta_{15} + \theta_{16} \ln(\max(R, 100)/40)) \times F_{\text{FABA}}, & \text{if } F_{\text{event}} = 0 \end{cases} \quad (33)$$

La métrica de distancia R es la distancia más cercana a la ruptura R_{rup} para eventos interplaca, mientras que para eventos intraplaca es la distancia hipocentral R_{hypo} . F_{FABA} es igual a 1 para Backarc y 0 para Forearc o sitios sin información al respecto. La desviación estándar total del modelo se obtuvo mediante:

$$\sigma = \sqrt{\tau^2 + \phi_{S2S}^2 + \phi_{SS}^2} \quad (34)$$

donde se realizó una partición del residual intra-evento ϕ en el residual promedio por eventos de sitio a sitio (site-to-site) ϕ_{S2S} y el residual por estación (single-station) ϕ_{SS} .

3.4.3. Modelo de Zhao et al (2006)

Este modelo se desarrolló a partir de datos de EEUU, Japón y algunos eventos sísmicos de Irán. Su forma funcional es:

$$\ln(y) = aM_W + bx - \ln(r) + e(h - h_c)\delta_h + S_I + S_S + S_{SL} \ln(x) + C_k + \xi_{i,j} + \eta_i, \quad (35)$$

$$r = x + c \exp(dM_W) \quad (36)$$

donde y es la aceleración espectral con 5% de amortiguamiento (media geométrica de las componentes horizontales) en cm/s^2 , x es la distancia de ruptura en km y h es la profundidad hipocentral en km. S_I se usa solo para eventos interplaca, mientras que S_S y S_{SL} se usan solo para eventos intraplaca. h_c es un límite para la profundidad hipocentral igual a 125 km y δ_h

es igual a 1 si $h \geq h_c$ e igual a 0 en otro caso. El máximo valor permitido para h es 125 km. La categoría del suelo viene dada por C_k de acuerdo con el modelo de Molas y Yamazaki (1995) con 4 diferentes categorías: roca, suelo duro, suelo medio y suelo blando. a , b , c , d y e son coeficientes de regresión y $\xi_{i,j}$ es el error intra-evento para el registro j del evento i , y η_i es el error inter-evento. En este estudio se adoptó el modelo ZhaoEtAl2006SInterNSHMP2008 (nomenclatura de OpenQuake Engine) para eventos interplaca que se desarrolló para el modelo de amenaza de EEUU de 2008 (Petersen et al., 2008); en consecuencia, la profundidad hipocentral quedó fijada en 20 km. Adicionalmente, para eventos intraplaca se adoptó el modelo ZhaoEtAl2006SSlabNSHMP2014 tomado del proyecto de mapeo de la amenaza en EEUU de 2014 (Petersen et al., 2014), donde la magnitud de momento tiene un límite superior en 7.8. Los parámetros de entrada de los modelos mencionados para fuentes de subducción se muestran en la tabla 2.

Tabla 2: Resumen de parámetros de entrada de los GMMs para fuentes de subducción.

Modelo	Magnitud [M_W]	Distancia [km]	V_{S30} [m/s]
AbrahamsonEtAl2016SInter	6.0 a 8.5	$10 \leq R_{rup} \leq 300$	150 a 1100
AbrahamsonEtAl2016SSlab	5.0 a 8.0	$40 \leq R_{hypo} \leq 300$	150 a 1100
ArtetaEtAl2021Inter	4.5 a 8.5	$10 \leq R_{rup} \leq 450$	100 a 1200
ArtetaEtAl2021Slab	4.5 a 8.0	$70 \leq R_{hypo} \leq 450$	100 a 1200
MontalvaEtAl2017SInter	4.5 a 8.8	$20 \leq R_{rup} \leq 300$	108 a 1951
MontalvaEtAl2017SSlab	4.5 a 7.8	$40 \leq R_{hypo} \leq 300$	108 a 1951
ZhaoEtAl2006SInterNSHMP2008	5.0 a 8.5	$20 \leq R_{rup} \leq 300$	230 a 760
ZhaoEtAl2006SSlabNSHMP2014	5.0 a 8.5	$40 \leq R_{rup} \leq 300$	230 a 760

3.5. Bayesian Model Updating

El teorema de Bayes permite actualizar los parámetros θ de un modelo cuando se cuenta con nuevas observaciones y (Martin et al., 2021):

$$P(\theta|y) = \frac{P(\theta)P(y|\theta)}{P(y)} \quad (37)$$

donde $P(\theta)$ son las distribuciones Prior de las variables del modelo, y representan el conocimiento que se tiene de estas variables antes de que aparecieran las observaciones y . $P(y|\theta)$ es la Likelihood y es una medida de la probabilidad de las observaciones y dado un modelo θ . $P(\theta|y)$ son las distribuciones posteriores (Posterior distributions) de todas las variables del modelo θ después de la aparición de las observaciones en y y reflejan cómo el modelo se ve transformado por la nueva evidencia. Finalmente, $P(y)$ Se conoce como el Likelihood marginal, y cuantifica la probabilidad de los datos observados tomando en consideración todos los valores de las variables definidas por las distribuciones Prior (Martin et al., 2021).

Las metodologías Bayesianas se han utilizado en la ingeniería sísmica para diferentes propósitos. Entre los usos más comunes se encuentran el pronóstico de terremotos (Bayliss

et al., 2022; Marzocchi et al., 2012), evaluar la respuesta y las propiedades sísmicas del suelo (Ching y Glaser, 2003; Hu y Liu, 2019) y estimar los parámetros de recurrencia de terremotos (Keller et al., 2014). En la literatura se les conoce como Bayesian Inference ó Bayesian Updating. En este estudio se le llamará Bayesian Model Updating BMU para clarificar que se están actualizando (o regionalizando) modelos, en lugar de desarrollar modelos nuevos.

Como se mencionó en la sección anterior, usualmente los GMMs son desarrollados a partir de los métodos de N. A. Abrahamson y Youngs (1992) (mixed-effects regression model) o de Joyner y Boore (1993, 1994) (maximum-likelihood two-stage regression method). Ambos producen GMMs donde los coeficientes de regresión son valores constantes. En contraste, con el BMU se obtienen distribuciones de probabilidad para los coeficientes, permitiendo una mejor evaluación de la incertidumbre del modelo. De acuerdo con Baker et al. (2021), existen dos fuentes principales de incertidumbre en las predicciones del movimiento del terreno. Una es la variabilidad aleatoria, la cual es inherente al fenómeno estudiado y no puede ser reducida. La otra es la incertidumbre epistémica, la cual está asociada con la forma como se construye el conocimiento científico sobre el fenómeno estudiado. Ésta última es susceptible de ser reducida en la medida que se mejora la comprensión del fenómeno en cuestión, se obtienen más datos y se elaboran mejores modelos. De acuerdo con Baker et al. (2021), en los GMMs existen tres fuentes principales de incertidumbre epistémica: los datos que se escogen para desarrollar los modelos, la forma funcional del modelo y la incertidumbre de los parámetros en el análisis de regresión.

Diversos autores han utilizado métodos Bayesianos para desarrollar GMMs. De acuerdo con Arroyo y Ordaz (2010) el enfoque Bayesiano tiene la ventaja de proporcionar distribuciones de probabilidad de los coeficientes del GMM, lo que permite saber cuáles parámetros no quedan suficientemente bien definidos con los datos disponibles. Esto es muy importante en el contexto colombiano debido a la falta de registros de sismos de grandes magnitudes a cortas distancias.

Un ejemplo de BMU para la regionalización de GMMs es presentado por Shahidzadeh y Yazdani (2017) en el cual modificaron la forma funcional del modelo de Ambraseys et al. (2005) añadiendo parámetros específicos de sitio para diferentes regiones de Irán, con el fin de captar las diferencias entre estas zonas sísmicas. Sus hallazgos mostraron que la cantidad de datos tiene un impacto directo en la incertidumbre del modelo. En particular, los modelos derivados de bases de datos locales con datos escasos presentan una mayor incertidumbre en comparación con los modelos globales desarrollados con grandes bases de datos. El modelo actualizado de Ambraseys et al (2005) se comparó posteriormente con modelos comúnmente utilizados en Irán mediante el método de Probabilidad Mediana (Scherbaum et al., 2004). Los resultados demostraron que el modelo actualizado era más preciso debido a su capacidad para incorporar datos sobre las condiciones del sitio y el mecanismo focal. Concluyeron que los modelos globales tienden a sobre estimar la aceleración espectral debido a diferencias sustanciales en la atenuación y la configuración tectónica.

De forma similar, Kowsari, Halldorsson, Hrafnkelsson, Snæbjörnsson y Jónsson (2019) usó el BMU para regionalizar los modelos de Akkar y Bommer (2010), Cauzzi y Faccioli (2008), Zhao et al. (2006), Ambraseys et al. (2005), Danciu y Tselentis (2007), Gülkan y

Kalkan (2002) y Lin y Lee (2008). Se usó una base de datos de sismicidad en Islandia (Iceland) con magnitudes M_W entre 5 y 6,5 y distancias de ruptura entre 0 y 80 km. Se mostró que los residuales de los modelos regionalizados estaban centrados en cero y tenían menores desviaciones estándar (menores τ y ϕ) y por tanto el modelo regionalizado resultó imparcial con respecto a la medida de intensidad y las métricas de distancia reportadas en el conjunto de datos. También realizaron una comparación de modelos utilizando el método propuesto por Atkinson y Adams (2013). Encontraron que la variabilidad entre modelos de los modelos globales originales era mayor que la variabilidad de los modelos regionalizados. Finalmente, los autores informaron que el escalado de PGA con la magnitud dentro de los modelos regionalizados también fue satisfactorio en sitios de roca.

Stafford (2019) utilizó BMU para probar cómo el modelo ASK14, que ha mantenido una forma funcional similar a lo largo de los años, puede ser actualizado con nuevos datos de eventos sísmicos. Este método incluye únicamente los nuevos datos, lo que reduce significativamente el tiempo de cálculo. Concluyó que el BMU tiene importantes implicaciones para el PSHA no ergódico, ya que permite incorporar estimaciones específicas del sitio y calcular la incertidumbre para cada estación a medida que se dispone de nuevos datos. También afirmó que el BMU mejora la evaluación de la incertidumbre epistémica en el PSHA y que los GMMs con formas funcionales complejas pueden actualizarse con nuevos datos gracias a los avances computacionales de las últimas décadas.

Finalmente, N. M. Kuehn et al. (2020) aplicaron la inferencia Bayesiana para desarrollar GMMs utilizando datos truncados, que ocurren cuando los instrumentos se activan a ciertos niveles. Utilizaron conjuntos de datos de NGA West 2, Irán y Taiwán para crear modelos Bayesianos que incluyen términos de eventos y estaciones. Encontraron que, para niveles de activación alrededor de 4–6 gal, el modelo de regresión truncada y una regresión de mixed-effects tienen un desempeño similar. Sin embargo, para niveles de activación más altos, como los de Irán, se observa un sesgo en las predicciones medianas a grandes distancias y una subestimación de las desviaciones estándar aleatorias. Concluyeron que el enfoque Bayesiano permite tener en cuenta la correlación entre el umbral de truncamiento y el sesgo en los términos de atenuación inelástica.

3.6. Bayesian Model Selection

La selección de GMMs para estudios de amenaza sísmica ha sido un tema de discusión desde que el PSHA comenzó a ser usado ampliamente. En este contexto, el Árbol Lógico ha sido utilizado para tener en cuenta la incertidumbre epistémica asociada a las limitaciones en el estado del conocimiento sobre la predicción del movimiento del terreno (Bommer et al., 2010). A continuación, se presenta una lista de requisitos para que los GMMs sean incluidos en el PSHA, según Bommer et al. (2010) y Arcila et al. (2020), basada en Cotton et al. (2006):

1. Seleccionar modelos de regiones tectónicas que sean relevantes para el sitio de interés.

2. Evitar redundancias eligiendo una lista reducida de GMMs cuyos conjuntos de datos no se superpongan. Por ejemplo, no seleccionar demasiados GMMs desarrollados a partir de los Modelos NGA (N. Abrahamson et al., 2008).
3. Asegurarse de que las medidas de intensidad previstas estén disponibles para los periodos espectrales de interés en diseño sísmico y de ingeniería.
4. Seleccionar GMMs cuya magnitud máxima disponible como entrada sea cercana al valor de M_{max} seleccionado para el PSHA.
5. Homogeneizar las métricas de magnitud y distancia entre la base de datos y los GMMs.
6. Excluir GMMs cuya forma funcional sea demasiado simple (muy pocos coeficientes) o demasiado compleja de implementar (demasiados coeficientes).
7. Asegurarse de que la regresión de los coeficientes de los GMMs se haya realizado mediante el método de máxima verosimilitud en dos etapas de Joyner y Boore (1993, 1994) o el método de efectos aleatorios de N. A. Abrahamson y Youngs (1992).

Siguiendo este argumento, después de la preselección de modelos, el siguiente paso es la comparación de los modelos escogidos. Para esto, se puede utilizar un enfoque Bayesiano, referido en este estudio como Selección Bayesiana de Modelos (Bayesian Model Selection BMS). Algunos estudios han demostrado que los GMMs regionalizados tienen un mejor desempeño que los GMMs globales utilizando el método WAIC (Criterio de Información de Watanabe-Akaike) (N. M. Kuehn y Scherbaum, 2016). Otros estudios también han comparado GMMs utilizando WAIC (Bodda et al., 2022; Kowsari et al., 2020; N. M. Kuehn y Abrahamson, 2018), y trabajos más especializados sobre BMS han comparado diferentes métodos, concluyendo que WAIC es más adecuado que el Deviance Information Criterion DIC (Martin, 2018; Martin et al., 2021; Vehtari et al., 2017). El WAIC se calcula con base en la siguiente expresión (tomada de Vehtari et al. (2017)):

$$ELPD_{WAIC} = LPPD - P_{WAIC} \quad (38)$$

$$LPPD = \sum_{i=1}^n \log \left(\frac{1}{S} \sum_{S=1}^S P(y_i | \theta^S) \right) \quad (39)$$

$$P_{WAIC} = \sum_i^n \left(V_{S=1}^S (\log(P(y_i | \theta^S))) \right) \quad (40)$$

donde $ELPD_{WAIC}$ es la densidad logarítmica predictiva puntual teóricamente esperada (Theoretical Expected Log Point-wise Predictive Density). La $LPPD$ (ecuación 39) se conoce como la densidad logarítmica predictiva puntual (Log Point-wise Predictive Density) y hace referencia a la capacidad del modelo para realizar predicciones por fuera de la muestra utilizada para desarrollar el BMU. Es importante destacar que el término $P(y_i | \theta^S)$ en la Ecuación 39

corresponde a la Likelihood en la Ecuación 37, calculada a partir de las S muestras de la distribución Posterior. La Ecuación 40 calcula el término de penalización P_{WAIC} , asociado al número efectivo estimado de parámetros. Este término penaliza el $LPPD$, ya que un modelo con muchos coeficientes de regresión podría tener, en algunos casos, ciertas ventajas sobre otros modelos con menos coeficientes (Martin et al., 2021). El término $V_{S=1}^S$ en la Ecuación 40 representa la varianza de las S muestras de la posterior provenientes de la densidad logarítmica predictiva $\log(P(y_i|\theta^S))$. Esta varianza se calcula para cada dato y_i y luego se suma para todos los puntos de datos, proporcionando una estimación simulada del número efectivo de parámetros (Vehtari et al., 2017).

De acuerdo con Gelman et al. (2014, 2021) la ventaja de utilizar WAIC dentro del enfoque Bayesiano radica en que WAIC calcula la capacidad de un modelo para realizar predicciones fuera del conjunto de datos utilizado para desarrollar el modelo: “En comparación con Akaike Information Criterion AIC y DIC, WAIC tiene la propiedad deseable de promediar sobre la distribución posterior en lugar de condicionarse a una estimación puntual. Esto es particularmente relevante en un contexto predictivo, ya que WAIC evalúa las predicciones que realmente se utilizan para nuevos datos en un enfoque Bayesiano.” (Gelman et al., 2014, 2021). Lo anterior resulta conveniente cuando hay pocos datos para BMU y no es posible dividirlos en conjuntos de entrenamiento y validación. Por estas razones, en este estudio se eligió el método WAIC para desarrollar el algoritmo de BMS.

En el ámbito particular de los GMMs, N. M. Kuehn y Scherbaum (2016) mostraron que al comparar un modelo jerárquico regionalizado (hierarchical regionalized model) con un modelo global por medio de WAIC, obtiene mejores resultados, lo cual indica que el modelo regionalizado tiene una mejor capacidad para realizar predicciones por fuera de los datos disponibles. N. M. Kuehn y Scherbaum (2016) consideran que el análisis de residuales y las desviaciones estándar estimadas por sí solos no son suficientes para comparar el desempeño de los GMMs.

Adicionalmente, en Bodda et al. (2022) utilizaron BMU para actualizar los coeficientes de regresión del modelo de Bindi et al. (2014) para la región de Europa Occidental usando un subconjunto de la base de datos European Strong-Motion (ESM) la cual contiene registros de eventos de magnitudes bajas y moderadas. Se probó un conjunto de diferentes variaciones de la forma funcional del modelo, tras lo cual se utilizó el método WAIC para compararlas. Los modelos actualizados obtuvieron puntuaciones similares con el método WAIC y se probaron con una base de datos de validación distinta a la base de datos de entrenamiento utilizada para BMU. Según el criterio de error cuadrático medio (RMSE), los modelos actualizados obtuvieron mejores resultados que el modelo original. En la siguiente sección se ilustra en detalle la metodología de implementación de BMU y BMS con WAIC.

4. Metodología

4.1. Base da datos de movimiento fuerte

El SGC y la Fundación Global Earthquake Model GEM construyeron una base de datos de registros triaxiales (dos componentes horizontales y una vertical) para el Modelo Nacional de Amenaza Sísmica para Colombia (Arcila et al., 2020). La base de datos fue actualizada para incluir eventos hasta 2020 para desarrollar los GMMs de subducción (Arteta et al., 2021, 2023) y de fuentes corticales (Arteta et al., 2023) de los cuales se adoptó el mismo criterio de selección de los datos:

- Solo se admiten valores de $PGA \geq 1 \times 10^{-4} g$ para eventos de subducción interplaca o intraplaca y $PGA \geq 1 \times 10^{-5} g$ para los eventos corticales.
- Distancias hipocentrales $R_{\text{hypo}} \leq 350$ km para eventos de subducción y distancias de ruptura $R_{\text{rup}} \leq 350$ km para eventos corticales.
- Para cada registro, la frecuencia mínima utilizable se estableció siguiendo el criterio de B. Chiou et al. (2008) como 1.25 veces el límite inferior de la frecuencia de filtrado de pasa-alta (high-pass frequency).

Las bases de datos resultantes al aplicar los anteriores criterios se resumen en la tabla 3. En las figuras 1a y 1b se muestran las bases de datos de subducción interplaca e intraplaca respectivamente. Como se observa en la tabla 3, la base de datos de eventos corticales contiene un número de registros que permite dividir la base de datos en conjuntos de entrenamiento (74 eventos, 680 registros) y validación (7 eventos, 164 registros). El conjunto para validación no se seleccionó aleatoriamente, porque el conjunto base tiene más registros de eventos de magnitud moderada a distancias largas, por tanto habría una mayor probabilidad de obtener este tipo de registros en una muestra aleatoria. En su lugar, se seleccionaron de tal forma que se cubriera el rango más amplio de magnitudes y distancias. Las bases de datos de entrenamiento y validación se muestran en las figuras 2a y 2b. Los valores de V_{S30} de las estaciones que son necesarios como inputs en algunos de los GMMs descritos en la sección anterior se obtuvieron de una base de datos interna del SGC donde se registran la metodología de exploración (Bender Element, SPAC, Downhole). Aquellas estaciones donde no se contó con estudios para estimar el V_{S30} , se infirió a partir del valor disponible de T_n usando la Tabla 1 en Mercado et al. (2023).


4.2. Implementación computacional del BMU

4.2.1. Distribuciones Prior


Como se observa en la ecuación 37, las distribuciones Priors tienen una influencia en las Posterior. De acuerdo con Wang y Takada (2009), cuando se tienen suficientes datos la función Likelihood domina las distribuciones Posterior y el uso de Prior informadas tiene los mismos

Tabla 3: Resumen de la base de datos de movimiento fuerte utilizada en este estudio.

Variable	Sub. Interplaca	Sub. Intraplaca	Corticales
Eventos/Registros	33/232	32/476	81/844
Magnitud [M_W]	4,4 a 7,8	4,1 a 7,2	4,5 a 6,75
Distancia [km]	$18 \leq R_{rup} \leq 344$	$63 \leq R_{hypo} \leq 350$	$12,5 \leq R_{rup} \leq 349$
Profundidad [km]	0 a 34	45 a 206	1 a 59
Estaciones	75	63	96
Registros por categoría de suelo	S_1 : 19, S_2 : 23, S_3 : 83, S_4 : 69, S_5 : 38	S_1 : 97, S_2 : 100, S_3 : 138, S_4 : 93, S_5 : 48	S_1 : 0, S_2 : 209, S_3 : 348, S_4 : 186, S_5 : 101
Registros por mecanismo focal	Reverse: 153, Normal: 58, Strike-slip: 21	Reverse: 64, Normal: 211, Strike-slip: 201	Reverse: 173, Normal: 50, Strike-slip: 621



(a) Subducción interplaca.



(b) Subducción intraplaca.

Figura 1: Bases de datos de eventos de subducción en el Pacífico Colombiano y Ecuador para BMU y BMS.

resultados que usar Priors no informadas. Mientras que cuando no se tienen suficientes datos, las distribuciones Prior son más influyentes y las Prior informadas con base en conocimiento de la sismología y geología de la región pueden compensar la falta de datos.

Arroyo y Ordaz (2010) trabajaron con datos sintéticos y reales, y mostraron que el uso de Priors informadas produce GMMs más estables que los algoritmos de regresión tradicionales, como el Least Squares de Kao et al. (2010) o el Maximum Likelihood de Joyner y Boore (1993, 1994).

Bodda et al. (2022) comparó diferentes modelos con Priors informadas y no informadas mediante DIC y WAIC. La varianza en las Priors informadas se definió con base en la desviación estándar total del modelo. Los modelos con Priors informadas tuvieron mejores puntuaciones.




Figura 2: Bases de datos de eventos corticales para BMU y BMS.

Adicionalmente, Kowsari et al. (2020) mostró cómo el uso de Priors no informadas genera correlaciones entre los coeficientes de regresión del modelo, lo cual indica que los datos no son suficientes para restringir apropiadamente los coeficientes del modelo. Kowsari et al. (2020) argumentan que un GMM con correlaciones en sus coeficientes aparentemente representa bien los datos usados en la regresión, pero no resulta confiable para hacer predicciones por fuera de estos datos. Kowsari et al. (2020) mostraron que los parámetros del GMM que estaban correlacionados eran el intercepto (por ejemplo, θ_1 en el GMM de Arteta et al. (2023), ecuación 5), el término de escalado de magnitud (por ejemplo, θ_2 en ecuación 5) y el término de escalado de distancia (θ_5 en ecuación 5). En consecuencia, Kowsari et al. (2020) concluyen que se debe procurar que el modelo resultante no tenga correlaciones en sus coeficientes, para lo cual se deben usar Priors informadas.

Teniendo en cuenta lo anterior, en este estudio se definieron dos tipos de Priors; informadas y no informadas. Las informadas se definieron mediante distribuciones normales cuya media es el valor del coeficiente reportado en la literatura y con una desviación estándar igual al 10 % del valor absoluto de la media. Las no informadas se definieron también como distribuciones normales, pero con una desviación estándar igual al 100 % del valor absoluto de la media (del valor reportado en la literatura).

$$\text{Prior informada: } P(\theta_i) \sim N(\theta_{i(GMM)}; 0, 10|\theta_{i(GMM)}|) \quad (41)$$

$$\text{Prior no informada: } P(\theta_i) \sim N(\theta_{i(GMM)}; |\theta_{i(GMM)}|) \quad (42)$$

donde $\theta_{i(GMM)}$ es el valor reportado en la literatura para el coeficiente en cuestión. Para los GMMs de fuentes corticales se definieron Priors no informadas para los coeficientes que no son susceptibles de presentar correlaciones y que podían ser bien definidos por los datos. Las

Priors no informadas tienen una desviación estándar del 100 % del valor absoluto del valor reportado en la literatura. En la tabla 4 se especifica cada uno de ellos.

Para los modelos de fuentes de subducción se usaron Priors informadas en todos los casos. Esto debido a que las formas funcionales de los modelos de N. Abrahamson et al. (2016) y Montalva et al. (2017) son extensas y se presentaban problemas de estabilidad y convergencia cuando se usaban Priors no informadas. De este modo, el uso de Priors informadas solucionó estos inconvenientes y se establecieron para todos los GMMs de subducción de manera que se pudieran comparar luego en el BMS bajo un marco común. Las únicas excepciones fueron los coeficientes C_1 y ΔC_1 en N. Abrahamson et al. (2016) y Montalva et al. (2017), donde la desviación estándar de sus Priors se definieron como el valor central de ΔC_1 que se muestra en la tabla (4) de N. Abrahamson et al. (2016). Es importante resaltar que el efecto de no incluir Priors informadas en algunos coeficientes puede resultar en modelos cuyas predicciones son contrarias al fenómeno estudiado. Por ejemplo, el permitir una desviación estándar del 100 % del valor reportado en la literatura para el coeficiente γ en el modelo de Idriss (2014) hace que la Posterior del coeficiente presente valores positivos, generando un efecto indeseado de amplificación de la aceleración con la distancia, contrario al esperado efecto de atenuación, pues en este modelo se tiene la expresión γR_{rup} .

4.2.2. Likelihood

Se definió la Likelihood como una distribución normal:

$$P(y|\theta) \sim N(\mu, \sigma_{\text{Total}}) \quad (43)$$

$$\mu = \ln(Sa) = f(rup, site, \theta) \quad (44)$$

donde la media μ corresponde con el valor de $\ln(Sa)$ que predice el GMM en función de las propiedades de la ruptura, del sitio y de los coeficientes θ . Es decir, la media es el valor que predice la forma funcional del GMM. La desviación estándar de la Likelihood σ_{Total} es la desviación estándar total del GMM.

La implementación computacional se realizó mediante la librería PyMC de Python (Abril-Pla et al., 2023). Las variables de la base de datos de movimiento fuerte, como magnitud, distancia y aceleración RotD50, se ingresan por medio de "data containers". La figura 3 muestra el modelo del BMU en PyMC. Los rectángulos grises representan los datos que alimentan el modelo de ArtetaEtAl2023 y los globos blancos corresponden a las distribuciones Prior de cada coeficiente. El término y_{post} es la Likelihood y y_{obs} son los valores observados del valor de $\ln(Sa)$.

Para el proceso de muestreo se usó el Sequential Monte Carlo based sampling SMC, con 10 000 muestras y 4 Monte Carlo Markov Chains MCMC (PyMC, 2020). Los modelos fueron corridos para periodos espectrales de 0.01, 0.075, 0.1, 0.15, 0.2, 0.5, 1, 3, y 5 segundos. Para los modelos de Subducción se usó el sampler NUTS con 10 000 muestras y 5000 muestras de ajuste (Tune samples) las cuales se descartan después de lograr la convergencia del modelo. (Hoffman y Gelman, 2011).




Figura 3: Diagrama del BMU en PyMC integrando datos, Priors y Likelihood.

4.3. Implementación computacional del BMS

Una vez que todos los GMMs han pasado por el proceso de BMU para un cierto periodo espectral, se calcula la Log-Likelihood elemento por elemento de las muestras de las distribuciones Posterior mediante la librería PyMC con el comando `pm.compute_log_likelihood`. Luego se comparan los modelos con base en el *ELPD* por medio del comando `az.compare` de la librería Arviz (Kumar et al., 2019). El parámetro `ic=waic` dentro de `az.compare` permite definir el método para el BMS. A continuación, se muestra un pseudo-código del proceso de BMU y BMS:

Código 1: Pseudo código de BMU con PyMC y BMS con Arviz.

Entradas:

Dataframe con la base de datos de movimiento fuerte, contiene las variables de predicción para cada registro (magnitud, distancia, VS30 y las aceleraciones espectrales observadas en cada estación).

Modelo de BMU en PyMC:

- Data containers para las variables mencionadas
- Definir los Priors
- Definir la forma funcional de los GMMs
- Definir la Likelihood
- Configurar el muestreo (NUTS o SMC)

Salidas:

- Distribuciones Posterior para cada coeficiente y la desviación estándar total.

-
- Valores Maximum a Posteriori de las distribuciones de los coeficientes, chequeo de convergencia, e intervalos HDI (High Density Intervals) para el 95%.

BMS

Entradas:

- Distribuciones Posterior **del** BMU

- Se calcula el Log_Likelihood de las distribuciones Posterior

Salidas:

- Ranking **del** ELPD_WAIC con Arviz
- Se grafican los resultados con Arviz

5. Resultados

5.1. BMU para GMMs corticales

La tabla 4 resume los resultados de BMU para los GMMs de fuentes corticales. Cada GMM en cada periodo espectral tardó aproximadamente 3 minutos en obtener las distribuciones Posterior. Se usó una máquina 11th Gen Intel(R) Core(TM) i5-11400H @ 2.70GHz con 32 GB de RAM. Como era de esperarse, las distribuciones de probabilidad obtenidas para cada coeficiente son normales, pues tanto las distribuciones Prior como la Likelihood se definieron como normales. En la columna "Tipo de Prior" se especifica si fueron informadas (Inf.) o no informadas (No inf.). El valor de máxima probabilidad o Maximum a Posteriori MAP corresponde con la media de la distribución, por ser distribuciones normales. La columna 95 % HDI muestra el High Density Interval, es decir, el valor del coeficiente estará dentro de ese intervalo con una probabilidad del 95 %.

La columna $\hat{R}$ corresponde al Potential Scale Reduction Factor (Martin et al., 2021; Vehtari et al., 2021), el cual se usa para validar el proceso de muestreo con MCMC, lo cual se conoce como análisis de convergencia. El concepto central es que las diferentes cadenas deben converger a la misma distribución Posterior. La figura 4 muestra el gráfico de las trazas de muestreo del modelo ArtetaEtAl2023 para fuentes corticales en un periodo espectral de 0.01 segundos que equivale a la PGA. De acuerdo con Martin et al. (2021) las muestras deben parecer ruido blanco para mostrar que el muestreo no se quedó estancado en algún espacio paramétrico en particular. $\hat{R}$ se calcula con:

$$\hat{R} = \sqrt{\frac{\hat{V}}{W}} \quad (45)$$

donde W representa la varianza dentro de cada cadena de Markov, mientras que $\hat{V}$ denota la varianza estimada de todas las trazas combinadas de las Posterior para cada coeficiente. $\hat{R}$ es cercana a 1,00 cuando todas las trazas representan adecuadamente las muestras de la distribución Posterior. Valores por encima de 1,01 sugieren que una o más cadenas no han alcanzado la convergencia.

Tabla 4: Resultados de BMU para GMMs de fuentes corticales con periodo espectral de 0,01 segundos equivalente a PGA.

Modelo	Coefficiente	Tipo de Prior	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
ArtetaEtAl2023	θ_1	No inf.	-0,090	-0,108	0,087	(0,277; 0,063)	1,00
	θ_2	Inf.	-0,1	-0,096	0,010	(-0,115; 0,076)	1,00
	θ_4	Inf.	-0,790	-0,811	0,034	(-0,877; -0,744)	1,00
	θ_5	No inf.	-0,00352	-0,004	0,001	(-0,006; -0,003)	1,00
	θ_7	No inf.	0,0083	0,0080	0,002	(0,003; 0,013)	1,00
	σ	No inf.	0,88	1,093	0,030	(1,036; 1,153)	1,00
	c_1	No inf.	-2,196	-2,221	0,324	(-2,861; -1,589)	1,00
CauzziEtAl2014	m_1	Inf.	0,523	0,521	0,052	(0,418; 0,623)	1,00
	m_2	No inf.	-0,061	-0,055	0,009	(-0,073; -0,038)	1,00
	r_1	Inf.	-3,801	-3,816	0,176	(-4,161; -3,475)	1,00
	r_2	Inf.	0,355	0,350	0,031	(0,290; 0,413)	1,00
	b_V	No inf.	-0,310	-0,184	0,099	(-0,378; 0,009)	1,00
	σ	No inf.	0,752	1,174	0,032	(1,114; 1,240)	1,00
	α_1	No inf.	7,088	0,333	1,041	(-1,718; 2,368)	1,00
Idriss2014	α_2	Inf.	0,205	0,216	0,021	(0,176; 0,256)	1,00
	α_3	Inf.	0,059	0,054	0,006	(0,042; 0,064)	1,00
	β_1	Inf.	2,994	2,798	0,201	(2,401; 3,185)	1,00
	β_2	Inf.	-0,229	-0,300	0,015	(-0,330; -0,272)	1,00
	ξ	No inf.	-0,854	-0,185	0,102	(-0,387; 0,010)	1,00
	γ	No inf.	-0,0027	-0,005	0,001	(-0,007; -0,002)	1,00
	σ	No inf.	0,614*	1,168	0,032	(1,105; 1,230)	1,00

* Este valor fue calculado tomando $Mw = 6,75$ y $T = 0,01$ en la ecuación 13.




Figura 4: Gráfico hecho con la librería Arviz del proceso de muestreo para el modelo de ArtetaEtAl2023. Las 4 cadenas tienen distribuciones normales (izquierda) y las trazas del muestreo (derecha) deben parecer ruido blanco (white noise).

Las figuras 5, 6 y 7 fueron generadas con Arviz y muestran las distribuciones posteriores de los modelos de ArtetaEtAl2023, CauzziEtAl2014 e Idriss2014 respectivamente. Las distribuciones para cada coeficiente son las que se obtienen al juntar las 4 cadenas de Markov que se muestran en la figura 4. La línea vertical representa el valor del coeficiente que se reportó en la literatura por los autores originales, mientras que la línea horizontal gruesa de color negro representa el 95 % HDI. Este tipo de gráficos es útil para evaluar los valores MAP (media de la distribución) respecto de los reportados en la literatura, así como su rango de variabilidad. Los resultados para los demás periodos espectrales se encuentran en los anexos.




Figura 5: Distribuciones Posterior obtenidas como resultado del BMU para el modelo de ArtetaEtAl2023 con un periodo espectral de 0,01 segundos (PGA). Fuente: autor. Software: librería Arviz de Python.




Figura 6: Distribuciones Posterior de BMU para CauzziEtAl2014 con un periodo espectral de 0,01 segundos.




Figura 7: Distribuciones Posterior de BMU para Idriss2014 con un periodo espectral de 0,01 segundos.

A continuación, en la figura 8 se muestran las desviaciones estándar totales de los modelos regionalizados mediante el BMU. También se registraron los valores reportados en la literatura σ_{GMPE} donde GMPE significa Ground Motion Prediction Equation, un término que es equivalente al de GMM.




Figura 8: Desviaciones estándar totales de GMMs corticales regionalizados con BMU en función del periodo espectral.

Se puede notar que los modelos regionalizados tienen mayores valores de σ que los reportados en la literatura por los diferentes autores. Además, los mayores valores de σ se dan para un periodo espectral de 0,2 segundos. Para periodos mayores a 3 segundos todos los modelos tienden a tener el mismo valor de σ . El modelo de ArtetaEtAl2023 reportó los menores valores de σ en un rango que va desde 0,01 hasta 3,0 segundos.

Las distribuciones Posterior de los coeficientes se pueden utilizar para construir un nuevo modelo y comparar sus predicciones con la base de datos de validación. Esto se conoce como Posterior Predictive Check PPC. A continuación se muestran los PPC para los modelos anteriormente mencionados usando los datos del sismo de Armenia del 25/01/1999 (M_W 6,2). La línea negra (Posterior median) corresponde con la mediana que predice el modelo actualizado. Se obtiene al considerar únicamente los valores MAP de los coeficientes del modelo actualizado. La zona gris es un intervalo de $\pm 2\sigma$, es decir, se tienen en cuenta 2 desviaciones estándar totales del modelo actualizado. La línea azul (GMM median) es la predicción que realiza el modelo original cuya forma funcional es la reportada en la literatura por cada autor, donde cada coeficiente tiene un valor constante.




Figura 9: Posterior Predictive Check del modelo actualizado de ArtetaEtAl2023 con datos del sismo de Armenia 1999. Fuente: autor. Software: Matplotlib-Python.

Como se observa en las figuras figuras 9, 10 y 11, la desviación estándar total de los modelos actualizados es mayor que la de los modelos originales. Como consecuencia, algunos de los datos observados del sismo de Armenia (puntos color naranja) que no logran entrar en




Figura 10: Posterior Predictive Check del modelo actualizado de CauzziEtAl2014 con datos del sismo de Armenia 1999.

el intervalo de $\pm 2\sigma$ de los modelos originales, sí logran entrar en el mismo intervalo con los modelos actualizados (zona gris). Se observó un comportamiento similar con los demás sismos que hacen parte de la base de datos de validación.




Figura 11: Posterior Predictive Check del modelo actualizado de Idriss2014 con datos del sismo de Armenia 1999.

5.2. BMS para GMMs corticales

En la tabla 5 se muestran los resultados del BMS con WAIC para un periodo espectral de 0.01 segundos. La columna Posición hace referencia al modelo que obtuvo el mejor puntaje WAIC entre los demás. Es decir, el modelo ArtetaEtAl2023 tiene el mejor desempeño en comparación con los demás modelos para realizar predicciones por fuera de los datos usados en el BMU. La columna $ELPD_{WAIC}$ muestra el cómputo de la ecuación 38 en escala logarítmica, es decir, el mayor valor está asociado con el mejor resultado. La columna P_{WAIC} muestra el número estimado de parámetros efectivos o penalización del modelo. Este valor siempre es mayor para los modelos de CauzziEtAl2014 e Idriss2014, pues, como se vio en la sección de GMMs corticales, estos modelos tienen una forma funcional más extensa que la del modelo ArtetaEtAl2023, y por tanto, son penalizados. La columna $ELPD_{diff}$ muestra la diferencia entre el $ELPD_{WAIC}$ de la posición 1 y los demás, por eso para el modelo en la

posición 1 siempre es 0. La columna SE muestra el error estándar del proceso de cómputo del $ELPD_{WAIC}$.

Los resultados de la tabla 5 se pueden visualizar en las figuras 12, 13 y 14. Los círculos blancos indican el $ELPD_{WAIC}$, mientras que la línea vertical punteada indica el modelo que obtuvo la Posición 1. Las líneas horizontales negras son el intervalo de $\pm SE$. La línea horizontal gris que contiene un triángulo muestra el $ELPD_{diff}$.

También se observa que las desviaciones estándar totales obtenidas tras el BMU (tabla 4) son menores para el modelo que obtiene la Posición 1 en el BMS (ArtetaEtAl2023). Es decir, el modelo con menor desviación estándar total tiene mejores puntajes en el BMS con WAIC que los modelos con valores relativamente altos de σ .

Las figuras 12 y 13 muestran que el modelo de ArtetaEtAl2023 obtuvo la mejor calificación. En el caso de la figura 14 para un periodo espectral $T = 5$ segundos, las predicciones para $ELPD_{WAIC} \pm SE$ se traslapan. Esto indica que no está claro cuál modelo es el mejor y que el modelo mejor clasificado tiene solo una pequeña ventaja sobre los demás.

Tabla 5: Resultados de BMS con WAIC para GMMs de fuentes corticales.

T [s]	Modelo	Posición	$ELPD_{WAIC}$	P_{WAIC}	$ELPD_{diff}$	SE
0,01	ArtetaEtAl2023	1	-1026,76	3,64	0,00	18,80
	Idriss2014	2	-1072,09	5,03	45,33	19,19
	CauzziEtAl2014	3	-1076,26	4,88	49,50	19,24
0,3	ArtetaEtAl2023	1	-1061,33	4,11	0,00	18,39
	Idriss2014	2	-1113,12	5,10	51,79	18,86
	CauzziEtAl2014	3	-1124,41	4,72	63,08	18,83
5	ArtetaEtAl2023	1	-742,96	5,01	0,00	22,26
	Idriss2014	2	-744,91	6,27	1,95	22,60
	CauzziEtAl2014	3	-749,18	5,73	6,22	22,54




Figura 12: Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 0,01 segundos (PGA). Fuente: autor. Software: Arviz-Python.




Figura 13: Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 0,3 segundos.




Figura 14: Resultados de BMS con GMMs para fuentes corticales con un periodo espectral de 5 segundos.

5.3. BMU para GMMs de subducción interplaca

Según la ecuación 37, el uso de distribuciones normales tanto para las Prior como para el Likelihood da como resultado distribuciones normales para las Posterior de los coeficientes de los GMM. En consecuencia, la media de cada distribución es equivalente al Maximum a Posteriori (MAP), que es el valor con la mayor probabilidad. Las tablas 6, 7, 8 y 9 muestran los resultados para los GMMs de subducción interplaca con un periodo espectral de 0,01 segundos (PGA). Para abreviar, el resto de las tablas de resultados de BMU se proporcionan en los anexos.

Tabla 6: Resultados de BMU para el modelo AbrahamsonEtAl2015SInter con un periodo espectral de 0,01 segundos equivalente a PGA.

Coeficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
b	-1,186	-1,2153	0,1008	(-1,4102; -1,0147)	1,00
C_1	7,8	7,7700	0,1941	(7,3941; 8,1537)	1,00
C_4	10	9,5814	0,9998	(7,5759; 11,5031)	1,00
n	1,18	1,2018	0,1004	(1,0110; 1,4038)	1,00
c	1,88	1,8977	0,1853	(1,5394; 2,2596)	1,00
θ_1	4,22	4,3865	0,3258	(3,7759; 5,0533)	1,00
θ_2	-1,35	-1,4906	0,0676	(-1,6247; -1,3595)	1,00
θ_3	0,1	0,0951	0,0089	(0,0783; 0,1132)	1,00
θ_4	0,9	0,8099	0,0584	(0,6954; 0,9240)	1,00
θ_6	-0,001	-0,0012	0,0001	(-0,0014; -0,0009)	1,00
θ_9	0,4	0,3979	0,0399	(0,3181; 0,4751)	1,00
θ_{12}	0,980	0,9538	0,0907	(0,7810; 1,1369)	1,00
θ_{13}	-0,01	-0,0133	0,0013	(-0,0159; -0,0106)	1,00
θ_{15}	0,999	1,0767	0,0930	(0,8999; 1,2598)	1,00
θ_{16}	-1,0	-0,8400	0,0803	(-0,9940; -0,6803)	1,00
σ	0,74	0,9401	0,0351	(0,8718; 1,0089)	1,00

Tabla 7: Resultados de BMU para el modelo ArtetaEtAl2021Inter con un periodo espectral de 0.01 segundos.

Coeficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
θ_1	4.329	3.8008	0.3259	(3.1709; 4.4463)	1.00
θ_2	0,730	0,6569	0,0452	(0,5691; 0,7456)	1,00
θ_3	-0,021	-0,0204	0,0021	(-0,0243; -0,0163)	1,00
θ_4	-1,450	-1,4330	0,0704	(-1.5698; -1.2956)	1,00
θ_5	-0,006	-0,0046	0,0005	(-0,0056; -0,0036)	1,00
σ	0,934	0,9152	0,0399	(0,8391; 0,9939)	1,00

Tabla 8: Resultados de BMU para el modelo MontalvaEtAl2017SInter con un periodo espectral de 0,01 segundos.

Coficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
b	-1,186	-1,3969	0,1145	(-1,6227; -1,1757)	1,00
C_1	7,2	7,3626	0,1562	(7,0561; 7,6681)	1,00
C_4	10	9,8639	0,9902	(7,9573; 11,8613)	1,00
n	1,18	1,2121	0,0993	(1,0190; 1,4060)	1,00
c	1,88	1,9061	0,1837	(1,5457; 2,2585)	1,00
θ_1	5,875	6,5720	0,4557	(5,6464; 7,4383)	1,00
θ_2	-1,754	-2,0631	0,0905	(-2,2352; -1,8819)	1,00
θ_3	0,131	0,0806	0,0078	(0,0655; 0,0959)	1,00
θ_4	0,803	1,0063	0,0621	(0,8839; 1,1281)	1,00
θ_5	-0,335	-0,0395	0,0039	(-0,0471; -0,0317)	1,00
θ_9	0,4	0,3953	0,0396	(0,3204; 0,4757)	1,00
θ_{12}	1,015	1,2491	0,1177	(1,0169; 1,4756)	1,00
θ_{15}	0,997	1,2037	0,1029	(1,0030; 1,4055)	1,00
θ_{16}	-1,0	-0,9305	0,0889	(-1,1021; -0,7548)	1,00
σ	0,838	0,9799	0,0402	(0,9018; 1,0584)	1,00

Tabla 9: Resultados de BMU para el modelo ZhaoEtAl2006SInterNSHMP2008 con un periodo espectral de 0,01 segundos.

Coficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
a	1,101	1,0020	0,0169	(0,9680; 1,0345)	1,00
b	-0,00564	-0,0066	0,0004	(-0,0074; -0,0058)	1,00
c	0,0055	0,0054	0,0006	(0,0043; 0,0065)	1,00
d	1,080	0,9403	0,0772	(0,7883; 1,0893)	1,00
e	0,0141	0,0137	0,0014	(0,0109; 0,0164)	1,00
σ	0,723	0,9865	0,0354	(0,9184; 1,0572)	1,00




Figura 15: Distribuciones Posterior de los coeficientes del GMM de AbrahamsonEtAl2015SInter para un periodo espectral de 0,01 segundos.




Figura 16: Distribuciones Posterior de los coeficientes del GMM de ArtetaEtAl2021Inter para un periodo espectral de 0,01 segundos.




Figura 17: Distribuciones Posterior de los coeficientes del GMM de MontalvaEtAl2017SInter para un periodo espectral de 0,01 segundos.




Figura 18: Distribuciones Posterior de los coeficientes del GMM de ZhaoE-tA12006SInterNSHMP2008 para un periodo espectral de 0,01 segundos. El coeficiente SI no se incluyó porque el valor reportado en la literatura para $T=0.01$ segundos es 0.

A continuación, se muestran las desviaciones estándar totales de los GMMs para eventos de subducción interplaca (figura 19). Se puede observar que los valores de σ de los modelos regionalizados son mayores a los reportados en la literatura, y que el modelo de ArtetaEtAl2021Inter tiene los menores valores de σ . Los mayores valores de σ se registran en el periodo de 0,075 segundos, excepto para el modelo de ZhaoEtAl2006NSHMP2008.




Figura 19: Desviaciones estándar totales para GMMs de subducción interplaca regionalizados con BMU en función del periodo espectral.

Una vez se han regionalizado los modelos mediante el BMU es necesario comparar las predicciones de los modelos regionalizados con las observaciones de terremotos reales medidos por estaciones. Esto se conoce como Posterior Predictive Check PPC. Para esto, se consideraron dos eventos de subducción interplaca. Ambos ocurrieron cerca de la costa de Ecuador. En orden cronológico, el primer evento tuvo lugar el 27 de marzo de 2022 a las 04:28 UTC con una magnitud de momento de 6,0 y una profundidad hipocentral de 23,8 km. El segundo tuvo lugar el 17 de diciembre de 2022 a las 09:46 UTC con una magnitud de momento de 5,3 y una profundidad hipocentral de 12 km. Se pueden consultar más detalles de estos eventos en <https://ds.iris.edu/spud/momenttensor/20313631>, <https://ds.iris.edu/spud/momenttensor/21089264> y <https://sismo.sgc.gov.co/evento/SGC2022gajpbj>, <https://sismo.sgc.gov.co/evento/SGC2022ytfpjt> respectivamente.




Figura 20: Posterior Predictive Checks del modelo AbrahamsonEtAl2015SInter para los eventos de subducción interplaca en la costa de Ecuador.




Figura 21: Posterior Predictive Checks del modelo ArtetaEtAl2021Inter para los eventos de subducción interplaca en la costa de Ecuador.




Figura 22: Posterior Predictive Checks del modelo MontalvaEtAl2017SInter para los eventos de subducción interplaca en la costa de Ecuador.




Figura 23: Posterior Predictive Checks del modelo ZhaoEtAl2006SInterNSHMP2008 para los eventos de subducción interplaca en la costa de Ecuador.

Las figuras 20, 21, 22 y 23 muestran las PPC, donde el punto gris es la media geométrica de la aceleración máxima del suelo medida de los dos componentes horizontales principales EW y NS en unidades de gravedad. La métrica de distancia es la distancia hipocentral porque estos fueron los datos disponibles en el Servicio Geológico de Colombia y las distancias de ruptura no estaban disponibles. Esto se hizo bajo el supuesto de que para las distancias registradas la diferencia entre la distancia de ruptura y la distancia hipocentral no es significativa. Las predicciones con cada GMM regionalizado se realizaron con los valores MAP (puntos de colores) en un rango de $\pm 2\sigma$, es decir, tomado el 95 % HDI registrado en las tablas anteriores y los colores corresponden a las categorías de suelo definidas por Mercado et al. (2023). Esto se hizo con el único fin de tener un marco de comparación común de las estaciones para las estimaciones con los modelos regionalizados. Cada punto corresponde a una estación y se

tomaron en cuenta propiedades como Backarc , V_{S30} y período natural del depósito de suelo según los datos de entrada requeridos para cada modelo. Se descartaron las estaciones sin datos de estos parámetros.

Se puede observar que para ambos terremotos la gran mayoría de las observaciones caen dentro del rango $\pm 2\sigma$ de las predicciones de los modelos. Adicionalmente, no se observa ninguna incidencia particular de variaciones importantes entre las observaciones y las predicciones de los modelos relacionadas con la distancia o con el tipo de suelo.

5.4. BMS para GMMs de subducción interplaca

Al igual que para los GMMs de fuentes corticales, se llevó a cabo el BMS para los GMMs de fuentes de subducción interplaca. La tabla 10 muestra los resultados para periodos espectrales de 0,01; 0,3 y 5 segundos. Los resultados de los demás periodos se pueden encontrar en el anexo. El modelo de ArtetaEtAl2021Inter obtuvo los mejores puntajes WAIC para los periodos espectrales inferiores a 3 segundos (figuras 24 y 25). Sin embargo, para periodos espectrales mayores a 3 segundos se evidenció que las puntuaciones de todos los modelos evaluados tienden a ser iguales. Esto genera un traslapeo de la línea horizontal negra en la figura 26, la cual representa el puntaje WAIC en un rango de una desviación estándar $\pm SE$. Lo anterior quiere decir que el criterio WAIC no es concluyente sobre cuál es el modelo con el mejor desempeño para periodos mayores a 3 segundos.

Tabla 10: Resultados de BMS con WAIC para GMMs de subducción interplaca.

T [s]	Modelo	Posición	$ELPD_{WAIC}$	P_{WAIC}	$ELPD_{diff}$	SE
0.01	ArtetaEtAl2021Inter	1	-308,65	3,18	0,00	12,55
	MontalvaEtAl2017SInter	2	-332,71	5,40	24,06	12,66
	AbrahamsonEtAl2015SInter	3	-333,97	5,04	25,32	12,21
	ZhaoEtAl2006SInterNSHMP2008	4	-351,54	2,37	42,90	11,86
0.3	ArtetaEtAl2021Inter	1	-296,38	3,03	0,00	13,33
	AbrahamsonEtAl2015SInter	2	-331,22	5,14	34,85	10,65
	MontalvaEtAl2017SInter	3	-332,65	5,32	36,28	12,77
	ZhaoEtAl2006SInterNSHMP2008	4	-360,42	2,57	64,04	13,90
5	MontalvaEtAl2017SInter	1	-229,38	4,27	0,00	10,10
	AbrahamsonEtAl2015SInter	2	-234,31	3,55	4,93	11,45
	ArtetaEtAl2021Inter	3	-238,94	2,94	9,56	10,75
	ZhaoEtAl2006SInterNSHMP2008	4	-266,50	2,32	37,12	11,25




Figura 24: BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 0,01 segundos equivalente a PGA.




Figura 25: BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 0,3 segundos.




Figura 26: BMS con WAIC para GMMs de subducción interplaca con un periodo espectral de 5 segundos.

5.5. BMU para GMMs de subducción intraplaca

En las tablas siguientes se presentan los resultados del BMU para los GMMs de subducción intraplaca considerados en este estudio. En todos los GMMs se logró la convergencia del modelo de acuerdo con los resultados del coeficiente $\hat{R}$ para cada coeficiente de la forma funcional del GMM. Las distribuciones Posterior de los coeficientes fueron todas Gaussianas y

su valor Maximum a Posteriori corresponde con la media (mean) de la distribución tal como se ilustra en las tablas 11, 12, 13 y 14.

Tabla 11: Resultados de BMU para el modelo de AbrahamsonEtAl2015SSlab con un periodo espectral de 0,01 segundos (PGA).

Coefficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
b	-1,186	-1,090	0,102	(-1,297; -0,896)	1,00
C_1	7,8	7,916	0,281	(7,364; 8,463)	1,00
C_4	10	9,972	0,998	(8,024; 11,909)	1,00
n	1,18	1,091	0,103	(0,888; 1,290)	1,00
c	1,88	1,873	0,189	(1,502; 2,242)	1,00
θ_1	4,220	3,964	0,360	(3,247; 4,657)	1,00
θ_2	-1,350	-1,434	0,081	(-1,594; -1,279)	1,00
θ_3	0,1	0,098	0,009	(0,080; 0,115)	1,00
θ_4	0,9	0,899	0,059	(0,786; 1,016)	1,00
θ_6	-0,0012	-0,00118	0,00012	(-0,00141; -0,00094)	1,00
θ_7	1,099	1,133	0,101	(0,933; 1,330)	1,00
θ_8	-1,42	-1,010	0,075	(-1,160; -0,868)	1,00
θ_9	0,4	0,400	0,0399	(0,323; 0,479)	1,00
θ_{10}	3,12	2,980	0,288	(2,402; 3,535)	1,00
θ_{11}	0,0130	0,0112	0,0011	(0,0089; 0,0134)	1,00
θ_{12}	0,980	1,042	0,088	(0,868; 1,214)	1,00
θ_{13}	-0,0135	-0,0135	0,0013	(-0,0160; -0,0109)	1,00
θ_{14}	-0,40	-0,4069	0,0387	(-0,4837; -0,3320)	1,00
σ	0,74	1,0276	0,0288	(0,9728; 1,0855)	1,00

Tabla 12: Resultados de BMU para el modelo de ArtetaEtAl2021Slab con un periodo espectral de 0,01 segundos (PGA).

Coefficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
θ_1	4,639	4,148	0,356	(3,454; 4,843)	1,00
θ_2	1,070	1,001	0,055	(0,893; 1,107)	1,00
θ_3	-0,027	-0,0263	0,00263	(-0,03147; -0,02115)	1,00
θ_4	-1,450	-1,412	0,071	(-1,550; -1,271)	1,00
θ_5	-0,005	-0,0042	0,00043	(-0,0050; -0,0033)	1,00
θ_6	-0,653	-0,598	0,055	(-0,708; -0,490)	1,00
σ	0,795	0,927	0,028	(0,873; 0,982)	1,00

Tabla 13: Resultados de BMU para el modelo de MontalvaEtAl2017SSlab con un periodo espectral de 0,01 segundos (PGA).

Coefficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
b	-1,186	-1,104	0,102	(-1,306; -0,908)	1,00
C_1	7,2	7,02	0,175	(6,680; 7,365)	1,00
C_4	10	10,157	0,998	(8,181; 12,111)	1,00
n	1,18	1,106	0,103	(0,904; 1,309)	1,00
c	1,88	1,876	0,188	(1,505; 2,245)	1,00
θ_1	5,875	4,864	0,483	(3,932; 5,829)	1,00
θ_2	-1,754	-1,549	0,105	(-1,761; -1,350)	1,00
θ_3	0,131	0,134	0,011	(0,113; 0,155)	1,00
θ_4	0,803	0,895	0,061	(0,776; 1,016)	1,00
θ_5	-0,335	-0,336	0,033	(-0,400; -0,269)	1,00
θ_6	-0,00039	-0,00038	0,00004	(-0,00046; -0,00031)	1,00
θ_7	1,099	1,130	0,101	(0,937; 1,334)	1,00
θ_8	-1,42	-0,981	0,077	(-1,133; -0,832)	1,00
θ_9	0,4	0,395	0,040	(0,317; 0,473)	1,00
θ_{10}	4,531	3,933	0,402	(3,142; 4,718)	1,00
θ_{11}	0,0057	0,0058	0,00055	(0,00468; 0,00683)	1,00
θ_{12}	1,015	1,067	0,091	(0,885; 1,244)	1,00
θ_{14}	-0,7308	-0,695	0,069	(-0,828; -0,557)	1,00
σ	0,838	1,047	0,030	(0,988; 1,107)	1,00

Tabla 14: Resultados de BMU para el modelo de ZhaoEtAl2006SSlabNSHMP2014 con un periodo espectral de 0,01 segundos (PGA).

Coefficiente	Valor en literatura	Valor MAP	Desviación estándar	95 % HDI	$\hat{R}$
a	1.101	1,213	0,045	(1,127; 1,303)	1,00
b	-0,00564	-0,00548	0,00046	(-0,00639; -0,00459)	1,00
c	0,0055	0,00548	0,00055	(0,00443; 0,00659)	1,00
d	1,080	1,057	0,099	(0,860; 1,249)	1,00
e	0,0141	0,0120	0,0012	(0,0096; 0,0144)	1,00
S_S	2,607	2,235	0,218	(1,805; 2,659)	1,00
S_{SL}	-0,528	-0,598	0,043	(-0,683; -0,512)	1,00
σ	0,723	1,057	0,029	(1,0016; 1.1148)	1,00

Las desviaciones estándar totales de los diferentes modelos regionalizados se resumen en la figura 27. Se puede observar que para periodos espectrales entre 0,15 y 0,2 segundos se alcanzan las mayores desviaciones estándar totales. Los GMMs regionalizados tienen valores por encima de los reportados por la literatura, una tendencia ya observada en los GMMs para fuentes corticales. En general, el modelo de ArtetaEtAl2021Slab obtuvo los menores σ hasta un periodo de 2,0 segundos. El modelo de ZhaoEtAl2006NSHMP2014 obtuvo los mayores valores de σ entre los cuatro GMMs regionalizados, a pesar de que sus valores de literatura (línea discontinua color naranja) eran menores que los de los modelos de ArtetaEtAl2021Slab y MontalvaEtAl2017SSlab.




Figura 27: Desviaciones estándar totales de GMMs para subducción intraplaca regionalizados con BMU en función del periodo espectral.

A continuación se muestra el Posterior Predictive Check para los GMMs de fuentes intraplaca. El evento sísmico que se seleccionó fue el ocurrido 19 de enero de 2024 a las 06:26 (hora local de Colombia) cuyo epicentro se localizó en el municipio de Ansermanuevo, departamento del Valle del Cauca, República de Colombia (Latitud 4,78 grados, Longitud -76,04 grados). La magnitud de momento fue de 5,6 y la intensidad máxima percibida fue clasificada como VI (daño leve) en la Escala Macrosísmica Europea EMS-98, según el Servicio Geológico Colombiano (Servicio Geológico Colombiano, 2024). La profundidad reportada fue de 52 km, lo cual podría no ser suficiente para considerarlo como un evento intraplaca. Sin embargo, de acuerdo con la ubicación del epicentro en la vertiente oriental de la cordillera occidental, y la profundidad del hipocentro, este sismo podría clasificarse como un sismo de cuña del manto, es decir, eventos de subducción ubicados por encima de la placa subducida. Según Martínez-Jaramillo y Prieto (2024) la placa subducida libera fluidos que producen sismicidad en la cuña del manto. Más detalles sobre los daños en varias estructuras del norte del Valle del Cauca y las medidas instrumentales para este evento se pueden encontrar en Salazar, Ortiz et al. (2024).




Figura 28: Posterior Predictive Checks del modelo AbrahamsonEtAl2015SSlab con el sismo de Ansermanuevo.




Figura 29: Posterior Predictive Checks del modelo ArtetaEtAl2021Slab con el sismo de Ansermanuevo.




Figura 31: Posterior Predictive Checks del modelo ZhaoEtAl2006SSlabNSHMP2014 con el sismo de Ansermanuevo.




Figura 30: Posterior Predictive Checks del modelo MontalvaEtAl2017SSlab con el sismo de Ansermanuevo.

Las predicciones de los modelos AbrahamsonEtAl2015SSlab, MontalvaEtAl2017SSlab y ZhaoEtAl2006SSlabNSHMP2014 subestiman la aceleración espectral en el rango de distancias de 50 a 150 km. En contraste, las predicciones del modelo ArtetaEtAl2021Slab se ajustan más a los movimientos del suelo observados en este intervalo. Para sitios de roca S_2 (azul), los valores observados se encuentran consistentemente dentro de dos desviaciones estándar de las predicciones de los modelos. Sin embargo, las predicciones de AbrahamsonEtAl2015SSlab muestran el mayor desvío con respecto a las observaciones. Para los sitios de suelos blandos categoría S_5 (morado), que solo están presentes en el rango de 150 a 450 km, la mayoría de los modelos actualizados proporcionan predicciones dentro del rango de dos desviaciones estándar.

5.6. BMS para GMMs de subducción intraplaca

A continuación, se presentan los resultados de BMS con el método WAIC para los GMMs de subducción intraplaca. En la tabla 15 se observa que el modelo de ArtetaEtAl2021Slab obtuvo los mejores resultados para los periodos de 0,01 y 0,3 segundos. Los resultados para todos los periodos espectrales se adjuntan en el anexo.

Tabla 15: Resultados de BMS con WAIC para GMMs de subducción intraplaca.

T [s]	Modelo	Posición	$ELPD_{WAIC}$	P_{WAIC}	$ELPD_{diff}$	SE
0.01	ArtetaEtAl2021Slab	1	-641,73	3,54	0,00	15,78
	MontalvaEtAl2017SSlab	2	-715,26	6,14	73,53	16,61
	AbrahamsonEtAl2015SSlab	3	717,50	5,43	75,77	16,88
	ZhaoEtAl2006SSlabNSHMP2014	4	-736,81	3,23	95,08	15,46
0.3	ArtetaEtAl2021Slab	1	-669,93	3,79	0,00	18,47
	MontalvaEtAl2017SSlab	2	-752,52	6,23	82,59	19,05
	AbrahamsonEtAl2015SSlab	3	-757,52	5,78	87,59	21,57
	ZhaoEtAl2006SSlabNSHMP2014	4	-775,72	3,11	105,79	17,25
5	ArtetaEtAl2021Slab	1	-608,42	3,12	0,00	20,25
	AbrahamsonEtAl2015SSlab	2	-619,94	3,94	11,51	19,58
	MontalvaEtAl2017SSlab	3	-622,33	4,47	13,90	21,17
	ZhaoEtAl2006SSlabNSHMP2014	4	-648,15	2,38	39,72	16,98

Además, para los modelos intraplaca se observó la misma tendencia que para los modelos interplaca, donde los resultados del puntaje WAIC suelen ser similares para todos los modelos dentro de periodos espectrales mayores a 3 segundos. El traslape de las estimaciones del WAIC en el rango de $\pm SE$ que se observa en la figura 34 sugiere que el criterio WAIC no es concluyente sobre la conveniencia de un modelo en particular.




Figura 32: Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 0,01 segundos (PGA). Gráfico obtenido mediante Arviz.




Figura 33: Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 0,3 segundos.




Figura 34: Resultados de BMS con WAIC para GMMs de subducción intraplaca con periodo espectral de 5 segundos.

5.7. Discusión

El objetivo de este estudio fue evaluar, desde un enfoque bayesiano-probabilístico, cuáles GMMs son los más adecuados para una región determinada. Para responder a esto, el primer paso fue regionalizar un conjunto de GMMs globales mediante Bayesian Model Updatig, utilizando una base de datos local de movimiento fuerte. Este estudio muestra que los modelos regionalizados con BMU alcanzaron desviaciones estándar totales más altas σ que sus contrapartes de la literatura. Esto parece comprobar lo mencionado por Shahidzadeh y Yazdani (2017) sobre el aumento en la incertidumbre de los GMMs ajustados con bases de datos locales relativamente pequeñas comparadas con las globales.

En N. Abrahamson et al. (2016) el coeficiente σ se define como un valor constante igual a 0,74 para todos los períodos espectrales. En Zhao et al. (2006) y Montalva et al. (2017) se define como un valor constante dependiente del período. Mientras tanto, en Arteta et al. (2021) se define como una función de la distancia y el período espectral. En este estudio, la desviación estándar total del modelo se definió utilizando la ecuación 43, es decir, el valor σ tiene en cuenta la variabilidad aleatoria tanto de los datos observados como de la forma funcional del GMM. La incertidumbre epistémica se cuantifica mediante las distribuciones *Posterior* de los coeficientes. Esta incertidumbre se traslada a la incertidumbre en las predicciones de la mediana de la aceleración espectral que realiza el modelo, y no debe ser ignorada (N. M. Kuehn y Scherbaum, 2016). Mientras que la incertidumbre que proviene de los datos se asocia con la variabilidad aleatoria inherente al fenómeno estudiado (N. M. Kuehn et al., 2023).

Al regionalizar modelos globales con bases de datos regionales relativamente pequeñas, se espera un impacto en el coeficiente σ pues la nueva base de datos informa al modelo sobre ciertos aspectos que no quedan totalmente restringidos por los datos disponibles. Esta es la razón por la cual en los modelos de Arteta et al. (2021, 2023) se adoptan los parámetros f_{magGL} y f_{pathGL} de los modelos globales. En este estudio se asumieron esos valores de los modelos globales para informar a las Priors.

Por otra parte, es común que en los GMMs se obtenga el coeficiente σ por medio del análisis de residuales (Ecuación 9). En este estudio, se definió por medio de la Likelihood (Ecuación 43). La diferencia entre estos radica en que el análisis de residuales se hace con respecto a la base de datos usada para desarrollar el modelo y teniendo en cuenta las medianas de las predicciones del modelo. Además, en los métodos de regresión tradicionales, los coeficientes del modelo son tratados como constantes desconocidas sin ninguna incertidumbre asociada, mientras que el método Bayesiano las considera como variables aleatorias con distribuciones de probabilidad. De manera que el método Bayesiano captura la incertidumbre epistémica por medio de las distribuciones de los coeficientes y la variabilidad aleatoria total asociada a los datos y a la forma funcional del GMM por medio de σ . Por tanto es de esperarse que haya divergencias entre los valores de σ de la literatura y los reportados por medio de análisis de regresión Bayesianos.

En forma matemática, estas diferencias pueden cuantificarse usando la expresión que se encuentra en la p. 56 de N. Kuehn et al. (2020):

$$\sigma_{total} = \sqrt{\tau^2 + \phi^2 + \psi_\mu^2} \quad (46)$$

donde σ_{total} es la variabilidad total, la cual combina variabilidad aleatoria e incertidumbre epistémica y describe el rango completo de posibles aceleraciones espectrales y ψ_μ es la incertidumbre epistémica asociada con las predicciones del modelo. De acuerdo con la ecuación 46 queda claro entonces, que el σ que se obtiene en este estudio es igual al σ_{total} y se ve aumentado de acuerdo con ψ_μ respecto de los valores que se registran en la literatura.

En este estudio se mostró cómo BMU puede ser utilizado para extrapolar modelos regionales a partir de sus formas funcionales iniciales, y como resultado, por ejemplo, se ajustó el modelo de Idriss2014 para un rango de V_{S30} fuera del rango utilizado para su definición inicial.

El PPC es útil para evaluar los modelos actualizados (regionalizados), pues permite comparar directamente las observaciones con las predicciones de los modelos. Estas observaciones fueron tomadas de eventos que no están incluidos en la base de datos del BMU, por lo que son un indicador de las capacidades de predicción de los modelos. Sin embargo, es difícil decir cuál modelo es más conveniente a partir del mero análisis del PPC. A lo sumo, un modelo con un mal comportamiento en el PPC podría ser descartado. Por ejemplo, un modelo cuyas predicciones en su mayoría estuvieran por fuera del intervalo de dos desviaciones estándar.

Algo similar ocurre con el análisis de residuales que se usa comúnmente durante el desarrollo de los GMMs mediante la ecuación 9. En el análisis de residuales se comparan las predicciones del modelo con los datos que se usaron para ajustar el mismo modelo. Por esta razón, los residuales por sí solos no son suficientes para evaluar las capacidades de los GMM para hacer predicciones para eventos futuros, sino que son una forma de cuantificar el ajuste de un modelo con datos existentes. Por ejemplo, el trabajo de Salazar, Ortiz y Marulanda Casas (2024) muestra cómo dos modelos con residuales idénticos hacen predicciones muy diferentes para distancias cortas.

Tanto el análisis de PPC como el de residuos no son suficientes para tomar decisiones sobre la conveniencia de los GMM y cómo asignar pesos en el árbol lógico para PSHA. Eso motiva la implementación de técnicas de selección de modelos que tengan en cuenta las capacidades del modelo para hacer predicciones por fuera de los datos utilizado para ajustar el modelo. Los resultados de BMS utilizando el método WAIC para periodos espectrales de 0,01 a 1,0 segundos muestran que ArtetaEtAl2021Inter y ArtetaEtAl2021Slab obtuvieron la mejor clasificación, pero más allá de estos periodos, la clasificación WAIC no es concluyente tanto para los modelos de subducción interplaca como para los de intraplaca. Los resultados muestran una relación entre las desviaciones estándar totales de los modelos regionalizados con BMU y los resultados del BMS con WAIC; los modelos con menores valores de σ tras el BMU, obtienen los mejores puntajes WAIC (ver figuras 8, 19 y 27). Sin embargo, las diferencias entre los valores de σ entre los GMMs regionalizados no son significativamente grandes entre ellos. De esto se derivan dos consideraciones principales. En primer lugar, no existe un modelo único que pueda considerarse el "mejor". En cambio, se debe evaluar y comparar un conjunto de modelos. En segundo lugar, el periodo espectral juega un papel fundamental, ya que se han encontrado diferencias en periodos específicos, para cada tipo de fuente sísmica (corticales y de subducción).

El objetivo de investigación mencionado anteriormente resulta transformarse en: ¿cuáles son los GMM más adecuados para una región determinada en un periodo espectral determinado? Este estudio sugiere que, para periodos mayores a 1,0 segundos en modelos interplaca y 3,0 segundos en modelos intraplaca, no hay una conclusión clara. Como máximo, se podría descartar el modelo con el puntaje más bajo. En este caso, se debe acudir a otros criterios para complementar el análisis, pues lo que sugiere el WAIC por sí solo es que todos los modelos deberían tener el mismo peso en el árbol lógico en periodos mayores a 3 segundos. Este trabajo también destaca la importancia de definir árboles lógicos y la incertidumbre epistémica en el contexto de los códigos de diseño, donde los coeficientes para periodos cortos y largos se especifican de forma independiente. En ambos rangos, los GMM dominantes pueden diferir.

Los GMMs que obtienen la mejor clasificación con WAIC, *ArtetaEtAl2021Inter*, *ArtetaEtAl2021Slab* y *ArtetaEtAl2023*, tienen algunas características especiales, respecto a sus contrapartes. En primer lugar, tienen una forma funcional relativamente sencilla y con 5, 6 y 7 coeficientes de regresión θ respectivamente. En segundo lugar, los efectos del sitio se describen en términos del período natural del depósito de suelo T_n . Este término se introduce en el modelo como parte del conjunto de datos y no se actualiza mediante el proceso BMU. En tercer lugar, los modelos de Arteta et al. (2021) y Arteta et al. (2023) se desarrollaron con una base de datos muy similar a la utilizada en este estudio. Eso significa que la metodología usada en este estudio sirve para validar los GMMs desarrollados en una región específica. En cuarto lugar, los modelos de subducción interplaca e intraplaca (*ArtetaEtAl2021Inter*, *ArtetaEtAl2021Slab*) tienen definidos sus coeficientes θ de forma independiente, mientras que los modelos de N. Abrahamson et al. (2016), Montalva et al. (2017) y Zhao et al. (2006) tienen los mismos coeficientes para ambos ambientes tectónicos y solamente añaden o modifican unos pocos términos dependiendo del ambiente que se trabaja.

Como se explicó en la Metodología, el WAIC tiene una interpretación fundamentalmente estadística, pero podría dar pistas sobre procesos físicos que son mejor capturados por algunos GMMs. En particular, los efectos de sitio caracterizados de acuerdo con el periodo natural del depósito de suelo y en función del ambiente tectónico, como en el modelo de Mercado et al. (2023) usado en los GMMs de Arteta et al. (2021, 2023) y no solamente a partir de un parámetro del suelo como el V_{S30} , muestran una ventaja respecto a los demás modelos cuando se comparan mediante WAIC.

El método WAIC se seleccionó porque utiliza por completo las muestras de las distribuciones Posterior en la comparación de los modelos. Esto es importante porque no podían compararse modelos por fuera del marco del Bayesian Model Updating. En los trabajos de Arteta et al. (2021, 2023) y Montalva et al. (2017) se muestra a partir del análisis de residuales que los modelos regionalizados tienen mejores probabilidades de representar la sismicidad de la región, en contraste con los modelos globales que se usan bajo el principio ergódico. Luego, incluir en el WAIC modelos globales sin regionalizar habría resultado en una clara ventaja de antemano para los modelos regionales.

Otros métodos de selección/comparación de modelos, como el Deviance Information Criterion DIC, usan solamente la media de las distribuciones Posterior para comparar modelos (Bodda et al., 2022; Kowsari, Halldorsson, Hrafnkelsson y Jónsson, 2019). En el contexto del

presente estudio, esto resulta poco conveniente, pues, como se comentó en la introducción, la región estudiada cuenta con un historial relativamente corto de sismicidad, en especial en el rango de magnitudes grandes a cortas distancias. En escenarios de alta incertidumbre, esto hace que las distribuciones Posterior sean más sensibles a las Prior. Por tanto, es preferible un método de selección de modelos que tenga en cuenta toda la incertidumbre contenida en las Posterior, en lugar de trabajar solamente con el valor medio.

Finalmente, la selección de GMMs en el Modelo Nacional de Amenaza para Colombia de Arcila et al. (2020) se realizó utilizando el método LLH propuesto por Scherbaum et al. (2009). Para la subducción interplaca, los pesos que definieron en el Árbol Lógico fueron los siguientes: AbrahamsonEtAl2015SInter (0.437), ZhaoEtAl2006SInterNSHMP2008 (0.348) y MontalvaEtAl2016SInter (0.215). Este estudio muestra que AbrahamsonEtAl2015SInter y MontalvaEtAl2016SInter obtienen calificaciones similares con WAIC y ZhaoEtAl2006SInterNSHMP2008 obtuvo el puntaje más bajo. Para los modelos intraplaca, Arcila et al. (2020) definieron los siguientes pesos: MontalvaEtAl2016SSlab (0,424), AbrahamsonEtAl2015SSlab (0,365) y ZhaoEtAl2006SSlabNSHMP2014 (0,210). En este estudio se muestra una tendencia similar en las figuras 32 y 33, y en la figura 34 se observa una muy leve ventaja del modelo de AbrahamsonEtAl2015SSlab sobre el de MontalvaEtAl2016SSlab que, como se discutió más arriba, no es importante. De esta manera, si ArtetaEtAl2021Slab se excluyera de la lista, MontalvaEtAl2016SSlab habría obtenido la mejor clasificación entre los tres modelos restantes, similar a lo reportado por Arcila et al. (2020).

6. Conclusiones

El Bayesian Model Updating BMU es un enfoque probabilístico efectivo para regionalizar Modelos de Movimiento del Terreno (GMMs) globales, utilizando conjuntos de datos locales y distribuciones Prior informadas con base en la literatura existente. Además, el BMU puede ser una metodología de validación para GMMs desarrollados mediante otros métodos de regresión, lo cual es particularmente valioso en países como Colombia, donde existe una cantidad limitada de datos sísmicos para terremotos de gran magnitud a distancias cortas.

Este estudio evidencia una relación entre las clasificaciones según WAIC y la desviación estándar total σ de los GMMs actualizados. Esto se relaciona con la capacidad de los modelos para realizar predicciones fuera de la base de datos utilizada en el proceso de BMU. Es decir, el modelo mejor clasificado por WAIC en un determinado período espectral tiene una mayor probabilidad de representar mejor las intensidades esperadas de movimiento del terreno en la región estudiada.

Los valores más altos de la desviación estándar total σ obtenidos con el enfoque Bayesiano pueden resultar en cambios significativos en las estimaciones de amenaza sísmica. Estudios futuros podrían evaluar el efecto de utilizar diferentes intervalos de las distribuciones de probabilidad de cada coeficiente actualizado dentro del Árbol Lógico y su impacto en las estimaciones de PSHA. La calificación obtenida por los modelos ArtetaEtAl2021Inter y ArtetaEtAl2021Slab mediante BMS-WAIC sugiere que en el PSHA deberían tener un mayor peso dentro del Árbol Lógico.

En este estudio, las variables de entrada del conjunto de datos de movimiento fuerte, como magnitud, distancia y propiedades del depósito de suelo, se trataron como valores constantes, aunque es bien sabido que estas poseen sus propias incertidumbres. Estudios futuros podrían incorporar dichas incertidumbres en un análisis Bayesiano evaluando la propagación de la incertidumbre en los GMMs para Colombia, tomando como base metodológica el trabajo de N. M. Kuehn y Abrahamson (2018).

Los GMMs para el Nido Sísmico de Bucaramanga deberían ser estudiados en un futuro cercano con el fin de aplicar el mismo marco Bayesiano-probabilístico a las principales fuentes sísmicas de Colombia. En particular, debería incorporarse la misma metodología de BMS en un listado que contenga el modelo de Pájaro et al. (2024) junto con otros GMMs de subducción intraplaca considerados en Arcila et al. (2020) para este ambiente tectónico.

Finalmente, la metodología implementada en este estudio mediante BMU y BMS-WAIC podría servir como base para desarrollar un sistema de asignación de pesos de los GMMs en el árbol lógico para PSHA. Se podrían incluir otros métodos de Model Selection y definir distintas ramas del árbol lógico en función de estos.

Referencias

- Abrahamson, N. A., & Youngs, R. R. (1992). A stable algorithm for regression analyses using the random effects model. *Bulletin of the Seismological Society of America*, 82(1), 505-510. <https://doi.org/10.1785/BSSA0820010505>
- Abrahamson, N., Atkinson, G., Boore, D., Bozorgnia, Y., Campbell, K., Chiou, B., Idriss, I. M., Silva, W., & Youngs, R. (2008). Comparisons of the NGA Ground-Motion Relations. *Earthquake Spectra*, 24(1), 45-66. <https://doi.org/10.1193/1.2924363>
- Abrahamson, N., Gregor, N., & Addo, K. (2016). BC Hydro Ground Motion Prediction Equations for Subduction Earthquakes. *Earthquake Spectra*, 32(1), 23-44. <https://doi.org/10.1193/051712EQS188MR>
- Abrahamson, N., & Gülerce, Z. (2020, diciembre). *Regionalized Ground-Motion Models for Subduction Earthquakes Based on the NGA-SUB Database* (PEER Reports) (Series: PEER Reports). Pacific Earthquake Engineering Research Center, University of California, Berkeley, CA. <https://doi.org/10.55461/SSXE9861>
- Abrahamson, N. A., Silva, W. J., & Kamai, R. (2014). Summary of the ASK14 Ground Motion Relation for Active Crustal Regions. *Earthquake Spectra*, 30(3), 1025-1055. <https://doi.org/10.1193/070913EQS198M>
- Abril-Pla, O., Andreani, V., Carroll, C., Dong, L., Fonnesbeck, C. J., Kochurov, M., Kumar, R., Lao, J., Luhmann, C. C., Martin, O. A., Osthege, M., Vieira, R., Wiecki, T., & Zinkov, R. (2023). PyMC: a modern, and comprehensive probabilistic programming framework in Python. *PeerJ Computer Science*, 9, e1516. <https://doi.org/10.7717/peerj-cs.1516>
- Akkar, S., & Bommer, J. J. (2010). Empirical Equations for the Prediction of PGA, PGV, and Spectral Accelerations in Europe, the Mediterranean Region, and the Middle East. *Seismological Research Letters*, 81(2), 195-206. <https://doi.org/10.1785/gssrl.81.2.195>
- Akkar, S., & Cagnan, Z. (2010). A Local Ground-Motion Predictive Model for Turkey, and Its Comparison with Other Regional and Global Ground-Motion Models. *Bulletin of the Seismological Society of America*, 100(6), 2978-2995. <https://doi.org/10.1785/0120090367>
- Al Atik, L., Abrahamson, N., Bommer, J. J., Scherbaum, F., Cotton, F., & Kuehn, N. (2010). The Variability of Ground-Motion Prediction Models and Its Components. *Seismological Research Letters*, 81(5), 794-801. <https://doi.org/10.1785/gssrl.81.5.794>
- Ambraseys, N. N., Douglas, J., Sarma, S. K., & Smit, P. M. (2005). Equations for the Estimation of Strong Ground Motions from Shallow Crustal Earthquakes Using Data from Europe and the Middle East: Horizontal Peak Ground Acceleration and Spectral Acceleration. *Bulletin of Earthquake Engineering*, 3(1), 1-53. <https://doi.org/10.1007/s10518-005-0183-0>
- Anderson, J. G., & Brune, J. N. (1999). Probabilistic Seismic Hazard Analysis without the Ergodic Assumption. *Seismological Research Letters*, 70(1), 19-28. <https://doi.org/10.1785/gssrl.70.1.19>

- Arcila, M., García, J., Montejó, J., Eraso, J., Valcárcel, J., Mora, M., Viganò, D., Pagani, M., & Díaz, F. J. (2020). *Modelo nacional de amenaza sísmica para Colombia*. Servicio Geológico Colombiano. <https://doi.org/10.32685/9789585279469>
- Arroyo, D., & Ordaz, M. (2010). Multivariate Bayesian Regression Analysis Applied to Ground-Motion Prediction Equations, Part 2: Numerical Example with Actual Data. *Bulletin of the Seismological Society of America*, 100(4), 1568-1577. <https://doi.org/10.1785/0120090320>
- Arteta, C. A., Pajaro, C. A., Mercado, V., Montejó, J., Arcila, M., & Abrahamson, N. A. (2021). Ground-motion model for subduction earthquakes in northern South America. *Earthquake Spectra*, 37(4), 2419-2452. <https://doi.org/10.1177/87552930211027585>
- Arteta, C. A., Pajaro, C. A., Mercado, V., Montejó, J., Arcila, M., & Abrahamson, N. A. (2023). Ground-Motion Model (GMM) for Crustal Earthquakes in Northern South America (NoSam Crustal GMM). *Bulletin of the Seismological Society of America*, 113(1), 186-203. <https://doi.org/10.1785/0120220168>
- Asociación Colombiana de Ingeniería Sísmica AIS. (1984). *Estudio General del Riesgo Sísmico de Colombia*.
- Asociación Colombiana de Ingeniería Sísmica AIS. (1996). *Estudio General de Amenaza Sísmica de Colombia*.
- Asociación Colombiana de Ingeniería Sísmica AIS, Comité AIS-300. (2009). *Estudio General de Amenaza Sísmica de Colombia 2009*.
- Atkinson, G. M., & Adams, J. (2013). Ground motion prediction equations for application to the 2015 Canadian national seismic hazard maps. *Canadian Journal of Civil Engineering*, 40(10), 988-998. <https://doi.org/10.1139/cjce-2012-0544>
- Baker, J., et al. (2021). *Seismic Hazard and Risk Analysis*. Cambridge University Press. <https://doi.org/10.1017/9781108425056>
- Bayliss, K., Naylor, M., Kamranzad, F., & Main, I. (2022). Pseudo-prospective testing of 5-year earthquake forecasts for California using inlabru. *Natural Hazards and Earth System Sciences*, 22(10), 3231-3246. <https://doi.org/10.5194/nhess-22-3231-2022>
- Bindi, D., Massa, M., Luzi, L., Ameri, G., Pacor, F., Puglia, R., & Augliera, P. (2014). Pan-European ground-motion prediction equations for the average horizontal component of PGA, PGV, and 5%-damped PSA at spectral periods up to 3.0 s using the RESORCE dataset. *Bulletin of Earthquake Engineering*, 12(1), 391-430. <https://doi.org/10.1007/s10518-013-9525-5>
- Bodda, S. S., Keller, M., Gupta, A., & Senfaute, G. (2022). A Methodological Approach to Update Ground Motion Prediction Models Using Bayesian Inference. *Pure and Applied Geophysics*, 179(1), 247-264. <https://doi.org/10.1007/s00024-021-02915-8>
- Bommer, J. J., Douglas, J., Scherbaum, F., Cotton, F., Bungum, H., & Fäh, D. (2010). On the Selection of Ground-Motion Prediction Equations for Seismic Hazard Analysis. *Seismological Research Letters*, 81(5), 783-793. <https://doi.org/10.1785/gssrl.81.5.783>
- Bommer, J. J., & Scherbaum, F. (2008). *The Use and Misuse of Logic Trees in Probabilistic Seismic Hazard Analysis* [Publisher: SAGE PublicationsSage UK: London, England]. *Earthquake Spectra*. <https://doi.org/10.1193/1.2977755>

- Boore, D. M. (2010). Orientation-Independent, Nongeometric-Mean Measures of Seismic Intensity from Two Horizontal Components of Motion. *Bulletin of the Seismological Society of America*, 100(4), 1830-1835. <https://doi.org/10.1785/0120090400>
- Campbell, K. W. (1997). Empirical Near-Source Attenuation Relationships for Horizontal and Vertical Components of Peak Ground Acceleration, Peak Ground Velocity, and Pseudo-Absolute Acceleration Response Spectra. *Seismological Research Letters*, 68(1), 154-179. <https://doi.org/10.1785/gssrl.68.1.154>
- Cauzzi, C., & Faccioli, E. (2008). Broadband (0.05 to 20 s) prediction of displacement response spectra based on worldwide digital records. *Journal of Seismology*, 12(4), 453-475. <https://doi.org/10.1007/s10950-008-9098-y>
- Cauzzi, C., Faccioli, E., Vanini, M., & Bianchini, A. (2015). Updated predictive equations for broadband (0.01–10 s) horizontal response spectra and peak ground motions, based on a global dataset of digital acceleration records. *Bulletin of Earthquake Engineering*, 13(6), 1587-1612. <https://doi.org/10.1007/s10518-014-9685-y>
- Ching, J., & Glaser, S. D. (2003). Identification of soil degradation during earthquake excitations by Bayesian inference. *Earthquake Engineering & Structural Dynamics*, 32(6), 845-869. <https://doi.org/10.1002/eqe.251>
- Chiou, B., Darragh, R., Gregor, N., & Silva, W. (2008). NGA Project Strong-Motion Database. *Earthquake Spectra*, 24(1), 23-44. <https://doi.org/10.1193/1.2894831>
- Chiou, B.-J., & Youngs, R. R. (2008). An NGA Model for the Average Horizontal Component of Peak Ground Motion and Response Spectra. *Earthquake Spectra*, 24(1), 173-215. <https://doi.org/10.1193/1.2894832>
- Chlieh, M., Beauval, C., Yepes, H., Marinière, J., Saillard, M., & Audin, L. (2021). Seismic and Aseismic Cycle of the Ecuador–Colombia Subduction Zone. *Frontiers in Earth Science*, 9, 701720. <https://doi.org/10.3389/feart.2021.701720>
- Costa, C., Alvarado, A., Audemard, F., Audin, L., Benavente, C., Bezerra, F. H., Cembrano, J., González, G., López, M., Minaya, E., Santibañez, I., Garcia, J., Arcila, M., Pagani, M., Pérez, I., Delgado, F., Paolini, M., & Garro, H. (2020). Hazardous faults of South America; compilation and overview. *Journal of South American Earth Sciences*, 104, 102837. <https://doi.org/10.1016/j.jsames.2020.102837>
- Cotton, F., Scherbaum, F., Bommer, J. J., & Bungum, H. (2006). Criteria for Selecting and Adjusting Ground-Motion Models for Specific Target Regions: Application to Central Europe and Rock Sites. *Journal of Seismology*, 10(2), 137-156. <https://doi.org/10.1007/s10950-005-9006-7>
- Danciu, L., & Tselentis, G.-A. (2007). Engineering Ground-Motion Parameters Attenuation Relationships for Greece. *Bulletin of the Seismological Society of America*, 97(1B), 162-183. <https://doi.org/10.1785/0120050087>
- Donovan, N. (1973). A statistical evaluation of strong motion data: Including the February 9, 1971 San Fernando earthquake.
- Gallego, M. (2000). *Estimación del Riesgo Sísmico en la República de Colombia* [Tesis de Maestría]. Universidad Nacional Autónoma de México.

- Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A., & Rubin, D. B. (2021). *Bayesian Data Analysis* (3.^a ed.). Columbia University.
- Gelman, A., Hwang, J., & Vehtari, A. (2014). Understanding predictive information criteria for Bayesian models. *Statistics and Computing*, 24(6), 997-1016. <https://doi.org/10.1007/s11222-013-9416-2>
- Gülerce, Z., Kargoğlu, B., & Abrahamson, N. A. (2016). Turkey-Adjusted NGA-W1 Horizontal Ground Motion Prediction Models. *Earthquake Spectra*, 32(1), 75-100. <https://doi.org/10.1193/022714EQS034M>
- Gülkan, P., & Kalkan, E. (2002). Attenuation modeling of recent earthquakes in Turkey. *Journal of Seismology*, 6(3), 397-409. <https://doi.org/10.1023/A:1020087426440>
- Hoffman, M. D., & Gelman, A. (2011). The No-U-Turn Sampler: Adaptively Setting Path Lengths in Hamiltonian Monte Carlo [Version Number: 1]. <https://doi.org/10.48550/ARXIV.1111.4246>
- Hu, J., & Liu, H. (2019). Bayesian network models for probabilistic evaluation of earthquake-induced liquefaction based on CPT and Vs databases. *Engineering Geology*, 254, 76-88. <https://doi.org/10.1016/j.enggeo.2019.04.003>
- Idriss, I. M. (2014). An NGA-West2 Empirical Model for Estimating the Horizontal Spectral Values Generated by Shallow Crustal Earthquakes. *Earthquake Spectra*, 30(3), 1155-1177. <https://doi.org/10.1193/070613EQS195M>
- Joyner, W. B., & Boore, D. M. (1993). Methods for regression analysis of strong-motion data. *Bulletin of the Seismological Society of America*, 83(2), 469-487. <https://doi.org/10.1785/BSSA0830020469>
- Joyner, W. B., & Boore, D. M. (1994). Errata: Methods for regression analysis of strong-motion data. *Bulletin of the Seismological Society of America*, 84(3), 955-956. <https://doi.org/10.1785/BSSA0840030955>
- Kao, C.-Y., Chung, J.-K., & Yeh, Y.-T. (2010). A Comparative Study of the Least Squares Method and the Genetic Algorithm in Deducing Peak Ground Acceleration Attenuation Relationships. *Terrestrial, Atmospheric and Oceanic Sciences*, 21(6), 869. [https://doi.org/10.3319/TAO.2010.02.10.01\(T\)](https://doi.org/10.3319/TAO.2010.02.10.01(T))
- Keller, M., Pasanisi, A., Marcilhac, M., Yalamas, T., Secanell, R., & Senfaute, G. (2014). A Bayesian Methodology Applied to the Estimation of Earthquake Recurrence Parameters for Seismic Hazard Assessment. *Quality and Reliability Engineering International*, 30(7), 921-933. <https://doi.org/10.1002/qre.1735>
- Kowsari, M., Halldorsson, B., Hrafnkelsson, B., & Jónsson, S. (2019). Selection of earthquake ground motion models using the deviance information criterion. *Soil Dynamics and Earthquake Engineering*, 117, 288-299. <https://doi.org/https://doi.org/10.1016/j.soildyn.2018.11.014>
- Kowsari, M., Halldorsson, B., Hrafnkelsson, B., Snæbjörnsson, J. P., & Jónsson, S. (2019). Calibration of ground motion models to Icelandic peak ground acceleration data using Bayesian Markov Chain Monte Carlo simulation. *Bulletin of Earthquake Engineering*, 17(6), 2841-2870. <https://doi.org/10.1007/s10518-019-00569-5>

- Kowsari, M., Sonnemann, T., Halldorsson, B., Hrafnkelsson, B., Snæbjörnsson, J. P., & Jónsson, S. (2020). Bayesian inference of empirical ground motion models to pseudo-spectral accelerations of south Iceland seismic zone earthquakes based on informative priors. *Soil Dynamics and Earthquake Engineering*, 132, 106075. <https://doi.org/10.1016/j.soildyn.2020.106075>
- Kuehn, N., Bozorgnia, Y., Campbell, K., & Gregor, N. (2020, septiembre). *Partially Non-Ergodic Ground-Motion Model for Subduction Regions using the NGA Subduction Database* (PEER Reports) (Series: PEER Reports). Pacific Earthquake Engineering Research Center, University of California, Berkeley, CA. <https://doi.org/10.55461/NZZW1930>
- Kuehn, N. M., & Abrahamson, N. A. (2018). The Effect of Uncertainty in Predictor Variables on the Estimation of Ground-Motion Prediction Equations. *Bulletin of the Seismological Society of America*, 108(1), 358-370. <https://doi.org/10.1785/0120170166>
- Kuehn, N. M., Bozorgnia, Y., Campbell, K. W., & Gregor, N. (2023). A regionalized partially nonergodic ground-motion model for subduction earthquakes using the NGA-Sub database. *Earthquake Spectra*, 39(3), 1625-1657. <https://doi.org/10.1177/87552930231180906>
- Kuehn, N. M., & Scherbaum, F. (2016). A partially non-ergodic ground-motion prediction equation for Europe and the Middle East. *Bulletin of Earthquake Engineering*, 14(10), 2629-2642. <https://doi.org/10.1007/s10518-016-9911-x>
- Kuehn, N. M., Kishida, T., AlHamaydeh, M., Lavrentiadis, G., & Bozorgnia, Y. (2020). A Bayesian model for truncated regression for the estimation of empirical ground-motion models. *Bulletin of Earthquake Engineering*, 18(14), 6149-6179. <https://doi.org/10.1007/s10518-020-00943-8>
- Kumar, R., Carroll, C., Hartikainen, A., & Martin, O. (2019). ArviZ a unified library for exploratory analysis of Bayesian models in Python. *Journal of Open Source Software*, 4(33), 1143. <https://doi.org/10.21105/joss.01143>
- Lay, T., & Wallace, T. C. (1995). *Modern Global Seimology*. Academic Press. Consultado el 22 de agosto de 2024, desde https://www.researchgate.net/publication/221678247_Modern_Global_Seimology
- Lin, P.-S., & Lee, C.-T. (2008). Ground-Motion Attenuation Relationships for Subduction-Zone Earthquakes in Northeastern Taiwan. *Bulletin of the Seismological Society of America*, 98(1), 220-240. <https://doi.org/10.1785/0120060002>
- Lomnitz, C., & Hashizume, M. (1985). The Popayán, Colombia, earthquake of 31 March 1983. *Bulletin of the Seismological Society of America*, 75(5), 1315-1326. <https://doi.org/10.1785/BSSA0750051315>
- Martin, O. (2018). *Bayesian Analysis with Python* (2.^a ed.). Packt Publishing. www.packtpub.com
- Martin, O., Kumar, R., & Lao, J. (2021, noviembre). *Bayesian Modeling and Computation in Python* (1.^a ed.). Chapman; Hall/CRC. <https://doi.org/10.1201/9781003019169>

- Martínez, S., & Chica, A. (1997). *Ecuaciones de Atenuación de la Energía Sísmica Para Colombia* [Tesis de Grado]. Pontificia Universidad Javeriana, Departamento de Ingeniería Civil.
- Martínez-Jaramillo, D., & Prieto, G. A. (2024). Tectonic setting of the northwestern andes Constrained by a high-resolution earthquake catalog: Block Kinematics. *Journal of South American Earth Sciences*, 134, 104761. <https://doi.org/10.1016/j.jsames.2023.104761>
- Marzocchi, W., Zechar, J. D., & Jordan, T. H. (2012). Bayesian Forecast Evaluation and Ensemble Earthquake Forecasting. *Bulletin of the Seismological Society of America*, 102(6), 2574-2584. <https://doi.org/10.1785/0120110327>
- McGuire, R. K. (1974). *Seismic Structural Response Risk Analysis, Incorporating Peak Response Regressions On Earthquake Magnitude and Distance* (inf. téc. N.º 51). MIT Department of Civil Engineering.
- McGuire, R. K. (2004). *Seismic Hazard and Risk Analysis* (1.^a ed.). Earthquake Engineering Research Institute.
- Mercado, V., Pajaro, C. A., Arteta, C. A., Díaz, F. J., Montejo, J., Arcila, M., & Abrahamson, N. A. (2023). Semiempirical model for the estimation of site amplification in Northern South America. *Earthquake Spectra*, 39(2), 1109-1139. <https://doi.org/10.1177/87552930231153190>
- Ministerio de Ambiente, V. y. D. T. (2010). Reglamento Colombiano De Construcción Sismorresistente NSR-10.
- Molas, G. L., & Yamazaki, F. (1995). Attenuation of earthquake ground motion in Japan including deep focus events. *Bulletin of the Seismological Society of America*, 85(5), 1343-1358. <https://doi.org/10.1785/BSSA0850051343>
- Montalva, G. A., Bastías, N., & Rodriguez-Marek, A. (2017). Ground-Motion Prediction Equation for the Chilean Subduction Zone. *Bulletin of the Seismological Society of America*, 107(2), 901-911. <https://doi.org/10.1785/0120160221>
- Ojeda, A., & Martínez, S. (1998). *Modelo para la atenuación de la Energía Sísmica en Colombia a partir de Sismos Registrados por la Red Nacional de Acelerógrafos* (Boletín técnico núm. 53). Asociación Colombiana de Ingeniería sísmica AIS.
- Pagani, M., Monelli, D., Weatherill, G., Danciu, L., Crowley, H., Silva, V., Henshaw, P., Butler, L., Nastasi, M., Panzeri, L., Simionato, M., & Vigano, D. (2014). OpenQuake Engine: An Open Hazard (and Risk) Software for the Global Earthquake Model. *Seismological Research Letters*, 85(3), 692-702. <https://doi.org/10.1785/0220130087>
- Pájaro, C. A., Arteta, C. A., Mercado, V., Montejo, J., Arcila, M., & Abrahamson, N. A. (2024). Partially non-ergodic ground motion model for the Bucaramanga seismic nest in Northern South America (NoSam Nest GMM). *Bulletin of Earthquake Engineering*, 22(8), 3677-3702. <https://doi.org/10.1007/s10518-024-01898-w>
- Petersen, M., Frankel, A. D., & et al. (2008). *Documentation for the 2008 Update of the United States National Seismic Hazard Maps* (Open-File Report) (Series: Open-File Report).

- Petersen, M., Moschetti, M. P., Powers, P. M., Mueller, C. S., Haller, K. M., Frankel, A. D., Zeng, Y., Rezaeian, S., Harmsen, S. C., Boyd, O. S., Field, E. H., Chen, R., Rukstales, K. S., Luco, N., Wheeler, R. R., Williams, R. A., & Olsen, A. H. (2014). *Documentation for the 2014 update of the United States national seismic hazard maps* (Open-File Report) (Series: Open-File Report). USGS Geologic Hazards Science Center. <https://doi.org/10.3133/ofr20141091>
- Pulido, N., Yoshimoto, M., & Sarabia, A. M. (2020). Broadband wavelength slip model of the 1906 Ecuador-Colombia megathrust-earthquake based on seismic intensity and tsunami data. *Tectonophysics*, 774, 228226. <https://doi.org/10.1016/j.tecto.2019.228226>
- PyMC. (2020). pymc.smc.sample_smc — PyMC 5.18.2 documentation. Consultado el 25 de noviembre de 2024, desde https://www.pymc.io/projects/docs/en/stable/api/generated/pymc.smc.sample_smc.html#pymc.smc.sample_smc
- Sadigh, K., Chang, C. Y., Egan, J. A., Makdisi, F., & Youngs, R. R. (1997). Attenuation Relationships for Shallow Crustal Earthquakes Based on California Strong Motion Data. *Seismological Research Letters*, 68(1), 180-189. <https://doi.org/10.1785/gssrl.68.1.180>
- Salazar, B., Ortiz, A., Arcila, M., Montejó, J., Carrillo, J., Arroyo, O., Arteta, C., Bonett, R., Blandón, C., & Piscal, C. (2024). Sismo Mw 5.6 de Ansermanuevo, Valle del Cauca, Colombia del 19-01-2024, Informe preliminar de reconocimiento posterremoto [Publisher: Unpublished Version Number: 1]. *Research Gate (Unpublished)*. <https://doi.org/10.13140/RG.2.2.23852.64646/1>
- Salazar, B., Ortiz, A. R., & Marulanda Casas, J. (2024). Uncertainty quantification of Ground Motion Models using Bayesian Analysis – Models for Colombia. *Recent Advances in Ground Motion Modeling GRM5*.
- Salgado-Gálvez, M., Bernal, G., & Cardona, O. (2016). Evaluación probabilista de la amenaza sísmica de Colombia con fines de actualización de la Norma Colombiana de Diseño de Puentes CCP-14. *Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería*, 32(4), 230-239. <https://doi.org/10.1016/j.rimni.2015.07.001>
- Sarabia Gómez, A. M., Barbosa Castro, D. R., & Arcila, M. (2022). Macroseismic intensity data and effects of significant earthquakes in Colombia based on historical seismicity studies. <https://doi.org/https://doi.org/10.32685/0120-1425/bol.geol.49.2.2022.638>
- Scasserra, G., Stewart, J. P., Bazzurro, P., Lanzo, G., & Mollaioli, F. (2009). A Comparison of NGA Ground-Motion Prediction Equations to Italian Data. *Bulletin of the Seismological Society of America*, 99(5), 2961-2978. <https://doi.org/10.1785/0120080133>
- Scherbaum, F., Delavaud, E., & Riggelsen, C. (2009). Model Selection in Seismic Hazard Analysis: An Information-Theoretic Perspective. *Bulletin of the Seismological Society of America*, 99(6), 3234-3247. <https://doi.org/10.1785/0120080347>
- Scherbaum, F., Bommer, J., Bungum, H., & Cotton, F. (2005). Composite Ground-Motion Models and Logic Trees: Methodology, Sensitivities, and Uncertainties. *BULLETIN OF THE SEISMOLOGICAL SOCIETY OF AMERICA*, 95, 1575-1593. <https://doi.org/10.1785/0120040229>
- Scherbaum, F., Cotton, F., & Smit, P. (2004). On the Use of Response Spectral-Reference Data for the Selection and Ranking of Ground-Motion Models for Seismic-Hazard Analysis in

- Regions of Moderate Seismicity: The Case of Rock Motion. *Bulletin of the Seismological Society of America*, 94(6), 2164-2185. <https://doi.org/10.1785/0120030147>
- Servicio Geológico Colombiano. (1993). Red Sismologica Nacional de Colombia. <https://doi.org/10.7914/SN/CM>
- Servicio Geológico Colombiano. (2024). SGC - Sismo Generalidades. Consultado el 19 de enero de 2024, desde <https://www.sgc.gov.co/detalleevento/SGC2024bhxvaw/resumen>
- Shahidzadeh, M. S., & Yazdani, A. (2017). A Bayesian Updating Applied to Earthquake Ground-Motion Prediction Equations for Iran. *Journal of Earthquake Engineering*, 21(2), 290-324. <https://doi.org/10.1080/13632469.2016.1158754>
- Stafford, P. J. (2019). Continuous integration of data into ground-motion models using Bayesian updating. *Journal of Seismology*, 23(1), 39-57. <https://doi.org/10.1007/s10950-018-9792-3>
- Taboada, A., Rivera, L. A., Fuenzalida, A., Cisternas, A., Philip, H., Bijwaard, H., Olaya, J., & Rivera, C. (2000). Geodynamics of the northern Andes: Subductions and intracontinental deformation (Colombia). *Tectonics*, 19(5), 787-813. <https://doi.org/10.1029/2000TC900004>
- Thingbaijam, K. K. S., Martin Mai, P., & Goda, K. (2017). New Empirical Earthquake Source-Scaling Laws. *Bulletin of the Seismological Society of America*, 107(5), 2225-2246. <https://doi.org/10.1785/0120170017>
- Vehtari, A., Gelman, A., & Gabry, J. (2017). Practical Bayesian model evaluation using leave-one-out cross-validation and WAIC. *Statistics and Computing*, 27(5), 1413-1432. <https://doi.org/10.1007/s11222-016-9696-4>
- Vehtari, A., Gelman, A., Simpson, D., Carpenter, B., & Bürkner, P.-C. (2021). Rank-Normalization, Folding, and Localization: An Improved $\hat{R}$ for Assessing Convergence of MCMC (with Discussion) [Publisher: International Society for Bayesian Analysis]. *Bayesian Analysis*, 16(2), 667-718. <https://doi.org/10.1214/20-BA1221>
- Wang, M., & Takada, T. (2009). A Bayesian Framework for Prediction of Seismic Ground Motion. *Bulletin of the Seismological Society of America*, 99(4), 2348-2364. <https://doi.org/10.1785/0120080017>
- Wright, R., Kramer, S., & Culver, C. (1973). *Earthquake Hazard For Buildings, Building Practices for Disaster Mitigation* (San Francisco, CA, USA). U.S. Department of Commerce, National Bureau of Standards.
- Yamanaka, Y., & Tanioka, Y. (2021). Study on the 1906 Colombia-Ecuador Megathrust Earthquake Based on Tsunami Waveforms Observed at Tide Gauges: Release Variation of Accumulated Slip Deficits in the Source Area. *Journal of Geophysical Research: Solid Earth*, 126(5), e2020JB021375. <https://doi.org/10.1029/2020JB021375>
- Zhao, J. X., Zhang, J., Asano, A., Ohno, Y., Oouchi, T., Takahashi, T., Ogawa, H., Irikura, K., Thio, H. K., Somerville, P. G., Fukushima, Y., & Fukushima, Y. (2006). Attenuation Relations of Strong Ground Motion in Japan Using Site Classification Based on Predominant Period. *Bulletin of the Seismological Society of America*, 96(3), 898-913. <https://doi.org/10.1785/0120050122>