



**UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA CIVIL**

**CLASIFICACIÓN MEDIANTE PARÁMETROS INSTRUMENTALES DE LA
INTENSIDAD DE MERCALLI MODIFICADA**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL

PAMELA ANDREA OVIEDO VEGA

**PROFESOR GUÍA:
RUBÉN BOROSCHEK KRAUSKOPF**

**MIEMBROS DE LA COMISIÓN:
MARCOS ORCHARD CONCHA
JOÃO PEDRO SANTOS**

**SANTIAGO DE CHILE
AÑO 2017**

RESUMEN DE MEMORIA PARA OPTAR AL TÍTULO DE: Ingeniera Civil con mención en Estructuras, Construcción y Geotecnia.
POR: Pamela Andrea Oviedo Vega
FECHA: 31/03/2017
PROFESOR GUÍA: Rubén Boroschek Krauskopf

CLASIFICACIÓN MEDIANTE PARÁMETROS INSTRUMENTALES DE LA INTENSIDAD DE MERCALLI MODIFICADA

La evaluación de los daños y/o pérdidas en un sitio determinado ocurridos como consecuencia de un terremoto es un tema importante en el ámbito de la ingeniería sísmica. Las escalas de intensidades permiten identificar en primera instancia y en forma rápida el nivel de severidad del movimiento, pero estas son de carácter cualitativo ya que están basadas en la observación y el juicio humano. Por lo anterior, se han buscado relaciones entre los parámetros instrumentales asociados a un movimiento sísmico y las escalas de intensidades. En particular, este trabajo tiene como objetivo principal estimar la Intensidad de Mercalli Modificada (IMM) mediante el uso de parámetros instrumentales utilizando métodos estadísticos tanto de clasificación como de regresión. Además, se busca identificar que variables son las más influyentes en el valor de la escala de la Intensidad de Mercalli Modificada asignado luego de la ocurrencia de un sismo.

Para lograr los objetivos de este trabajo se utilizan dos métodos estadísticos que son clasificados dentro de lo que se conoce como Aprendizaje Automático (AA): Redes Neuronales Artificiales (RNA) y Regresión Logística Multinomial (RGM). Los parámetros instrumentales considerados son: Aceleración Máxima de Suelo (PGA), Velocidad Máxima de Suelo (PGV), duración fase fuerte, Intensidad de Arias (I_a), Intensidad Espectral de Housner (SI), Intensidad Instrumental de la Agencia Meteorológica de Japón (IJMA), velocidad absoluta acumulada (CAV), intensidad de cruces por cero (ν), frecuencia central, espectros de respuesta (S_a , S_v y S_d), distancia al hipocentro, profundidad hipocentro y fuente sismogénica.

Del desarrollo de este trabajo y el análisis de los resultados obtenidos, se tienen como conclusiones y observaciones principales que el método de RLM presenta un mejor desempeño que RNA. En cuanto a qué parámetros instrumentales son los más influyentes, se obtiene que son: $\log(\text{PGV})$, $\log(\text{PGA})$, $\log(I_a)$, $\log(\text{SI})$ e IJMA. El modelo generado mediante RLM ocupando solo estas variables arroja un mayor porcentaje de clasificación que ocupando todos los parámetros. Sin embargo, para ambos métodos el uso de cada variable por separado (las más influyentes) es levemente mejor que utilizar las cinco juntas, siendo la que mejor resultados entrega $\log(\text{PGV})$.

Por último, de los resultados se observa que el conocimiento a priori del tipo de suelo no es influyente en los resultados.

A mi familia y amigos...

Agradecimientos

En primer lugar, le doy las gracias a TODA mi familia por todo el apoyo que he recibido durante, no solo el transcurso de esta carrera, sino durante mis 26 años. Quiero agradecer a mis padres, hermanos, abuelitos, tías y primos.

En particular, a mi papá por ser mi ejemplo a seguir; a mi mamá por enseñarme a ver la vida de otra forma; a mi hermana por estar siempre conmigo, y por su gran aporte a este trabajo, ya que sin su ayuda y la de Roberto, los gráficos de esta memoria serían muy feos; a mi abuelita “*Oba*” por siempre estar rezándole a los ángeles para que me fuera bien en todos los controles; a mis tías por también estar siempre preocupadas que estuviera bien, dándome muchas veces Flores de Bach, para que las cosas se me hicieran un poquito más fáciles.

Agradezco a mis amigos del colegio (*Carli, Coté, Isi, Pazi y Tóbal*), quienes siguen presentes en mi vida, y siempre dándome su apoyo cuando lo he necesitado. Y no solo en los momentos más complicados, sino que son los que muchas veces me han ayudado a distraerme y olvidarme un poco de la universidad; a mis amigos de la universidad: *Abelits, Belén, Coni, Enzo, Magits, Michelle, Nata y Roberto*; en especial a la *Coni*, a quien ya conozco hace 8 años, y espero que sigamos siendo amigas por mucho tiempo más.

También me gustaría darle las gracias a mis compañeros de carrera, que sin ellos hubiera sido mucho más difícil todo. Por hacer más agradables las clases, el estudio, las horas haciendo tareas, informes, ejercicios, etc. A los de “*La Pecera*”, entre muchas otras cosas. A la *Tía Isabel*, que es una muy linda persona, que agradezco poder haber conocido, y gracias a sus *calzones rotos*, que esperaba todas las tardes.

Por otro lado, agradezco a los profesores de la carrera, a todos, ya que cada uno, de una u otra forma, ha sido un aporte a mi formación como profesional y persona. En especial gracias a mi profesor guía Rubén Boroschek por haber confiado en mí para desarrollar este trabajo y por toda la paciencia que me ha tenido; a mis profesores de comisión Marcos Orchard y João Pedro Santos, ya que no creo haber podido tener mejores profesores de comisión: siempre dispuestos a ayudarme, respuestas casi inmediatas a mis preguntas e interés por mi trabajo. Y por último, al profesor Juan Felipe Beltrán ya que sin su ayuda no hubieran sido casi 8 años, sino que más.

Y por último, me doy las gracias a mí, por creer en mi misma, por creer que era capaz de estudiar esta carrera y demostrarlo, por no dejar que situaciones difíciles de la vida me hicieran no seguir avanzando en ella y por ser quien soy.

Tabla de Contenido

CAPÍTULO 1: INTRODUCCIÓN	1
1.1 Objetivos	2
1.3 Alcances	2
1.2 Metodología	4
CAPÍTULO 2: ANTECEDENTES.....	5
2.1 Intensidad de Mercalli Modificada.....	5
2.2 Parámetros Instrumentales.....	7
2.2.1 Intensidad de Arias	7
2.2.2 Velocidad Absoluta Acumulada.....	7
2.2.3 Intensidad Espectral de Housner	8
2.2.4 Aceleración Máxima del Suelo y Velocidad Máxima del Suelo.....	9
2.2.5 Duración Movimiento Fuerte	9
2.2.6 Intensidad Sísmica de la Agencia Meteorológica de Japón	10
2.2.7 Espectros de respuesta.....	11
2.2.8 Cruces por cero	12
2.2.9 Contenido de frecuencia	12
2.2.10 Fuente Sismogénica	12
2.2.11 Distancia al hipocentro.....	14
2.2.12 Profundidad hipocentro	14
CAPÍTULO 3: MÉTODOS DE REGRESIÓN Y/O CLASIFICACIÓN.....	15
3.1 Redes Neuronales Artificiales.....	16
3.2 Regresión Logística Multinomial	20
3.3 Mínimos Cuadrados Parciales (PLS).....	22
CAPÍTULO 4: DETERMINACIÓN DE PARÁMETROS A PARTIR DE REGISTROS DE ACELERACIÓN.....	25
4.2 Análisis parámetros.....	28
CAPÍTULO 5: PRUEBA DE MÉTODOS DE CLASIFICACIÓN	32
5.1 Redes Neuronales Artificiales	32
5.1.1 Manejo del set de datos	32
5.1.2 Entrenamiento de la red.....	33
5.1.3 Prueba de la Red Neuronal	36
5.2 Regresión Logística Multinomial	38
5.2.1 Manejo del set de datos	38
5.2.2 Método de Regresión Logística Multinomial en Matlab.....	40
5.2.3 Prueba de la Regresión Logística Multinomial	40

5.3 Resumen Resultados	43
CAPÍTULO 6: APLICACIÓN DE MÉTODOS DE CLASIFICACIÓN	44
6.1 Redes Neuronales Artificiales.....	46
6.1.1 Red Neuronal Artificial utilizando 16 parámetros	46
6.1.2 Red Neuronal Artificial considerando un parámetro a la vez	58
6.2 Regresión Logística Multinomial	64
6.2.1 Clasificación con 17 clases	64
6.2.2 Clasificación con 5 clases	77
6.2.3 Clasificación con 2 clases	86
6.2.4 Clasificación considerando un parámetro a la vez.....	92
6.3 Resumen y Análisis de Resultados.....	101
6.3 Nuevos Resultados	104
6.3.1 Nuevo Modelo	104
6.3.2 Análisis error entre IMM modelo e IMM ONEMI	107
CAPÍTULO 7: COMENTARIOS Y CONCLUSIONES.....	113
CAPÍTULO 8: RECOMENDACIONES Y FUTURO TRABAJO	118
Bibliografía	120
ANEXO A: HISTOGRAMA VARIABLE DEPENDIENTE Y DE VARIABLES INDEPENDIENTES	124
ANEXO B: RELACIÓN ENTRE INTENSIDAD DE MERCALLI MODIFICADA Y CADA UNA DE LAS VARIABLES INDEPENDIENTES.....	148
ANEXO C: RELACIÓN ENTRE LAS VARIABLES INDEPENDIENTES.....	153

Índice de Tablas

Tabla 1: Parámetros de entrada	27
Tabla 2: Transformación de números romanos a números arábigos de los valores de IMM	32
Tabla 3: Valores vector de salida para Regresión Logística	38
Tabla 4: Valores vector de salida para Regresión Logística Multinomial agrupados en 5 clases.....	39
Tabla 5: Resumen porcentajes de clasificación de registros (RNA por parámetro)	43
Tabla 6: Conjunto de datos y división en sub conjuntos de entrenamiento, validación y prueba para Redes Neuronales Artificiales. Casos según criterio 1.	44
Tabla 7: Conjunto de datos y división en sub conjuntos de entrenamiento, validación y prueba para Regresión Logística Multinomial. Casos según criterio 1.	44
Tabla 8: Modelos según los criterios que se aplican en ellos	47
Tabla 9: Resumen porcentajes de clasificación según caso por tipo de suelo y casos según criterios utilizados	48
Tabla 10: Porcentaje de registros clasificados correctamente y/o con un valor mayor....	50
Tabla 11: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI	50
Tabla 12: Modelos según los criterios que se aplican en ellos	54
Tabla 13: Resumen porcentajes de clasificación según caso por tipo de suelo y casos según criterio utilizado.....	54
Tabla 14: Porcentaje de registros clasificados correctamente y/o con un valor mayor	57
Tabla 15: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI	57
Tabla 16: Resumen porcentajes de clasificación de registros (RNA 16 parámetros).....	57
Tabla 17: Modelos según los criterios que se aplican en ellos	58
Tabla 18: log(PGA)	58
Tabla 19: log(PGV)	58
Tabla 20: log(Ia).....	59
Tabla 21: log(SI)	59
Tabla 22: IJMA.....	59
Tabla 23: Resumen porcentajes de clasificación de registros (RNA por parámetro)	59
Tabla 24: Porcentaje de registros clasificados correctamente y/o con un valor mayor ...	62
Tabla 25: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI	62
Tabla 26: Regresión entre valor IMM salida del modelo y valor IMM informado por la ONEMI	63
Tabla 27: Pesos entre neuronas de la capa entrada y neuronas de la capa oculta	63

Tabla 28: Pesos entre neuronas de la capa oculta y neurona de la capa salida	63
Tabla 29: Valores vector de salida para Regresión Logística agrupados en 2 clases	64
Tabla 30: Modelos según los criterios que se aplican en ellos	64
Tabla 31: Resumen porcentajes de clasificación según caso y modificaciones	66
Tabla 32: Porcentaje de registros clasificados correctamente y/o con un valor mayor ...	72
Tabla 33: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI	72
Tabla 34: Modelos según los criterios que se aplican en ellos	73
Tabla 35: Resumen porcentajes de clasificación según caso y modificaciones	73
Tabla 36: Porcentaje de registros clasificados correctamente y/o con un valor mayor ...	76
Tabla 37: Porcentaje de registros clasificados con máximo 1 grado por sobre el valor informado por la ONEMI	76
Tabla 38: Resumen porcentajes de clasificación de registros RLM 17 clases	76
Tabla 39: Modelos según los criterios que se aplican en ellos	77
Tabla 40: Resumen porcentajes de clasificación según caso y criterios	78
Tabla 41: Modelos según los criterios que se aplican en ellos	84
Tabla 42: Resumen porcentajes de clasificación según caso y modificaciones	84
Tabla 43: Modelos según los criterios que se aplican en ellos	86
Tabla 44: Resumen porcentajes de clasificación según caso y modificaciones	87
Tabla 45: Resumen resultados Regresión Logística Multinomial considerando 2 clases	92
Tabla 46: Porcentaje de los registros pertenecientes a la clase “ $\leq V$ ” para el set de entrenamiento y prueba	92
Tabla 47: Modelos según los criterios que se aplican en ellos.....	92
Tabla 48: Resumen porcentajes de clasificación de registros (RLM por parámetro)	93
Tabla 49: log(PGA).....	94
Tabla 50: log(PGV).....	95
Tabla 51: log(Ia).....	96
Tabla 52: log(SI).....	97
Tabla 53: IJMA.....	97
Tabla 54: Porcentaje de registros clasificados correctamente y/o con un valor mayor .	100
Tabla 55: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI	100
Tabla 56: Resumen porcentajes de clasificación de registros (RNA 16 parámetros)	101
Tabla 57: Resumen porcentajes de clasificación de registros RLM 17 clases	101
Tabla 58: Resumen porcentajes de clasificación de registros (RNA por parámetro)	102
Tabla 59: Resumen porcentajes de clasificación de registros (RL por parámetro)	102
Tabla 60: Resumen resultados RLM considerando 2 clases	103

Tabla 61: Resumen porcentajes de clasificación de registros (RLM por parámetro)	103
Tabla 62: Resumen porcentajes de clasificación de registros (RNA por parámetro)	103
Tabla 63: Resumen porcentajes de clasificación nuevos modelos	105
Tabla 64: Resumen porcentajes de clasificación de registros RNA	105
Tabla 65: Resumen porcentajes de clasificación RLM 17 clases, por parámetro y 5 nuevos parámetros	106
Tabla 66: Resumen resultados RLM considerando 2 clases	106
Tabla 67: Resumen porcentajes de clasificación de registros (RNA 16 parámetros)	114

Índice de Figuras

Figura 1: (a) Definición de la Intensidad Espectral de Housner (SI), la cual es calculada como el área bajo la curva del Espectro de Respuesta de Velocidad con un amortiguamiento de 20%, entre los periodos de 0.1 a 2.5 segundos, dividido por el largo del intervalo del período. (b) Traza de SI calculada para cada rotación de las componentes de aceleración horizontales (EW y NS) de los registros de la estación JMA Kobe para el terremoto de Kobe en el año 1995. (Fuente: Karim y Yamasaki, 2001 [16]).	8
Figura 2: Definición genérica de duración de movimiento fuerte de un acelerograma. (Fuente: Elaboración Propia).....	9
Figura 3: Cálculo de la Intensidad Sísmica Instrumental JMA, la cual es obtenida (a) aplicando un filtro de pasa-banda en el dominio de las frecuencias y (b) considerando el efecto de duración $\tau(a)$ de PGA, el cual es obtenido en dominio del tiempo (c) sumando los segmentos de tiempo que exceden el valor de referencia de PGA de la suma vectorial de los tres componentes de los registros de aceleración (Fuente: Karim y Yamasaki, 2001) [16].	11
Figura 4: Perfil esquemático con la sismicidad del catálogo NEIC, registrada entre 1973 y 2007 de la zona en la latitud 33.5°S (considerando 0.5° en dirección norte y sur), cada punto representa un sismo, independiente de su magnitud o fecha de ocurrencia. El color azulado representa la posición esquemática de la placa de Nazca y verde, la placa Sudamericana. Las líneas punteadas indican la posición de las principales fuentes sismogénicas: a. interplaca tipo ‘thrust’; b. intraplaca de profundidad intermedia; c. corticales y d. ‘outer-rise’. (Fuente: Leyton, Ruiz y Sepúlveda, 2010) [22]	13
Figura 5: Esquema que muestra la distancia que corresponde a la profundidad del hipocentro. (Fuente: universobservado.blogspot.cl).....	14
Figura 6: Esquema neurona en RNA y analogía con neurona biológica. (Fuente: Universidad de Sevilla [38])	17
Figura 7: Ejemplos funciones de activación. (Fuente: Universidad de Sevilla [38])	17
Figura 8: Esquema RNA tipo feed-forward backpropagation. (Fuente: www.medicinaintensiva.org)	18
Figura 9: Representación de under-fitting, appropriate-fitting y over-fitting. (a) El ajuste de la línea azul es muy simple para explicar la varianza de los datos, (b) La línea azul representa un modelo que puede ser más fácilmente generalizado para otros datos, (c) La línea azul se ajusta perfectamente a los valores del conjunto de entrenamiento, pero	

luego es difícil que se pueda ocupar para otro conjunto de datos. (Fuente: Universidad de Sevilla [16])	19
Figura 10: Control del error del set de validación para evitar el sobre-entrenamiento. (Fuente: Matlab)	20
Figura 11: Gráfico función inversa del logit	22
Figura 12: Representación Geométrica de la regresión mediante Mínimos Cuadrados Parciales. (Fuente: www.nature.com).....	23
Figura 13: Loading plot obtenido de realizar PLS. Variables encerradas en cuadro rojo son candidatas a ser eliminadas. (Fuente: Elaboración Propia en Matlab).....	24
Figura 14: Distribución a lo largo de Chile de estaciones de las que se obtuvieron los registros. (Ordenes, 2017) [20].....	25
Figura 15: Excel con lista de los 1122 registros	26
Figura 16: Excel que contiene el valor de la escala IMM de todos los sismos sensibles ocurridos entre los años 2007 a 2015	26
Figura 17: Comparación relación entre PGA-IMM y PGV-IMM con y sin uso de logaritmo en base 10	29
Figura 18: Comparación relación entre Ia-IMM, SI-IMM y CAV-IMM con y sin uso de logaritmo en base 10	30
Figura 19: Comparación relación entre Profundidad-IMM, Distancia Hipocentro-IMM y Frecuencia Central-IMM con y sin uso de logaritmo en base 10	31
Figura 20: Estructura Red Neuronal. (Fuente: Matlab, resultado entrenamiento de la RNA).....	34
Figura 21: Interfaz entrenamiento Redes Neuronales en Matlab. (Fuente: Matlab, resultado entrenamiento de la RNA)	35
Figura 22: Diferencia entre IMM predicho e IMM informado por la ONEMI. Red Neuronal Artificial.....	37
Figura 23: Predicción de IMM vs IMM ONEMI. Red Neuronal Artificial.	37
Figura 24: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases.	41
Figura 25: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases.....	41
Figura 26: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases.....	42
Figura 27: Predicción de IMM vs IMM ONEMI. RLM 5 clases.	42
Figura 28: <i>Loading Plot</i> , define el nivel de información que aporta cada variable para realizar la regresión. Los parámetros que se encuentran encerrados por el cuadro verde son las que mayor información de la varianza de los datos aportan: log(PGA), log(PGV), log(Ia), log(SI) e IJMA.	46
Figura 29: Estructura Red Neuronal	47
Figura 30: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) Caso 0, (b) Caso 2, (c) Caso 3, (d) Caso 4. Método RNA.	49

Figura 31: Porcentaje de clasificación por rango, para cada uno de los casos según tipo de suelo. Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.	51
Figura 32: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 0..	51
Figura 33: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 2..	52
Figura 34: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 3..	52
Figura 35: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 4..	52
Figura 36: Regresión Lineal. Caso 0	53
Figura 37: Regresión Lineal. Caso 2	53
Figura 38: Regresión Lineal. Caso 3	53
Figura 39: Regresión Lineal. Caso 4	53
Figura 40: Diferencia entre IMM predicho e IMM informado por la ONEMI. RNA Caso Extra.	54
Figura 41: Predicción de IMM vs IMM ONEMI. RNA Caso Extra.	55
Figura 42: Regresión lineal entre valor IMM ONEMI e IMM predicho. Caso Extra.	55
Figura 43: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(SI), (e) IJMA. RNA por parámetro.	60
Figura 44: Predicción de IMM vs IMM ONEMI. RNA por parámetro (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(SI), (e) IJMA. RNA por parámetro.	61
Figura 45: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases. Caso 0.	67
Figura 46: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 0.	68
Figura 47: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases, Caso 2.	68
Figura 48: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 2.	69
Figura 49: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases, Caso 3.	69
Figura 50: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 3.	70
Figura 51: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 17 clases,	70
Figura 52: Predicción de IMM vs IMM ONEMI. RLM 17 clases, Caso 4.	71
Figura 53: Diferencia entre valor de la escala de la IMM predicho por el modelo y valor informado por la ONEMI. Modelo generado mediante RLM considerando 17 clases, Caso Extra.	74
Figura 54: Predicción de IMM vs IMM ONEMI. RLM 17 clases, Caso Extra.	74
Figura 55: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases,	79

Figura 56: Predicción de IMM vs IMM ONEMI. RLM5 clases, Caso 0.	80
Figura 57: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso 2.	80
Figura 58: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 2.....	81
Figura 59: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases,.....	81
Figura 60: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 3.	82
Figura 61: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases,.....	82
Figura 62: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 4.....	83
Figura 63: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases,.....	85
Figura 64: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso Extra.....	85
Figura 65: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases.....	88
Figura 66: Predicción de IMM vs IMM ONEMI. RLM 2 clases.	88
Figura 67: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases.....	89
Figura 68: Predicción de IMM vs IMM ONEMI. RLM 2 clases.	89
Figura 69: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases.....	90
Figura 70: Predicción de IMM vs IMM ONEMI. RLM 2 clases.	90
Figura 71: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases.....	91
Figura 72: Predicción de IMM vs IMM ONEMI. RLM 2 clases.	91
Figura 73: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(SI), (e) IJMA. Utilizando RLM.	98
Figura 74: Predicción de IMM vs IMM ONEMI. RLM por parámetro (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(SI), (e) IJMA. Utilizando RLM.	99
Figura 75: Loading plot donde se muestra qué variable se considera de cada uno de los "grupos" visibles.	104
Figura 76: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). Modelo de RNA que considera 16 variables predictoras.....	108
Figura 77: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). RNA considerando log(PGA) como variable predictora.	109
Figura 78: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). Modelo RLM 17 Clases.....	110
Figura 79: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). Modelo RLM 2 clases.....	111

Figura 80: Gráfico que muestra relación entre $\log(\text{PGA})$ y error del modelo (arriba), y $\log(\text{PGV})$ y error del modelo (abajo). Modelo RLM con $\log(\text{PGV})$ como variable predictora.	112
Figura 81: Histograma Intensidad de Mercalli Modificada	118

Índice de Figuras Anexo A

Figura A. 1: Histograma Intensidad de Mercalli Modificada	125
Figura A. 2: Histograma Mecanismo Focal	125
Figura A. 3: Histograma Tipo de Suelo.....	126
Figura A. 4: Histograma distancia al hipocentro para sismos menores a 6M y distancia de ruptura para sismos mayores a 6M.....	126
Figura A. 5: Histograma Intensidad de Housner	127
Figura A. 6: Histograma IJMA.....	127
Figura A. 7: Histograma PGA Dirección Horizontal	128
Figura A. 8: Histograma PGV Dirección Horizontal	128
Figura A. 9: Histograma Intensidad de Arias Dirección Horizontal.....	129
Figura A. 10: Histograma por partes Intensidad de Arias Dirección Horizontal	130
Figura A. 11: Histograma Velocidad Absoluta Acumulada Dirección Horizontal	131
Figura A. 12: Histograma CAV Dirección Horizontal por partes	132
Figura A. 13: Histograma CAV Dirección Horizontal sub-partes	133
Figura A. 14: Histograma Cruces por Cero Dirección Horizontal.....	134
Figura A. 15: Histograma Frecuencia Central Dirección Horizontal	134
Figura A. 16: Histograma Espectro de Desplazamiento Dirección Horizontal. Periodo $T=0.2$ [s]......	135
Figura A. 17: Histograma Espectro de Desplazamiento Dirección Horizontal. Periodo $T=1$ [s]......	135
Figura A. 18: Histograma Espectro de Velocidad Dirección Horizontal. Periodo $T=0.2$ [s]......	136
Figura A. 19: Histograma Espectro de Velocidad Dirección Horizontal. Periodo $T=1$ [s].	136
Figura A. 20: Histograma Espectro de Aceleración Dirección Horizontal. Periodo $T=0.2$ [s]......	137
Figura A. 21: Histograma Espectro de Aceleración Dirección Horizontal. Periodo $T=1$ [s].	137
Figura A. 22: Histograma PGA Dirección Vertical	138
Figura A. 23: Histograma PGV Dirección Vertical	138
Figura A. 24: Histograma Intensidad de Arias Dirección Vertical.....	139
Figura A. 25: Histograma Intensidad de Arias Dirección Vertical por partes.	140

Figura A. 26: Histograma Velocidad Absoluta Acumulada Dirección Vertical	141
Figura A. 27: Histograma CAV Dirección Vertical por partes	142
Figura A. 28: Histograma CAV Dirección Vertical sub-partes	143
Figura A. 29: Histograma Cruces por Cero Dirección Vertical	144
Figura A. 30: Histograma Frecuencia Central Dirección vertical	144
Figura A. 31: Histograma Espectro de Desplazamiento Dirección Vertical. Periodo T=0.2 [s].	145
Figura A. 32: Histograma Espectro de Desplazamiento Dirección Vertical. Periodo T=1 [s].	145
Figura A. 33: Histograma Espectro de Velocidad Dirección Vertical. Periodo T=0.2 [s].	146
Figura A. 34: Histograma Espectro de Velocidad Dirección Vertical. Periodo T=1 [s]. .	146
Figura A. 35: Histograma Espectro de Aceleración Dirección Vertical. Periodo T=0.2 [s].	147
Figura A. 36: Histograma Espectro de Aceleración Dirección Vertical. Periodo T=1 [s].	147

Índice de Figuras Anexo B

Figura B. 1: Relación entre IMM y (a) Fuente Sismogénica, (b) profundidad, (c) Distancia hipocentro, (d) log(PGA), (e) log(PGV), (f) Duración movimiento fuerte	149
Figura B. 2: Relación entre IMM y (a) log(Ia), (b) log(SI), (c) IJMA, (d) CAV, (e) Espectro de Desplazamiento T=0.2 [s], (f) Espectro de Desplazamiento T=1[s]	150
Figura B. 3: Relación de IMM y (a) Espectro de Velocidad T=0.2 [s], (b) Espectro de Velocidad T=1 [s], (c) Espectro de Aceleración T=0.2 [s], Espectro de Aceleración T=1 [s], (e) Cruces por Cero, (f) Frecuencia Central.....	151
Figura B. 4: Relación de IMM y Tipo de Suelo	152

Índice de Figuras Anexo C

Figura C. 1: Relación entre Fuente Sismogénica y (a) Profundidad, (b) Distancia Hipocentro o Ruptura, (c) log(SI), (d) IJMA.....	154
Figura C. 2: Relación entre Fuente Sismogénica y (a) log(PGA) horizontal, (b) log(PGA) vertical, (c) log(PGV) horizontal, (d) log(PGV) vertical, (e) log(Ia) horizontal, (f) log(Ia) vertical	155
Figura C. 3: Relación entre Fuente Sismogénica y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.	156
Figura C. 4: Relación entre Fuente Sismogénica y (a) log(CAV) Horizontal, (b) log(CAV) Vertical, (c) Espectro de Desplazamiento Horizontal T=0.2 [s], (d) Espectro de Desplazamiento Vertical T=0.2 [s], (e) Espectro de Desplazamiento Horizontal T=1 [s], (f) Espectro de Desplazamiento Vertical T=1 [s].	157

Figura C. 5: Relación entre Fuente Sismogénica y (a) Espectro de Velocidad Horizontal T=0.2 [s], (b) Espectro de Velocidad Vertical T=0.2 [s], (c) Espectro de Velocidad Horizontal T=1 [s], (d) Espectro de Velocidad Vertical T=1 [s].	158
Figura C. 6: Relación entre Fuente Sismogénica y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].	159
Figura C. 7: Relación entre Profundidad y (a) Distancia Hipocentro o Ruptura, (b) Intensidad de Housner, (c) IJMA, (d) log(PGA) horizontal, (e) log(PGA) vertical.	160
Figura C. 8: Relación entre Profundidad y (a) log(PGV) horizontal, (b) log(PGV) vertical, (c) Duración Mov. Fuerte horizontal, (d) Duración Mov. Fuerte Vertical, (e) log(Ia) horizontal, (f) log(Ia) vertical.....	161
Figura C. 9: Relación entre Profundidad y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical, (e) log(CAV) Horizontal, (f) log(CAV) Vertical.	162
Figura C. 10: Relación entre Profundidad y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].	163
Figura C. 11: Relación entre Profundidad y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].	164
Figura C. 12: Relación entre Distancia Hipocentro o Ruptura y (a) log(SI), (b) IJMA, (c) log(PGA) Horizontal, (d) log(PGA) Vertical, (e) log(PGV) Horizontal, (f) log(PGV) Vertical.....	165
Figura C. 13: Relación entre Distancia Hipocentro o Ruptura y (a) log(Ia) Horizontal, (b) log(Ia) Vertical, (c) Duración Mov. Fuerte Horizontal, (d) Duración Mov. Fuerte Vertical, (e) Cruces por Cero Horizontal, (f) Cruces por Cero Vertical.....	166
Figura C. 14: Relación entre Distancia Hipocentro o Ruptura y (a) Frecuencia Central Horizontal, (b) Frecuencia Central Vertical, (c) log(CAV) Horizontal, (d) log(CAV) Vertical.....	167
Figura C. 15: Relación entre Distancia Hipocentro o Ruptura y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].	168
Figura C. 16: Relación entre Distancia Hipocentro o Ruptura y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].	169
Figura C. 17: Relación entre log(PGA) Horizontal y (a) log(PGA) Vertical, (b) log(PGV) Horizontal, (c) log(PGV) Vertical, (d) Duración Mov. Fuerte Horizontal, (e) Duración Mov. Fuerte Vertical.....	170

Figura C. 18: Relación entre log(PGA) Horizontal y (a) log(Ia) Horizontal, (b) log(Ia) Vertical, (c) log(SI), (d) IJMA, (e) log(CAV) Horizontal, (f) log(CAV) Vertical.....	171
Figura C. 19: Relación entre log(PGA) Horizontal y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].	172
Figura C. 20: Relación entre log(PGA) Horizontal y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]	173
Figura C. 21: Relación entre log(PGA) Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	174
Figura C. 22: Relación entre log(PGA) Vertical y (a) log(PGV) Horizontal, (b) log(PGV) Vertical, (c) Duración Mov. Fuerte Horizontal, (d) Duración Mov. Fuerte Vertical, (e) log(Ia) Horizontal, (f) log(Ia) Vertical.	175
Figura C. 23: Relación entre log(PGA) Vertical y (a) log(SI), (b) IJMA, (c) log(CAV) Horizontal, (d) log(CAV) Vertical	176
Figura C. 24: Relación entre log(PGA) Vertical y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].	177
Figura C. 25: Relación entre log(PGA) Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].	178
Figura C. 26: Relación entre log(PGA) Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	179
Figura C. 27: Relación entre log(PGV) Horizontal y (a) log(PGV) Vertical, (b) Duración Mov. Fuerte Horizontal, (c) Duración Mov. Fuerte Vertical, (d) log(Ia) Horizontal, (e) log(Ia) Vertical, (f) log(SI).....	180
Figura C. 28: Relación entre log(PGV) Horizontal y (a) IJMA, (b) log(CAV) Horizontal, (c) log(CAV) Vertical, (d) Espectro de Desplazamiento Horizontal T=0.2 [s], (e) Espectro de Desplazamiento Vertical T=0.2 [s]	181
Figura C. 29: Relación entre log(PGV) Horizontal y (a) Espectro de Desplazamiento Horizontal T=1 [s], (b) Espectro de Desplazamiento Vertical T=1 [s], (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s]..	182
Figura C. 30: Relación entre log(PGV) Horizontal y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s]	183

Figura C. 31: Relación entre $\log(\text{PGV})$ y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical	184
Figura C. 32: Relación entre $\log(\text{PGV})$ Vertical y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) $\log(I_a)$ Horizontal, (d) $\log(I_a)$ Vertical.....	185
Figura C. 33: Relación entre $\log(\text{PGV})$ Vertical y (a) $\log(\text{SI})$, (b) IJMA, (c) $\log(\text{CAV})$ Horizontal, (d) $\log(\text{CAV})$ Vertical.	186
Figura C. 34: Relación entre $\log(\text{PGV})$ Vertical y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s]	187
Figura C. 35: Relación entre $\log(\text{PGV})$ Vertical y (a) Espectro de Velocidad Horizontal $T=1$ [s], (b) Espectro de Velocidad Vertical $T=1$ [s], (c) Espectro de Aceleración Horizontal $T=0.2$ [s], (d) Espectro de Aceleración Vertical $T=0.2$ [s], (e) Espectro de Aceleración Horizontal $T=1$ [s], (f) Espectro de Aceleración Vertical $T=1$ [s]	188
Figura C. 36: Relación entre $\log(\text{PGV})$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	189
Figura C. 37: Relación entre Duración Mov. Fuerte Horizontal y (a) Duración Mov. Fuerte Vertical, (b) $\log(I_a)$ Horizontal, (c) $\log(I_a)$ Vertical, (d) $\log(\text{SI})$, (e) IJMA.	190
Figura C. 38: Relación entre Duración Mov. Fuerte Horizontal y (a) $\log(\text{CAV})$ Horizontal, (b) $\log(\text{CAV})$ Vertical, (c) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (d) Espectro de Desplazamiento Vertical $T=0.2$ [s], (e) Espectro de Desplazamiento Horizontal $T=1$ [s], (f) Espectro de Desplazamiento Vertical $T=1$ [s].....	191
Figura C. 39: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Velocidad Horizontal $T=0.2$ [s], (b) Espectro de Velocidad Vertical $T=0.2$ [s], (c) Espectro de Velocidad Horizontal $T=1$ [s], (d) Espectro de Velocidad Vertical $T=1$ [s], (e) Espectro de Aceleración Horizontal $T=0.2$ [s], (f) Espectro de Aceleración Vertical $T=0.2$ [s]	192
Figura C. 40: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Aceleración Horizontal $T=1$ [s], (b) Espectro de Aceleración Vertical $T=1$ [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.....	193
Figura C. 41: Relación entre Duración Mov. Fuerte Horizontal y (a) $\log(I_a)$ Horizontal, (b) $\log(I_a)$ Vertical, (c) $\log(\text{SI})$, (d) IJMA, (e) $\log(\text{CAV})$ Horizontal, (f) $\log(\text{CAV})$ Vertical	194
Figura C. 42: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s],	195
Figura C. 43: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Velocidad Horizontal $T=1$ [s], (b) Espectro de Velocidad Vertical $T=1$ [s], (c) Espectro de Aceleración Horizontal $T=0.2$ [s], (d) Espectro de Aceleración Vertical $T=0.2$ [s], (e)	

Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].	196
Figura C. 44: Relación entre Duración Mov. Fuerte Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	197
Figura C. 45: Relación entre log(Ia) Horizontal y (a) log(Ia) Vertical, (b) log(SI), log(CAV) Horizontal, (d) log(CAV) Vertical	198
Figura C. 46: Relación entre log(Ia) Horizontal y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s]	199
Figura C. 47: Relación entre log(Ia) Horizontal y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]	200
Figura C. 48: Relación entre log(Ia) Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	201
Figura C. 49: Relación entre log(Ia) Vertical y (a) log(SI), (b) IJMA, (c) log(CAV) Horizontal, (d) log(CAV) Vertical.	202
Figura C. 50: Relación entre log(Ia) Vertical y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s]	203
Figura C. 51: Relación entre log(Ia) Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]	204
Figura C. 52: Relación entre log(Ia) Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical	205
Figura C. 53: Relación entre log(SI) y (a) IJMA, (b) log(CAV) Horizontal, (c) log(CAV) Vertical, (d) Espectro de Desplazamiento Horizontal T=0.2 [s], (e) Espectro de Desplazamiento Vertical T=0.2 [s].	206
Figura C. 54: Relación entre log(SI) y (a) Espectro de Desplazamiento Horizontal T=1 [s], (b) Espectro de Desplazamiento Vertical T=1 [s], (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s]	207
Figura C. 55: Relación entre log(SI) y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].....	208
Figura C. 56: Relación entre log(SI) y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	209

Figura C. 57: Relación entre IJMA y (a) $\log(\text{CAV})$ Horizontal, (b) $\log(\text{CAV})$ Vertical, (c) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (d) Espectro de Desplazamiento Vertical $T=0.2$ [s], (e) Espectro de Desplazamiento Horizontal $T=1$ [s], (f) Espectro de Desplazamiento Vertical $T=1$ [s].	210
Figura C. 58: Relación entre IJMA y (a) Espectro de Velocidad Horizontal $T=0.2$ [s], (b) Espectro de Velocidad Vertical $T=0.2$ [s], (c) Espectro de Velocidad Horizontal $T=1$ [s], (d) Espectro de Velocidad Vertical $T=1$ [s].	211
Figura C. 59: Relación entre IJMA y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].	212
Figura C. 60: Relación entre IJMA y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	213
Figura C. 61: Relación entre $\log(\text{CAV})$ Horizontal y (a) $\log(\text{CAV})$ Vertical, (b) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (c) Espectro de Desplazamiento Vertical $T=0.2$ [s], (d) Espectro de Desplazamiento Horizontal $T=1$ [s], (e) Espectro de Desplazamiento Vertical $T=1$ [s].	214
Figura C. 62: Relación entre $\log(\text{CAV})$ Horizontal y (a) Espectro de Velocidad Horizontal $T=0.2$ [s], (b) Espectro de Velocidad Vertical $T=0.2$ [s], (c) Espectro de Velocidad Horizontal $T=1$ [s], (d) Espectro de Velocidad Vertical $T=1$ [s].	215
Figura C. 63: Relación entre $\log(\text{CAV})$ Horizontal y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].	216
Figura C. 64: Relación entre $\log(\text{CAV})$ Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	217
Figura C. 65: Relación entre $\log(\text{CAV})$ Vertical y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s].	218
Figura C. 66: Relación entre $\log(\text{CAV})$ Vertical y (a) Espectro de Velocidad Horizontal $T=1$ [s], (b) Espectro de Velocidad Vertical $T=1$ [s], (c) Espectro de Aceleración Horizontal $T=0.2$ [s], (d) Espectro de Aceleración Vertical $T=0.2$ [s], (e) Espectro de Aceleración Horizontal $T=1$ [s], (f) Espectro de Aceleración Vertical $T=1$ [s].	219
Figura C. 67: Relación entre $\log(\text{CAV})$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	220
Figura C. 68: Relación entre Espectro de Desplazamiento Horizontal $T=0.2$ [s] y (a) Espectro de Desplazamiento Vertical $T=0.2$ [s], (b) Espectro de Desplazamiento Horizontal $T=1$ [s], (c) Espectro de Desplazamiento Vertical $T=1$ [s], (d) Espectro de Velocidad Horizontal $T=0.2$ [s], (e) Espectro de Velocidad Vertical $T=0.2$ [s].	221
Figura C. 69: Relación entre Espectro de Desplazamiento Horizontal $T=0.2$ [s] y (a) Espectro de Velocidad Horizontal $T=1$ [s], (b) Espectro de Velocidad Vertical $T=1$ [s], (c) Espectro de Aceleración Horizontal $T=0.2$ [s], (d) Espectro de Aceleración Vertical	

T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].	222
Figura C. 70: Relación entre Espectro de Desplazamiento Horizontal T=0.2 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	223
Figura C. 71: Relación entre Espectro de Desplazamiento Vertical T=0.2 [s] y (a) Espectro de Desplazamiento Horizontal T=1 [s], (b) Espectro de Desplazamiento Vertical T=1 [s], (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s].	224
Figura C. 72: Relación entre Espectro de Desplazamiento Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].	225
Figura C. 73: Relación entre Espectro de Desplazamiento Vertical T=0.2 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	226
Figura C. 74: Relación entre Espectro de Desplazamiento Horizontal T=1 [s] y (a) Espectro de Desplazamiento Vertical T= [s], (b) Espectro de Velocidad Horizontal T=0.2 [s], (c) Espectro de Velocidad Vertical T=0.2 [s], (d) Espectro de Velocidad Horizontal T=1 [s], (e) Espectro de Velocidad Vertical T=1 [s].	227
Figura C. 75: Relación entre Espectro de Desplazamiento Horizontal T= [s] y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].	228
Figura C. 76: Relación entre Espectro de Desplazamiento Horizontal T=1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	229
Figura C. 77: Relación entre Espectro de Desplazamiento Vertical T=1 [s] y (a) Espectro de Velocidad Horizontal T=0.2 [s], (b) Espectro de Velocidad Vertical T=0.2 [s], (c) Espectro de Velocidad Horizontal T=1 [s], (d) Espectro de Velocidad Vertical T=1 [s], (e) Espectro de Aceleración Horizontal T=0.2 [s], (f) Espectro de Aceleración Vertical T=0.2 [s].	230
Figura C. 78: Relación entre Espectro de Desplazamiento Vertical T=1 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.	231
Figura C. 79: Relación entre Espectro de Velocidad Horizontal T=0.2 [s] y (a) Espectro de Velocidad Vertical T=0.2 [s], (b) Espectro de Velocidad Horizontal T=1 [s], (c) Espectro de Velocidad Vertical T=1 [s], (d) Espectro de Aceleración Horizontal T=0.2 [s], (e) Espectro de Aceleración Vertical T=0.2 [s].	232
Figura C. 80: Relación entre Espectro de Velocidad Horizontal T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.	233

Figura C. 81: Relación entre Espectro de Velocidad Vertical T=0.2 [s] y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s].....	234
Figura C. 82: Relación entre Espectro de Velocidad Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal. (f) Frecuencia Central Vertical.....	235
Figura C. 83: Relación entre Espectro de Velocidad Horizontal T=1 [s] y (a) Espectro de Velocidad Vertical T=1 [s], (b) Espectro de Aceleración Horizontal T=0.2 [s], (c) Espectro de Aceleración Vertical T=0.2 [s], (d) Espectro de Aceleración Horizontal T=1 [s], (e) Espectro de Aceleración Vertical T=1 [s].	236
Figura C. 84: Relación entre Espectro de Velocidad Horizontal T=1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Horizontal, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	237
Figura C. 85: Relación entre Espectro de Velocidad Vertical T=1 [s] y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].	238
Figura C. 86: Relación entre Espectro de Velocidad Vertical T=1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	239
Figura C. 87: Relación entre Relación entre Espectro de Aceleración Horizontal T=0.2 [s] y (a) Espectro de Aceleración Vertical T=0.2 [s], (b) Espectro de Aceleración Horizontal T=1 [s], (c) Espectro de Aceleración Vertical T=1 [s].....	240
Figura C. 88: Relación entre Relación entre Espectro de Aceleración Horizontal T=0.2 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.	241
Figura C. 89: Relación entre Relación entre Espectro de Aceleración Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.	242
Figura C. 90: Relación entre Espectro de Aceleración Horizontal T= 1 [s] y (a) Espectro de Aceleración Vertical T= 1 [s], (b) Cruces por Cero Horizontal, (c) Cruces por Cero Vertical, (d) Frecuencia Central Horizontal, (e) Frecuencia Central Vertical.	243
Figura C. 91: Relación entre Espectro de Aceleración Vertical T= 1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.....	244
Figura C. 92: Relación entre Cruces por Cero Horizontal y (a) Cruces por Cero Vertical, (b) Frecuencia Central Horizontal, (c) Frecuencia Central Vertical, (d) Relación entre Cruces por Cero Vertical y Frecuencia Central Horizontal, (e) Relación entre Cruces por Cero Vertical y Frecuencia Central Vertical.....	245
Figura C. 93: Relación entre Tipo de Suelo y (a) Fuente Sismogénica, (b) Profundidad, (c) Distancia Hipocentro o Ruptura, (d) log(SI), (e) IJMA.	246

Figura C. 94: Relación entre Tipo de Suelo y (a) log(PGA) Horizontal, (b) log(PGA) Vertical, (c) log(PGV) Horizontal, (d) log(PGV) Vertical, (e) log(Ia) Horizontal, (f) log(Ia) Vertical.....	247
Figura C. 95: Relación entre Tipo de Suelo y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.	248
Figura C. 96: Relación entre Tipo de Suelo y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s].	249
Figura C. 97: Relación entre Tipo de Suelo y (a) log(CAV) Horizontal, (b) log(CAV) Vertical, (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s].	250
Figura C. 98: Relación entre Tipo de Suelo y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].	251

CAPÍTULO 1: INTRODUCCIÓN

Un tema importante en el ámbito de la ingeniería sísmica es la determinación del daño y/o pérdidas en un sitio determinado ocurridos como consecuencia de un terremoto. Para esto se han desarrollado las escalas de intensidades, como un medio que permite identificar en primera instancia y rápidamente el nivel de severidad del movimiento. Las más utilizadas en el mundo son la Intensidad de Mercalli Modificada (MMI), la Escala de Intensidad de Medvédev-Sponheuer-Kárník (MSK), la Escala de Intensidad Sísmica de la Agencia Meteorológica de Japón (JMA)¹ y la Escala Macrosísmica Europea (EMS-98).

Si bien las intensidades macrosísmicas ayudan a proveer una rápida estimación de los daños y pérdidas, estas son cualitativas ya que están basadas en la observación y juicio humano, por lo que son inherentemente subjetivas. En el caso de IJMA, esta escala es instrumental y utiliza un parámetro único derivado de un registro del movimiento en tres ejes ortogonales.

En el último tiempo, con el fin de tener una medición automatizada de la intensidad luego de un terremoto, se han desarrollado muchos estudios que buscan poder objetivar las escalas de intensidad mediante relaciones con parámetros instrumentales. La mayoría de estas relaciones son producto de técnicas de regresión estadística convencionales y utilizan principalmente los valores de Peak Ground Acceleration (PGA) y Peak Ground Velocity (PGV) ([4], [39]). Otros utilizan parámetros adicionales como Intensidad del Espectro (SI) ([16]), Espectro de Aceleración de Fourier (FAS) ([25]), entre otros.

Estas técnicas, al ser relaciones lineales, consideran a la intensidad como una variable continua a pesar de que esta, en realidad, es discreta.

Los estudios más recientes han utilizado métodos estadísticos, que a través de regresiones no lineales o métodos de clasificación, relacionan la intensidad (en particular MMI) con parámetros instrumentales. Además, en estos estudios el número de variables independientes utilizados es mayor. Como ejemplo se puede leer el trabajo de Tselentis y Vladutu [29] donde mediante el método de Redes Neuronales Artificiales se relaciona IMM con magnitud (M), logaritmo de la distancia epicentral ($\log(R)$), PGV, $\log(PGV)$, espectro de aceleración (S_a), PGA, $\log(PGA)$, Intensidad de Arias (I_a) y Cumulative Absolute Velocity (CAV); a Álvarez, Hurtado y Bedoya-Ruiz [2], quienes a través de tres algoritmos estadísticos (Support Vector Regression, Multilayer Perceptrons y Genetic Programming) relacionan IMM con magnitud de momento (M_w), R , PGA y PGV; o a Davenport [7] que utiliza Redes Neuronales Artificiales para relacionar IMM con PGA, PGV, PGD, espectro de respuesta de aceleración, espectro de respuesta de velocidad, I_a e intensidad JMA.

En la misma línea de los últimos estudios mencionados, este trabajo busca objetivar la Escala de Mercalli Modificada (IMM) mediante la utilización de distintos enfoques. Un primer método estadístico que se puede utilizar como clasificador trabaja con relaciones no lineales (Redes Neuronales Artificiales). Un segundo método estadístico que utiliza

¹ JMA por su nombre en inglés: Japan Meteorology Agency

regresión lineal y luego estos resultados se utilizan para clasificar (Regresión Logística Multinomial). Se consideran como variables de entrada parámetros instrumentales obtenidos del procesamiento de los registros de la Oficina Nacional de Emergencia del Ministerio del Interior y Seguridad Pública de Chile (ONEMI). Los parámetros instrumentales que se utilizarán son: Aceleración Máxima de Suelo (PGA), Velocidad Máxima de Suelo (PGV), duración fase fuerte, Intensidad de Arias (I_a), Intensidad Espectral de Housner (SI), Intensidad Instrumental de la Agencia Meteorológica de Japón (IJMA), velocidad absoluta acumulada (CAV), intensidad de cruces por cero (v), frecuencia central, espectros de respuesta (S_a , S_v y S_d), distancia al epicentro, profundidad hipocentro y fuente sismogénica.

1.1 Objetivos

Objetivo General

Objetivar la Intensidad de Mercalli Modificada mediante el uso de parámetros instrumentales.

Objetivos Específicos

1. Identificar los parámetros más influyentes en el valor de la escala de la IMM asignado luego de la ocurrencia de un sismo.
2. Determinar cuál método de clasificación se comporta mejor en la predicción de la Intensidad de Mercalli asociada a un movimiento sísmico.

1.3 Alcances

A continuación se describe de manera resumida el contenido de cada capítulo del presente trabajo de título.

Capítulo I: Introducción

Introducción y motivación del tema, objetivo general y objetivos específicos, metodología de trabajo.

Capítulo II: Antecedentes

Presentación de recopilación bibliográfica relacionada con el tema de estudio. Descripción parámetros instrumentales escogidos y modo de obtención a partir de los registros de la ONEMI y RENADIC.

Capítulo III: Métodos Estadísticos

Descripción de los Métodos Estadísticos que se estudiarán: base teórica, limitaciones y usos.

Capítulo IV: Determinación de parámetros a partir de registros de aceleración

Descripción de características del set de datos, método de asociación de registros con IMM. Análisis de las variables independientes y su relación con la Intensidad de Mercalli Modificada.

Capítulo V: Prueba de métodos estadísticos

Evaluación del comportamiento de los Métodos de Clasificación y familiarización con estos, mediante el uso de datos artificiales.

Capítulo VI: Prueba de métodos estadísticos

Evaluación del desempeño y eficiencia de los modelos obtenidos mediante los diferentes métodos al clasificar la Intensidad de Mercalli Modificada utilizando los parámetros instrumentales (obtenidos en el capítulo IV) como variables independientes.

Capítulo VII: Conclusiones

Presentación de los resultados obtenidos, comentarios y conclusiones respecto a estos.

Capítulo VIII: Recomendaciones y futuro trabajo

De acuerdo a las conclusiones y al desarrollo de este trabajo, se recomienda lo que se considera puede mejorar los resultados obtenidos y una posible línea a seguir si se quisiera continuar desarrollando el tema tratado.

1.2 Metodología

Revisión de Antecedentes

Recopilar información relacionada con la Intensidad de Mercalli. Buscar si hasta hoy se ha utilizado la clasificación estadística para objetivar la escala. Recolectar métodos que se han aplicado para relacionar la IMM con algún parámetro medible instrumentalmente.

Selección de Parámetros (Pseudo) Independientes

Seleccionar los parámetros independientes que se utilizarán en el método de clasificación y/o regresión para determinar la variable dependiente (IMM).

Métodos de clasificación y/o regresión

Para cumplir con el objetivo de la memoria se trabaja con dos métodos estadísticos: Redes Neuronales Artificiales y Regresión Logística Multinomial. De esta forma se tendrán dos modelos y se podrá determinar cuál es el que se acerca más al valor buscado (variable dependiente), que en este trabajo corresponde a la escala de la Intensidad de Mercalli Modificada informada. Se analizarán las fortalezas y limitaciones de cada método.

Por otro lado, para familiarizarse con los dos métodos antes mencionados, se realiza una evaluación con casos ya controlados. Para esto se trabaja con los datos utilizados en webinars de MATLAB que tratan sobre estos métodos.

Calculo de los Parámetros Independientes de la Base de Datos

Se cuenta con una base de datos (registros ONEMI) de la cual se deben calcular los parámetros independientes que se utilizan (mencionados en la selección de parámetros).

Probar Métodos y Concluir

Cuando estén definidos los parámetros independientes se procede a probar cada método para generar resultados. Con la observación y análisis de lo obtenido se concluye si es posible objetivar la IMM y si es así, cuál es el método que se desempeña de mejor forma.

CAPÍTULO 2: ANTECEDENTES

2.1 Intensidad de Mercalli Modificada

En el año 1902 Giuseppe Mercalli introduce la Escala de Intensidad de Mercalli de 10 grados de intensidad basada en la Escala de Rossi-Forel publicada en 1883 también de 10 grados de intensidad. Este mismo año Adolfo Cancani aumenta la escala a 12 grados e indica la aceleración máxima para cada grado [38]. Posteriormente, en 1923 esta escala es modificada por Sieberg quien publicó la elaboración de la escala de Mercalli incluyendo el esquema de Cancani. Luego, en 1931 la escala fue mejorada y actualizada por Wood y Neumann, incluyendo nuevos aspectos que se debían considerar (efectos en estructuras altas, el comportamiento de vehículos motorizados y camiones pesados, efecto en el sistema de tuberías subterráneas, entre otros), eliminando los rangos de aceleración propuestos por Cancani e incluyendo una versión reducida [40]. Esta escala tuvo su última modificación el año 1958 por Richter.

Por todo lo anterior esta escala se conoce como la escala de Intensidad de Mercalli Modificada (IMM).

A continuación se presenta la definición utilizada en la Norma Chilena Oficial “NCh 3 of 61: Escala de Intensidad de los Fenómenos Sísmicos” la cual establece la escala de grados para apreciar la intensidad de los fenómenos sísmicos.

Grados de Intensidad	Especificación
I	No se advierte sino por unas pocas personas y en condiciones de perceptibilidad especialmente favorables.
II	Se percibe sólo por algunas personas en reposo, particularmente las ubicadas en los pisos superiores de los edificios.
III	Se percibe en los interiores de los edificios y casas. Sin embargo, muchas personas no distinguen claramente que la naturaleza del fenómeno es sísmica, por su semejanza con la vibración producida por el paso de un vehículo liviano. Es posible estimar la duración del sismo.
IV	Los objetos colgantes oscilan visiblemente. Muchas personas lo notan en el interior de los edificios aún durante el día. En el exterior, la percepción no es tan general. Se dejan oír las vibraciones de la vajilla, puertas y ventanas. Se sienten crujir algunos tabiques de madera. La sensación percibida es semejante a la que produciría el paso de un vehículo pesado. Los automóviles detenidos se mecen.
V	La mayoría de las personas lo perciben aún en el exterior. En los interiores, durante la noche, muchas personas despiertan. Los líquidos oscilan dentro de sus recipientes y aún pueden derramarse. Los objetos inestables se mueven o se vuelcan. Los péndulos de los relojes alteran su ritmo o se detienen. Es posible estimar la dirección principal del movimiento sísmico.
VI	Lo perciben todas las personas. Se atemorizan y huyen hacia el exterior. Se siente inseguridad para caminar. Se quiebran los vidrios de las ventanas, la vajilla y los objetos frágiles. Los juguetes, libros y otros objetos caen de los

	armarios. Los cuadros suspendidos de las murallas caen. Los muebles se desplazan o se vuelcan. Se producen grietas en algunos estucos. Se hace visible el movimiento de árboles y arbustos, o bien, se les oye crujir. Se siente el tañido de las campanas pequeñas de las iglesias y escuelas.
VII	Los objetos colgantes se estremecen. Se experimenta dificultad para mantenerse en pie. El fenómeno es percibido por los conductores de automóviles en marcha. Se producen daños de consideración en estructuras de albañilería mal construidas o mal proyectadas. Sufren daños menores (grietas) las estructuras corrientes de albañilería bien construidas. Se dañan los muebles. Caen trozos de estuco, ladrillos, parapetos, cornisas y diversos elementos arquitectónicos. Las chimeneas débiles se quiebran al nivel de la techumbre. Se producen ondas en los lagos; el agua se enturbia. Los terraplenes y taludes de arena o grava experimentan pequeños deslizamientos o hundimientos. Se dañan los canales de hormigón para regadío. Tañen todas las campanas.
VIII	Se hace difícil e inseguro el manejo de vehículos. Se producen daños de consideración y aún el derrumbe parcial en estructuras de albañilería bien construidas. En estructuras de albañilería especialmente bien proyectadas y construidas sólo se producen daños leves. Caen murallas de albañilería. Caen chimeneas en casas e industrias; caen igualmente monumentos, columnas, torres y estanques elevados. Las casas de madera se desplazan y aún se salen totalmente de sus bases. Los tabiques se desprenden. Se quiebran las ramas de los árboles. Se producen cambios en corrientes de agua y en la temperatura de vertientes y pozos. Aparecen grietas en el suelo húmedo, especialmente en la superficie de pendientes escarpadas.
IX	Se produce pánico general. Las estructuras de albañilería mal proyectadas o mal construidas se destruyen. Las estructuras corrientes de albañilería bien construidas se dañan y a veces se derrumban totalmente. Las estructuras de albañilería bien proyectadas y bien construidas se dañan seriamente. Los cimientos se dañan. Las estructuras de madera son removidas de sus cimientos. Sufren daños considerables los depósitos de agua, gas, etc. Se quiebran las tuberías (cañerías) subterráneas. Aparecen grietas aún en suelos secos. En las regiones aluviales, pequeñas cantidades de lodo y arena son expelidas del suelo.
X	Se destruye gran parte de las estructuras de albañilería de toda especie. Se destruyen los cimientos de las estructuras de madera. Algunas estructuras de madera bien construidas, incluso puentes, se destruyen. Se producen grandes daños en represas, diques y malecones. Se producen grandes desplazamientos del terreno en los taludes. El agua de canales, ríos, lagos, etc. sale proyectada a las riberas. Cantidades apreciables de lodo y arenas se desplazan horizontalmente sobre las playas y terrenos planos. Los rieles de las vías férreas quedan ligeramente deformados.
XI	Muy pocas estructuras de albañilería quedan en pie. Los rieles de las vías férreas quedan fuertemente deformados. Las tuberías (cañerías subterráneas) quedan totalmente fuera de servicio.
XII	El daño es casi total. Se desplazan grandes masas de roca. Los objetos saltan al aire. Los niveles y perspectivas quedan distorsionados.

2.2 Parámetros Instrumentales

A continuación se definen los parámetros instrumentales que se utilizan en el presente trabajo de título como datos de entrada para la clasificación de la Escala de Mercalli Modificada. Las definiciones son obtenidas de bibliografía relacionada con la IMM.

2.2.1 Intensidad de Arias

Este parámetro fue introducido por Arias en el año 1970. Es la medición de la capacidad de daño basada en la energía del movimiento de suelo (por unidad de peso) disipada por un conjunto de estructuras (sistemas de un grado de libertad (SDOF)) uniformemente distribuidas en distintas frecuencias. Caracteriza la energía contenida en un registro de movimiento fuerte. Se define como sigue para el caso de 0 amortiguamiento [3]:

$$IA_i = \frac{\pi}{2g} \int_{t_0}^{t_0+D} a_i^2(t) dt \quad (2.1)$$

donde:

IA_i : Intensidad de Arias

$a_i(t)$: Amplitud de aceleraciones de la componente i con $i = EW, NS, Z$

t_0 : Tiempo inicial del registro de aceleraciones.

D : Duración del registro de aceleraciones.

2.2.2 Velocidad Absoluta Acumulada

La Velocidad Absoluta Acumulada, generalmente mencionada por su sigla en inglés CAV (Cumulative Absolute Velocity) fue propuesta por Kennedy y Reed el año 1988 en un estudio auspiciado por Electrical Power Research Institute (EPRI). Posteriormente, en el año 1991 la definición original fue modificada eliminando la influencia de pequeñas amplitudes, no dañinas para las estructuras; y considerando la contribución de la amplitud y la duración del movimiento. Se define como el área bajo la curva del acelerograma absoluto [10].

$$CAV = \int_{t_0}^{t_0+D} |a(t)| dt \quad (2.2)$$

donde:

CAV : Velocidad Absoluta Acumulada.

$a(t)$: Registro de aceleraciones.

t_0 : Tiempo inicial del registro de aceleraciones.

D : Duración del registro de aceleraciones.

2.2.3 Intensidad Espectral de Housner

La Intensidad Espectral de Housner (SI) definida por Housner en 1952, es un parámetro que mide la severidad de un movimiento en estructuras elásticas. Es calculada como el área bajo la curva del Espectro de Respuesta de Velocidad (S_v) con un amortiguamiento de 20%, entre los periodos de 0.1 a 2.5 segundos, dividido por el largo del intervalo del período (Figura 1 (a)) [13].

$$SI = \frac{1}{2.4} \int_{0.1}^{2.5} S_v(T, \beta = 0.2) dT \quad (2.3)$$

donde:

SI : Intensidad Espectral

S_v : Espectro de respuesta de Velocidad

T : Período

β : Amortiguamiento de 20%

dT : Intervalo de periodo tomado como 0.1 segundos

Para el cálculo de este parámetro se utiliza la definición de la Compañía de Gas de Tokio (Figura 3(b)), Karim y Yamasaki [16], que consiste en calcular SI para cada rotación de las componentes horizontales de aceleración (EW y NS) de 0° a 180° utilizando intervalos de 1°, siendo SI el máximo de los valores obtenidos.

Tong and Yamazaki [31] en su estudio “A relationship between seismic ground motion severity and house damage ratio” concluyeron que este parámetro tiene mayor relación con el daño en las casas que otros índices de movimiento de suelo. En Japón el valor de SI es usado como un índice para apagar el suministro de gas natural por cañerías después de un terremoto destructivo.

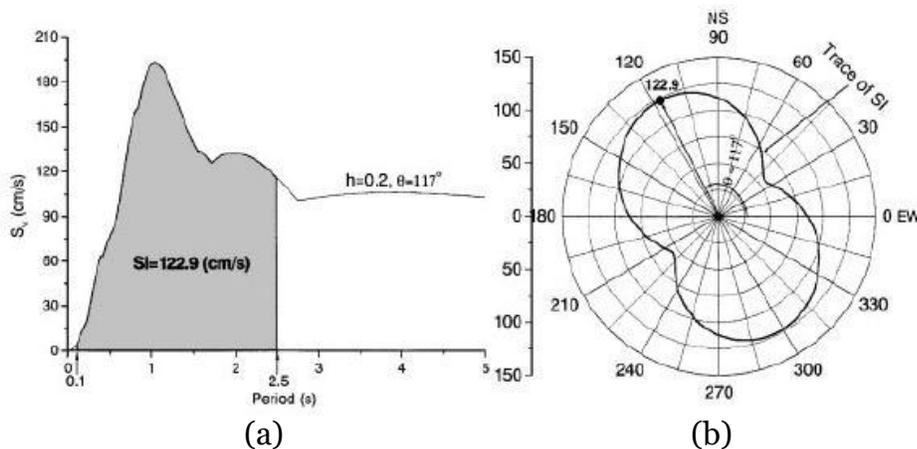


Figura 1: (a) Definición de la Intensidad Espectral de Housner (SI), la cual es calculada como el área bajo la curva del Espectro de Respuesta de Velocidad con un amortiguamiento de 20%, entre los periodos de 0.1 a 2.5 segundos, dividido por el largo del intervalo del período. (b) Trazo de SI calculada para cada rotación de las componentes de aceleración horizontales (EW y NS) de los registros de la estación JMA Kobe para el terremoto de Kobe en el año 1995. (Fuente: Karim y Yamasaki, 2001 [16]).

2.2.6 Intensidad Sísmica de la Agencia Meteorológica de Japón

La Intensidad Sísmica de la Agencia Meteorológica de Japón (I_{JMA}) ha sido usada por muchos años en Japón como una medida del movimiento fuerte, la cual se divide en 7 grados de intensidad. En un comienzo, al igual que la Escala de Mercalli, correspondía a una medición subjetiva, en base al juicio humano. Sin embargo, en los primeros años de la década del 90 la Agencia Meteorológica desarrolló la evaluación instrumental basándose en la misma definición.

Esta intensidad es utilizada para estimar el daño estructural, identificar áreas afectadas y preparar manejos de crisis ante terremotos.

El cálculo de I_{JMA} Instrumental se realiza aplicando la transformada de Fourier para las tres componentes de aceleración del registro. Luego, se aplica un filtro pasa-banda en el dominio de las frecuencias (Figura 3 (a)), filtro determinado por Karim y Yamazaki en el año 2001 [16]:

$$F(f) = F_1(f) \cdot F_2(f) \cdot F_3(f) \quad (2.4)$$

donde:

Period – effect filter

$$F_1(f) = \sqrt{1/f} \quad (2.5)$$

High – cut filter

$$F_2(f) = \frac{1}{\sqrt{1 + 0.694x^2 + 0.241x^4 + 0.0557x^6 + 0.009664x^8 + 0.00134x^{10} + 0.000155x^{12}}} \quad (2.6)$$

$(x = \sqrt{f/f_c})$

Low – cut filter

$$F_3(f) = \sqrt{1 - \exp(-f/f_0)^3}, \quad (2.7)$$

donde:

f : Frecuencia de campo libre

$f_c = 10$ [Hz]

$f_0 = 0.5$ [Hz]

Luego, las tres componentes son sumadas de manera vectorial (Figura 3 (c)) obteniendo una aceleración característica a_0 la cual debe cumplir que $\tau(a_0) \geq 0.3 \text{ seg}$. Donde $\tau(a_0)$ es el tiempo total que excede la aceleración a_0 (Figura 3 (b)). Finalmente, se calcula la Intensidad Sísmica JMA con la siguiente expresión:

$$I_{JMA} = 2.0 \cdot \log(a_0) + 0.94 \quad (2.8)$$

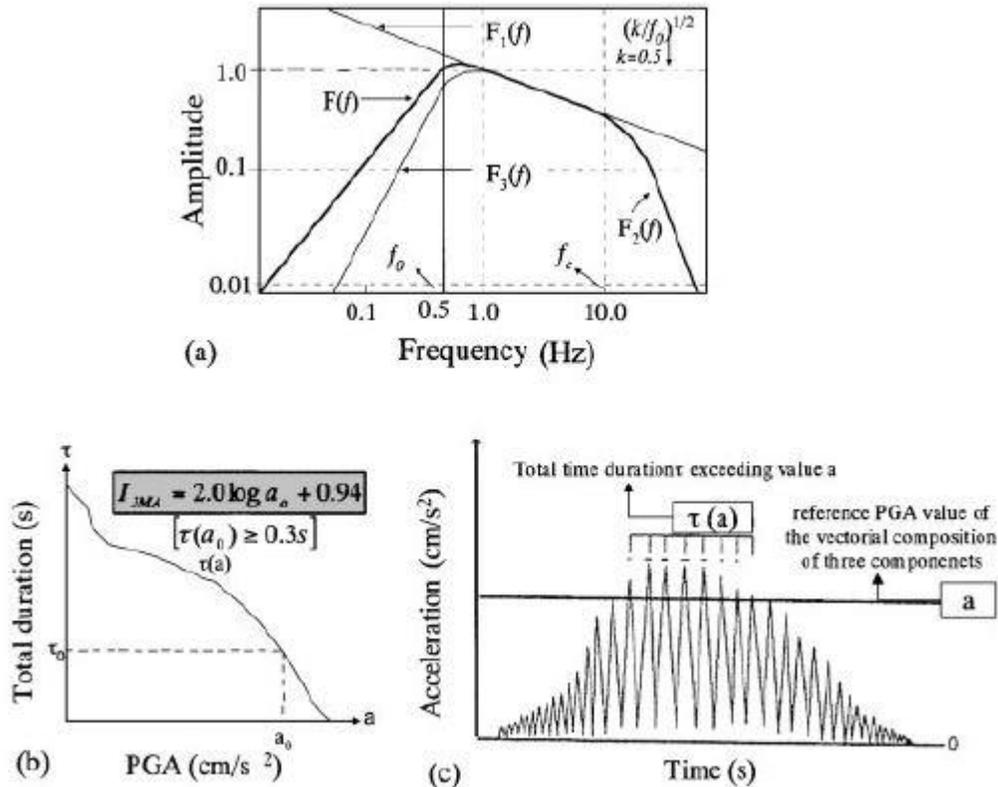


Figura 3: Cálculo de la Intensidad Sísmica Instrumental JMA, la cual es obtenida (a) aplicando un filtro de pasa-banda en el dominio de las frecuencias y (b) considerando el efecto de duración $\tau(a)$ de PGA, el cual es obtenido en dominio del tiempo (c) sumando los segmentos de tiempo que exceden el valor de referencia de PGA de la suma vectorial de los tres componentes de los registros de aceleración (Fuente: Karim y Yamasaki, 2001) [16].

2.2.7 Espectros de respuesta

Su cálculo se realiza a partir de la respuesta máxima que produce un movimiento fuerte a un conjunto de osciladores de 1 grado de libertad que abarcan un rango definido de períodos con un amortiguamiento determinado.

Para el cálculo de los espectros de respuesta se utiliza una función en Matlab desarrollada por R. Boroschek que utiliza el método descrito en “Calculation of Response Spectra from strong-motion earthquake records” [19], en el cual el paso final es encontrar los máximos valores de desplazamiento, velocidad y aceleración [18]:

$$S_d(\omega, \beta) = \max_{i=1,N} x_i(\omega, \beta) \quad (2.9.1)$$

$$S_v(\omega, \beta) = \max_{i=1,N} \dot{x}_i(\omega, \beta) \quad (2.9.2)$$

$$S_a(\omega, \beta) = \max_{i=1,N} \ddot{x}_i(\omega, \beta), \quad (2.9.3)$$

donde:

S_d : Espectro de respuesta de desplazamiento

S_v : Espectro de respuesta de velocidad

S_a : Espectro de respuesta de aceleración

De cada espectro se utilizan dos valores: un valor asociado al periodo $T=0.2$ [seg] y el otro al periodo $T=1$ [seg]. Para ambos se considera un amortiguamiento de 5%.

2.2.8 Cruces por cero

Corresponde a la cantidad de veces que el registro de aceleraciones corta la abcisa (tiempo) por segundo. Se considera para su cálculo el tramo del registro que coincide con el intervalo de duración de movimiento fuerte.

En diferentes estudios ([23], [24]) se ha concluido que este parámetro junto con la Intensidad de Arias están relacionados con el potencial destructivo (daño en estructuras) provocado por un sismo.

2.2.9 Contenido de frecuencia

El contenido de frecuencia se obtiene al aplicarle al registro de aceleraciones la transformada de Fourier. Para este trabajo se considera el valor de la frecuencia central, para la banda de energía entre el 0% y 75%.

2.2.10 Fuente Sismogénica

La generación de los terremotos en Chile se produce principalmente por la interacción entre las placas de Nazca y Sudamericana. Las placas chocan entre sí, provocando que la placa más densa (placa de Nazca) se meta bajo la menos densa (Sudamericana), esto se conoce como subducción. La velocidad de convergencia entre las placas es aproximadamente 6-7 [cm/año].

Como producto de esta colisión entre las placas se generan diferentes tipos de terremotos o fuentes sismogénicas [6] [12] [21].

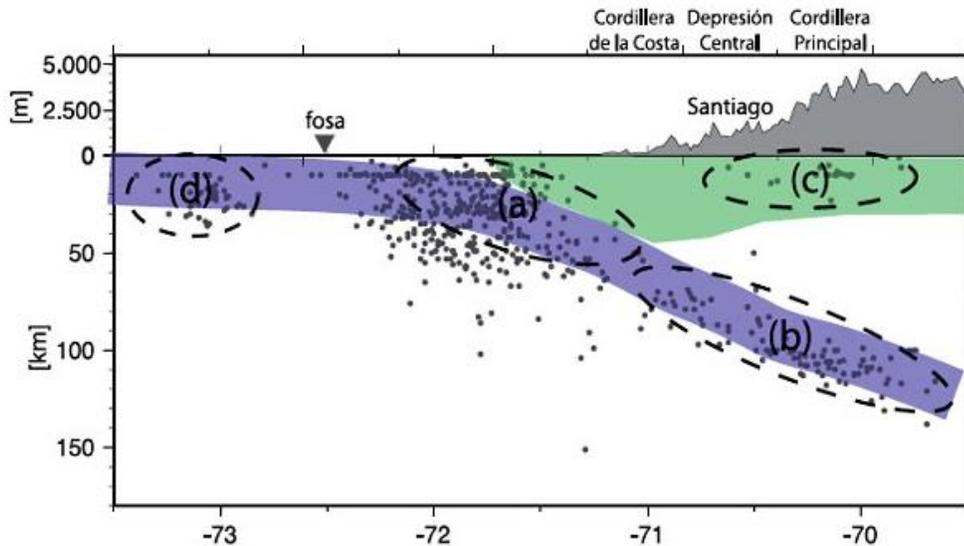


Figura 4: Perfil esquemático con la sismicidad del catálogo NEIC, registrada entre 1973 y 2007 de la zona en la latitud 33.5°S (considerando 0.5° en dirección norte y sur), cada punto representa un sismo, independiente de su magnitud o fecha de ocurrencia. El color azulado representa la posición esquemática de la placa de Nazca y verde, la placa Sudamericana. Las líneas punteadas indican la posición de las principales fuentes sísmogénicas: a. interplaca tipo 'thrust'; b. intraplaca de profundidad intermedia; c. corticales y d. 'outer-rise'. (Fuente: Leyton, Ruiz y Sepúlveda, 2010) [22]

- ❑ Interplaca tipo Thrust: Sismos producidos en el contacto entre la placa de Nazca y la placa Sudamericana, se extienden desde la fosa hasta ~50 [km] de profundidad.

Se caracterizan por tener isosistas, curvas de igual Intensidad de Mercalli Modificada, elípticas con su eje principal paralelo a la costa.

Ejemplos: Terremoto de Valdivia, año 1960 ($M_w=9.5$); y terremoto del Maule, año 2010 ($M_w=8.8$).

- ❑ Corticales o Superficiales Intraplaca: Estos terremotos ocurren en la superficie de la placa Sudamericana, principalmente en los sectores precordilleranos y cordilleranos. Están asociados a fallas con profundidad de 5-30 [km]. En general las fallas tienen 30 [km] de largo y alcanzan magnitudes de Richter máximas de $M=7.0$.

Ejemplo: Terremoto de Las Melosas, año 1958 ($M_w=6.3$).

- ❑ Intraplaca de Profundidad Intermedia: Ocurren en el interior de la placa de Nazca, su epicentro es en tierra y su profundidad focal oscila entre 60 a 250 [km]. En este tipo de sismos predominan los periodos muy cortos.

Ejemplos: Terremoto de Chillan, año 1939 ($M_s=8.3$); y terremoto de Punitaqui, año 1997 ($M_w=7.1$).

- ❑ Intraplaca Profunda: Sismos producidos por el mismo mecanismo que los de Intraplaca de Profundidad Intermedia pero estos ocurren a una profundidad mayor a 250 [km].

- ▣ Outer-Rise: Estos sismos ocurren debido a la flexión de la placa de Nazca al intentar meterse bajo la placa Sudamericana y la oposición que ejerce esta (fuerza de roce entre las placas). Por esto ocurren distantes a la costa por lo que no producen daños significativos. En general tienen magnitudes de Richter menores a $M=8.0$.

Ejemplo: Año 2001, frente a las costas de Valparaíso con magnitud $M_w=6.7$.

2.2.11 Distancia al hipocentro

La distancia al hipocentro se calcula como la distancia euclidiana entre el hipocentro y la estación que registra el sismo.

Conociendo la latitud y longitud de la estación, y la latitud, longitud y profundidad del hipocentro, se puede determinar el radio de la tierra en esta posición específica. Luego, con el radio, la latitud y longitud, se calculan las coordenadas cartesianas de ambos puntos (distancia en km). Por último, con estos dos valores se calcula la distancia entre estos.

2.2.12 Profundidad hipocentro

La profundidad del hipocentro es la distancia entre este y el epicentro. Esta información es obtenida de páginas de internet donde se encuentra la información del sismo. Las páginas utilizadas son las del Centro Sismológico Nacional (CSN). En el esquema mostrado a continuación se muestra a que distancia corresponde la profundidad del hipocentro.

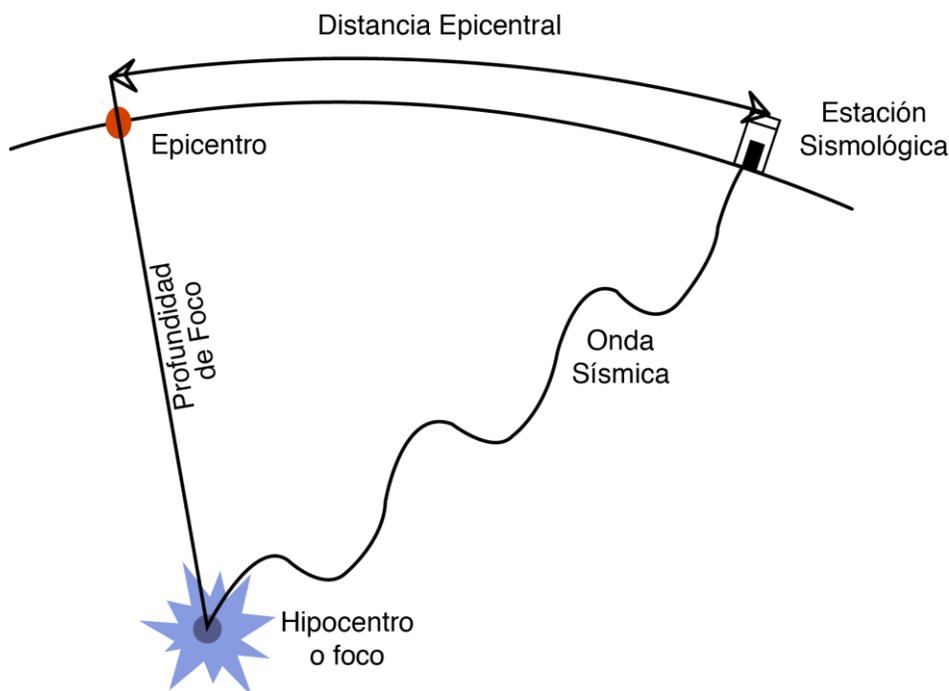


Figura 5: Esquema que muestra la distancia que corresponde a la profundidad del hipocentro. (Fuente: universobservado.blogspot.cl)

CAPÍTULO 3: MÉTODOS DE REGRESIÓN Y/O CLASIFICACIÓN

Los métodos que se utilizan en este trabajo están dentro de lo que se conoce como Aprendizaje Automático (AA). El AA es una rama de la Inteligencia Artificial que tiene como objetivo desarrollar técnicas que permitan a los computadores/ordenadores aprender. Lo anterior, creando algoritmos capaces de generalizar comportamientos y reconocer patrones a partir de información suministrada en forma de ejemplos. Por lo descrito en este párrafo se puede decir que el AA es un proceso de inducción del conocimiento.

Las aplicaciones del Aprendizaje Automático es muy amplia, siendo sus usos más comunes los siguientes: motores de búsqueda, diagnósticos médicos, detección de fraude en el uso de tarjetas de crédito, análisis del mercado de valores, clasificación de secuencias de ADN, reconocimiento del habla y del lenguaje escrito, juegos y robótica.

Dentro del AA se puede hacer una distinción entre métodos, según la forma en que los datos son presentados al sistema de aprendizaje [38]:

- ❑ **Aprendizaje Supervisado:** “Predicen un dato (variable objetivo) desconocido a priori, a partir de otros conocidos. Los algoritmos utilizados en este caso requieren que cada una de las instancias de los datos se encuentre etiquetados con un atributo objetivo”.
- ❑ **Aprendizaje No Supervisado:** “Descubren patrones y tendencias en los datos. Los algoritmos utilizados en este caso no requiere que los datos se encuentren etiquetados con el atributo objetivo.”

También se pueden clasificar según la función del algoritmo y la salida: regresión, clasificación, agrupamiento (“Clustering”), recomendación y aprendizaje profundo (“Deep Learning”). Se describe brevemente los que son utilizados en este trabajo.

- ❑ **Regresión:** Aquellos modelos que intentan predecir un valor real.
- ❑ **Clasificación (binaria o multiclase):** Aquellos modelos que intentan predecir la clasificación de objetos sobre un conjunto de clases prefijadas.

En este trabajo es utilizado el método de Redes Neuronales Artificiales y Regresión Logística. El primero puede trabajar como aprendizaje supervisado o no supervisado y además, permite el uso de datos que requieran salidas continuas (regresión) o discretas (clasificación). El segundo de ellos está en la categoría de aprendizaje supervisado y, según el tipo de salida, en regresiones. Sin embargo, los datos utilizados deben ser clases, que pueden ser del tipo nominales, ordinales o jerárquicas.

Se pueden revisar los siguientes artículos que utilizan Redes Neuronales Artificiales y están relacionados con el tema tratado en este trabajo: “A model por MMI-Attenuation Based on Artificial Neural Networks and Genetic Algorithms” [28], “Prediction of modified Mercalli intensity from PGA, PGV, moment magnitude, and epicentral distance

using several nonlinear statistical algorithms” [2], “A Neural Networks Based MMI attenuation Model” [32].

3.1 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNA) es una técnica de análisis predictivo que se basa en el comportamiento y/o estructura del sistema nervioso de los seres vivos, en particular en el funcionamiento del cerebro: neuronas conectadas entre sí mediante sinapsis.

La arquitectura de una RNA se refiere a la estructura de esta (Figura 6). A cómo son ordenados los nodos (neuronas) y las conexiones entre sí (sinapsis), que en general se suelen agrupar en unidades estructurales llamadas capas. Dentro de los diferentes tipos de RNA uno de los más utilizados es el llamado Multi-Layer Perceptron el cual es una estructura en capas.

Cada capa está formada por un número determinado de neuronas. Las capas son las siguientes [33]:

Capa de entrada: El número de neuronas en esta capa corresponde al número de parámetros predictores.

Capa oculta (puede existir o no): Esta capa recibe información de la capa de entrada y luego transmite información a la capa de salida. El número de neuronas en esta capa, que puede ser una o más, ayuda a controlar que no se produzca sobre-entrenamiento (*overfitting*).

Capa de salida: La capa de salida es la que recibe la información de la capa oculta. El número de neuronas en esta capa depende del número de variables dependientes.

La neurona es la unidad básica, el elemento procesador de una Red Neuronal Artificial. Cada una de ellas recibe información de la capa de neuronas anterior la cual ha sido ponderada por un peso. Esta información ponderada es generalmente sumada y luego se hace pasar por una función de activación con lo que se obtiene una señal que es transmitida a la próxima neurona. La ponderación refleja la fuerza de la conexión entre las neuronas.

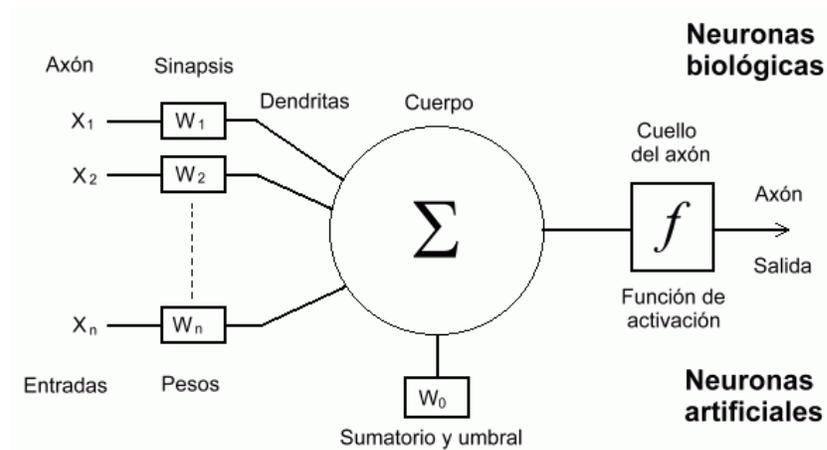


Figura 6: Esquema neurona en RNA y analogía con neurona biológica. (Fuente: Universidad de Sevilla [38])

La función de activación, como su nombre lo dice, se encarga de calcular el nivel o estado de activación de la neurona en función de la entrada total. Esta función es aplicada para obtener la señal (peso) que es transmitida a la próxima neurona. Si el valor del peso es positivo quiere decir que activará a la neurona siguiente, en caso que el valor sea negativo desactivará o inhibirá la neurona siguiente. En el caso que este peso sea igual a cero, quiere decir que no existe conexión entre ambas neuronas [11] [34]. En general, para la capa oculta se utiliza una función no lineal, entre las más comunes está la tangente sigmoideal (tansig). Y en este trabajo, para la capa de salida se utiliza una función lineal (purelin).



Figura 7: Ejemplos funciones de activación. (Fuente: Universidad de Sevilla [38])

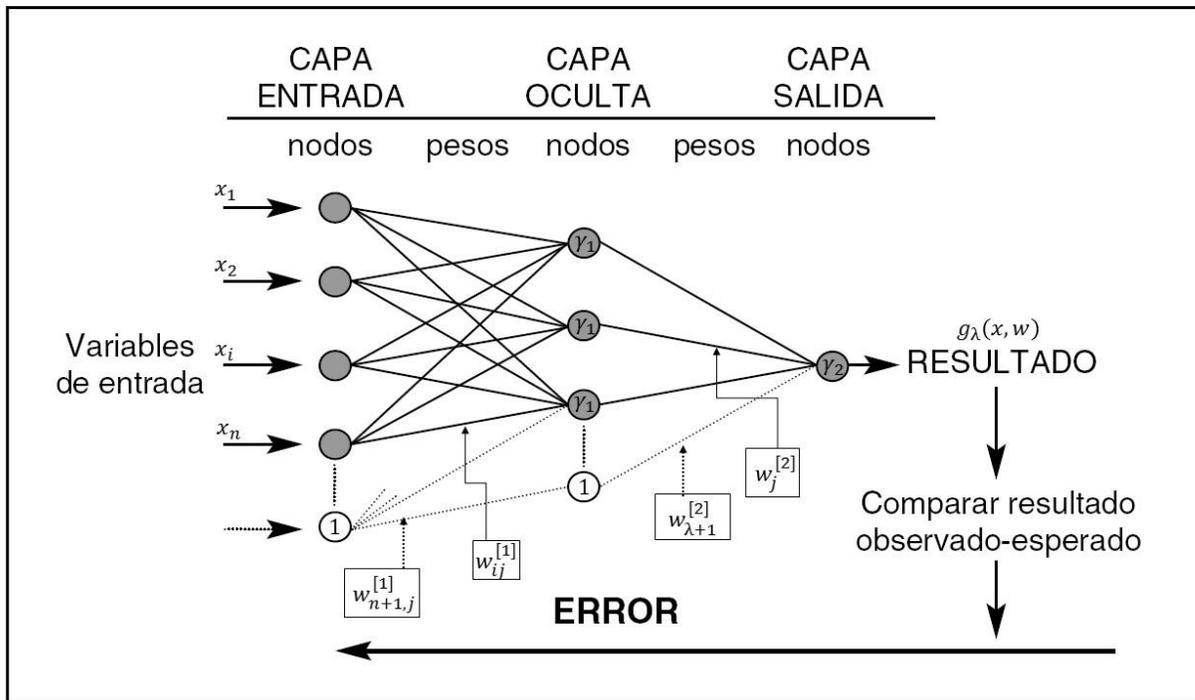


Figura 8: Esquema RNA tipo feed-forward backpropagation. (Fuente: www.medicinaintensiva.org)

Dado un conjunto de observaciones, la tarea del aprendizaje neuronal es construir un estimador $g_\lambda(x, w)$ [34]:

$$g_\lambda(x, w) = \gamma_2 \left(\sum_{j=1}^{\lambda} w_j^{[2]} \gamma_1 \left(\sum_{i=1}^n w_{ij}^{[1]} x_i + w_{n+1,j}^{[1]} \right) + w_{\lambda+1}^{[2]} \right), \quad (3.1)$$

donde:

$w_{ij}^{[1]}$: Vector paramétrico a ser estimado que equivale a las ponderaciones de las conexiones entre las neuronas de la capa de entrada y la capa oculta.

$w_{n+1,j}^{[1]}$: Ponderación de conexiones entre la neurona bias de la capa de entrada y las neuronas de la capa oculta.

$w_j^{[2]}$: Vector paramétrico a ser estimado que equivale a las ponderaciones de las conexiones entre las neuronas de la capa oculta y la capa de salida.

$w_{\lambda+1}^{[2]}$: Ponderación de conexiones entre la neurona bias de la capa oculta y las neuronas de la capa de salida.

γ_1 : Función no lineal acotada y diferenciable

γ_2 : Función que puede ser lineal o no lineal

λ : Parámetro de control que indica el número de neuronas en la capa oculta

$i=1, \dots, n$ con n número de neuronas de la capa de entrada

$j=1, \dots, \lambda$ con λ número de neuronas de la capa oculta

En este trabajo el tipo de red utilizado es feed-forward utilizando el método de entrenamiento backpropagation. Este método consiste en que la información recorre la red en una sola dirección (de izquierda a derecha, forward) buscando minimizar el error entre los valores obtenidos por la red y los del conjunto de datos de entrenamiento. Si el error obtenido es mayor al error máximo establecido, la información del error obtenida a

la salida de la red viaja hacia atrás (backpropagation), hasta la primera capa de la capa oculta (puede existir más de una capa oculta en la estructura de la red) y los pesos (w) son recalculados (Figura 8). Este proceso es repetido hasta que se cumpla el valor del error establecido. Para el cálculo del error se utiliza una función de entrenamiento, en este caso se ocupa el algoritmo de Levenberg-Marquardt (L-M) [36]. Se elige esta función ya que es en general una de las más utilizadas por su buen desempeño, ya comprobado en numerosos trabajos; es muy eficiente cuando se trabaja con funciones diferenciables como las utilizadas en este trabajo (tangente sigmoideal, función lineal); y converge rápidamente al mínimo error.

El algoritmo L-M se genera de una modificación al método de Gauss-Newton (G-N). Interpola entre el algoritmo de G-N y un descenso de gradiente. Esencialmente, el algoritmo se comporta como un descenso de gradiente lejos de la solución y como un G-N cerca de ésta.

Para trabajar con RNA es necesario que el set de datos con el que se quiere trabajar se divida en 3 sub-conjuntos: set de entrenamiento, set de validación y set de prueba. El set de entrenamiento, como lo dice su nombre es el conjunto de datos con que se entrena la red; el set de validación ayuda a identificar si existe sobre-entrenamiento, y con esto modificar el número de neuronas de la capa oculta; y el set de prueba se utiliza para evaluar el desempeño del modelo generado comparando entre distintas estructuras factibles. La forma de selección de estos conjuntos de datos se explica en el Capítulo 5.

Como se menciona en el párrafo anterior el set de validación ayuda a identificar el sobre-entrenamiento de la red. El sobre-entrenamiento consiste en que el algoritmo se enfoca excesivamente en el set de entrenamiento y queda entrenado para las características específicas de ese conjunto de datos y no aprende patrones generales para luego poder hacer predicciones de cualquier otro conjunto de datos (Figura 9). Una forma de evitarlo, forma que se utiliza en este trabajo, es que cuando el error del conjunto de datos de validación comienza a aumentar se detiene el proceso de entrenamiento (Figura 10).

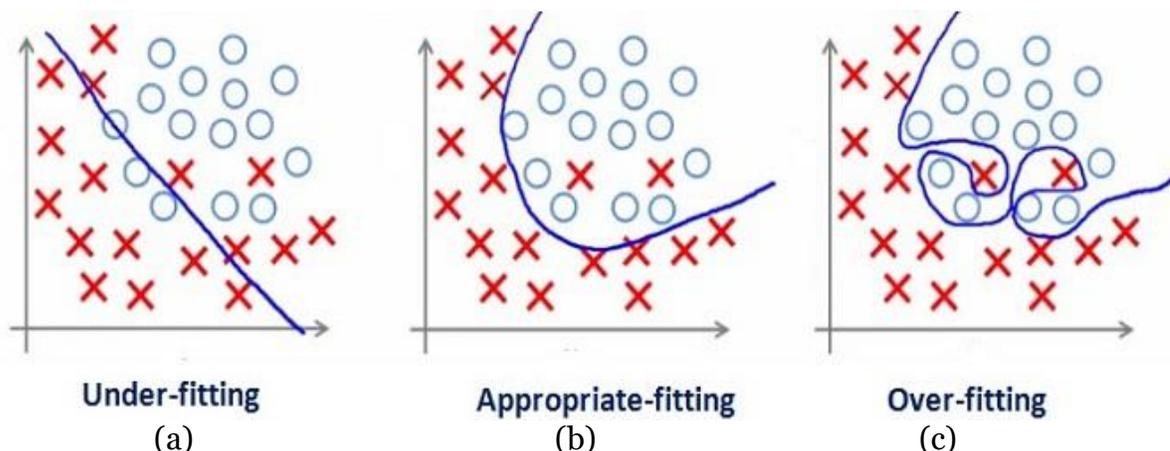


Figura 9: Representación de under-fitting, appropriate-fitting y over-fitting. (a) El ajuste de la línea azul es muy simple para explicar la varianza de los datos, (b) La línea azul representa un modelo que puede ser más fácilmente generalizado para otros datos, (c) La línea azul se ajusta perfectamente a los valores del conjunto de entrenamiento, pero luego es difícil que se pueda ocupar para otro conjunto de datos. (Fuente: Universidad de Sevilla [16])

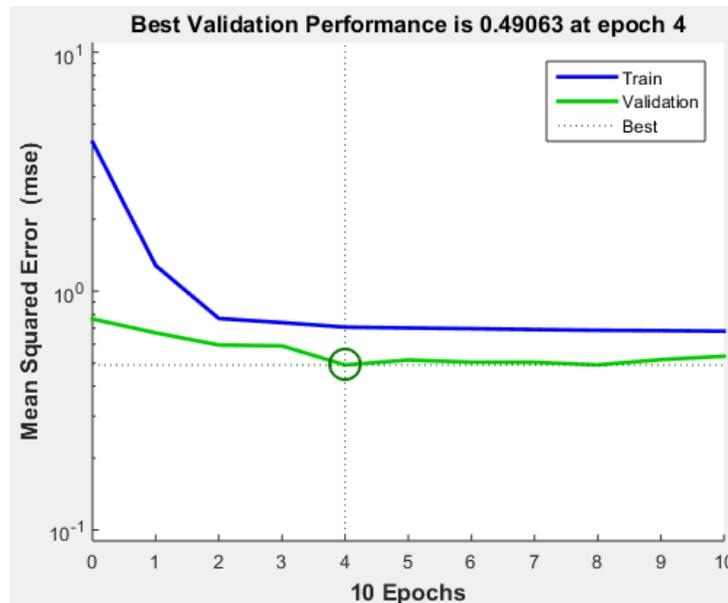


Figura 10: Control del error del set de validación para evitar el sobre-entrenamiento. (Fuente: Matlab)

El sobre-entrenamiento se puede producir por: uso de muchas neuronas en la capa oculta; si una red es muy compleja puede seguir el ruido y no la señal; alta correlación entre las variables de entrada; y/o mayor número de parámetros de entrada que observaciones del set de entrenamiento.

Las consecuencias de un sobre-entrenamiento de la red puede generar salidas del modelo fuera del rango de los datos de entrenamiento o salidas extrañas aunque el set de datos de entrenamiento no contenga ruido.

También se puede producir bajo-ajuste (underfitting), que puede ser producto de una red poco compleja que no es capaz de captar todos los parámetros de entrada. Sin embargo, es más complejo que ocurra sobre-entrenamiento por la consecuencia en los resultados de salida (Figura 9).

Como se menciona anteriormente, el entrenamiento de una red neuronal consiste en un proceso iterativo: primero la información del conjunto de entrenamiento recorre la red de izquierda a derecha y luego, la información del error viaja hacia atrás, a las neuronas de la capa oculta, desde donde la información recorre nuevamente la red de izquierda a derecha. Cuando todos los datos del conjunto de entrenamiento realizan este proceso es lo que se considera un *epoch*. Debido a que el conjunto de datos de entrenamiento se puede dividir en grupos (*batch*) para que realicen este proceso se hace la distinción entre un *epoch* y una iteración. Ya que una iteración se refiere a cada vez que un grupo realiza el proceso, y *epoch* a cuando, si el conjunto de datos fue dividido en grupos, todos los grupos completan el proceso completo.

3.2 Regresión Logística Multinomial

La Regresión Logística (RL) pertenece, dentro de los métodos estadísticos, a lo que se conoce como Modelo Lineal Generalizado (MLG), dentro de los cuales también se encuentran la Regresión Lineal y la Regresión de Poisson.

La RL permite realizar una regresión lineal entre una variable dependiente (o de respuesta) y entre una o más variables independientes (o de predicción). La variable de respuesta puede ser categórica (este trabajo), ordinales o de tipo jerárquica. Las variables predictoras pueden ser numéricas o categóricas.

Lo que busca la Regresión Logística es modelar la posibilidad de que un evento ocurra dependiendo de los valores de las variables independientes, estimar la probabilidad de que este evento ocurra utilizando un set de datos de observación de entrenamiento. Y por último, poder realizar una clasificación de datos observados (set de datos de prueba) estimando la posibilidad que una observación se encuentre en una categoría particular.

El modelo lo realiza igualando la posibilidad a una combinación lineal de las variables independientes utilizando como función de enlace el *logit*: logaritmo natural de la posibilidad de ocurrencia de un evento.

La posibilidad, en Regresión Logística Simple, corresponde a la probabilidad de que un evento ocurra dividido en la probabilidad de que el evento no ocurra:

$$\text{posibilidad} = \frac{P(\text{ocurrencia del evento})}{P(\text{evento no ocurra})} = \frac{p}{1-p} \quad (3.2)$$

En Regresión Logística Multinomial la posibilidad corresponde a la probabilidad de que ocurra un evento, dividido por la probabilidad de ocurrencia de un evento definido como evento base, en general se utiliza la última clase como evento base:

$$\text{posibilidad} = \frac{P(\text{ocurrencia del evento 1})}{P(\text{ocurrencia del evento base})} = \frac{p_1}{p_2} \quad (3.3)$$

Por lo tanto, la ecuación que representa este modelo es:

$$\text{logit}(p_i) = \ln\left(\frac{p_i}{p_n}\right) = \alpha_i = \beta_0 + \beta_1 \cdot X_1 + \dots + \beta_j \cdot X_j \quad (3.4)$$

donde:

p_i : Probabilidad variable de respuesta con $i = 1 \dots (n - 1)$

n : Número de variables de respuesta o número de clases de salida

p_n : Probabilidad variable de respuesta de referencia o base

β_0 : Coeficiente de intercepción

β : Coeficientes de la combinación lineal de las variables de predicción

X_i : Variable independiente o predictora con $i = 1 \dots j$

j : Número de variables independientes

La función inversa del *logit* entrega la posibilidad de que el “evento ocurra”. En el contexto de este trabajo corresponde a la posibilidad de que la variable de respuesta pertenezca a cada clase. Esta se conoce como la Ecuación de Regresión Estimada:

$$\text{logit}^{-1}\left(\frac{p_i}{p_n}\right) = \hat{p}_i = \frac{e^{\alpha_i}}{1 + \sum_{i=1}^{n-1} e^{\alpha_i}} \quad (3.5)$$

donde:

p : Probabilidad, valor entre 0 y 1

α_i : Combinación lineal de las variables independientes para la clase i , definida en ecuación 3.4.

Los coeficientes de la combinación lineal α_i son calculados utilizando la estimación por máxima verosimilitud.

A continuación se muestra el gráfico de la función inversa del logit, en el caso de una Regresión Lineal Simple (Figura 11).

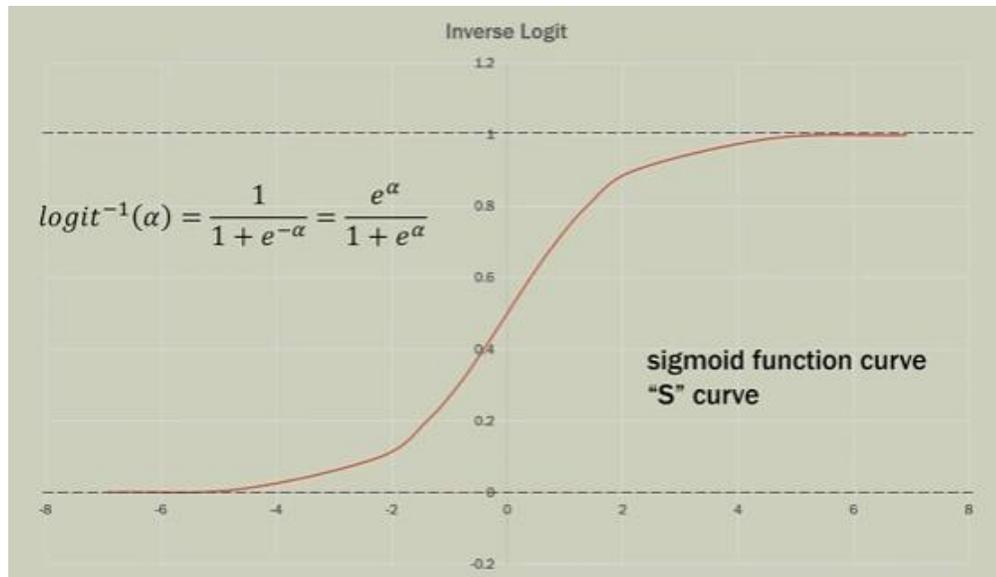


Figura 11: Gráfico función inversa del logit

3.3 Mínimos Cuadrados Parciales (PLS)²

Técnica de regresión que corresponde a una extensión del modelo de Regresión Lineal Múltiple (RLM), que tiene como objetivo principal encontrar la relación que existe entre múltiples variables independientes (X_i) y una variable dependiente (Y):

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (3.6)$$

donde:

Y : Variable dependiente

X_i : Variables independientes o predictoras, con $i = 1, 2, \dots, n$

b_0 : Intercepto de la regresión

b_i : Coeficientes de regresión para las variables independientes, con $i = 1, 2, \dots, n$

Mínimos Cuadrados Parciales es recomendado sobre otro método de RLM cuando las variables predictoras están altamente correlacionadas y/o cuando se tienen menos observaciones que variables independientes. Además, también sirve como herramienta

² PLS por su sigla en inglés: Partial Least Square

para reducir el número de variables predictoras, eliminando aquellas que aportan información redundante o que no aportan.

La regresión mediante Mínimos Cuadrados Parciales realiza una proyección (combinación lineal) de las variables independientes y otra proyección de las variables dependientes (en caso de ser más de una), con lo que crea nuevas variables (o variables de latencia) T_1 y U_1 (Figura 12). Las variables de latencia se definen en el set de datos de X (variables predictoras) que tienen una alta covarianza con las del conjunto de datos de Y (variables de respuesta). A través del algoritmo NIPALS (NonLinear Iterative Partial Least Square), PLS genera las distintas variables de latencia con los residuos que quedan después de generar cada nueva variable.

Esta técnica, proyecta simultáneamente las variables X e Y dentro de un espacio común (TU) de tal manera que existe una estrecha relación entre la posición de una observación en el plano X y su correspondiente posición en el plano Y .

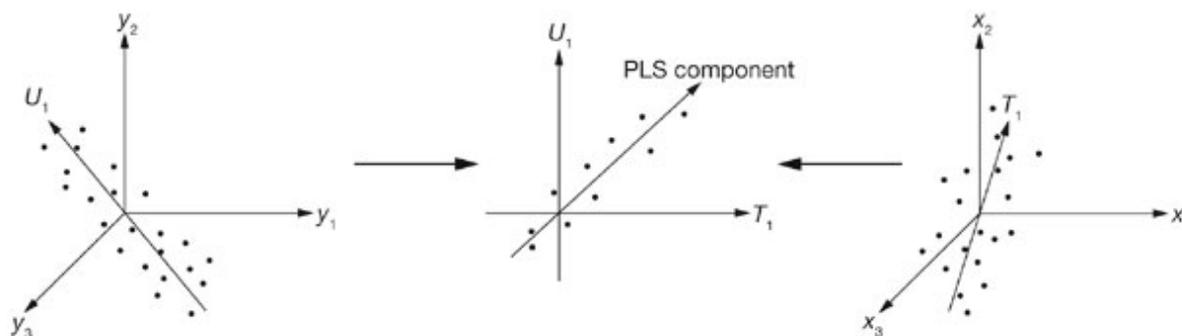


Figura 12: Representación Geométrica de la regresión mediante Mínimos Cuadrados Parciales. (Fuente: www.nature.com)

La utilización de esta técnica para reducir las variables independientes se basa en el análisis del *loading plot*. Se grafican los dos primeros vectores de la matriz de *loading*. El primer vector corresponde a una proyección (combinación lineal) de los parámetros, el segundo vector corresponde a la combinación lineal de lo que no se pudo explicar con el primero (error), y así sucesivamente.

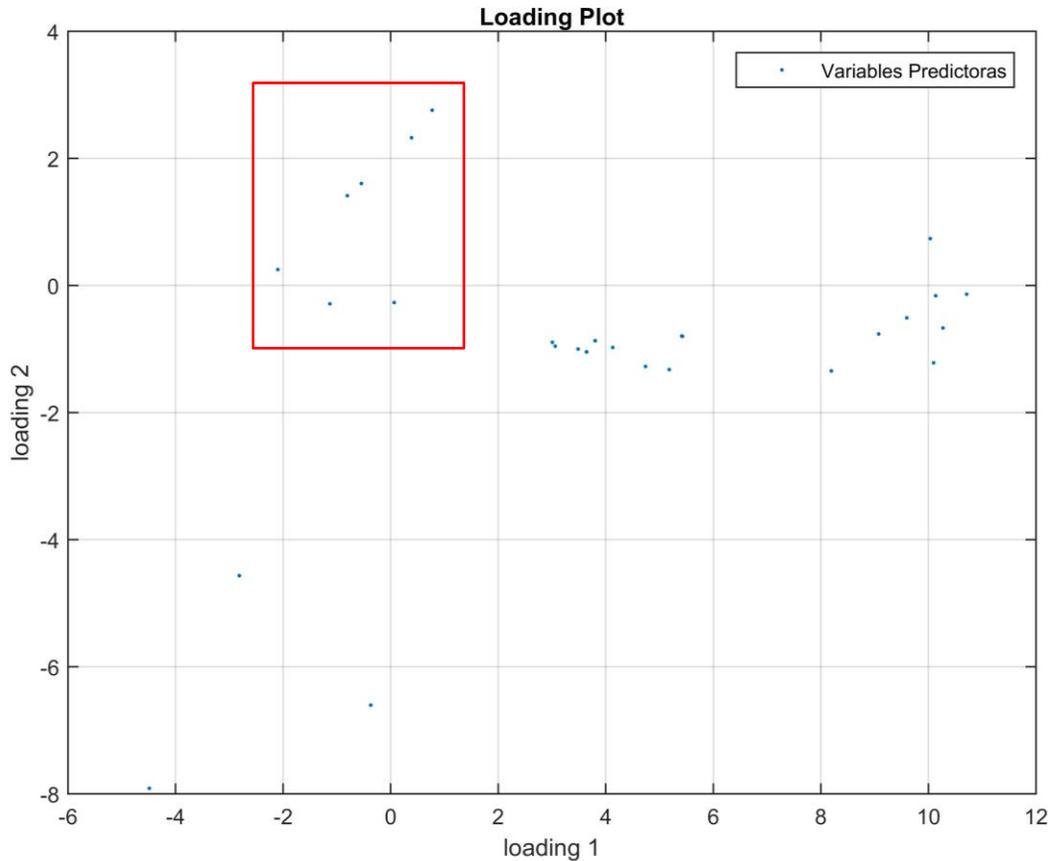


Figura 13: Loading plot obtenido de realizar PLS. Variables encerradas en cuadro rojo son candidatas a ser eliminadas. (Fuente: Elaboración Propia en Matlab)

En la Figura 13 se observa la posición de las variables independientes al graficar los dos primeros vectores de la matriz de *loading*. Las variables predictoras candidatas a ser eliminadas son las que se encuentran más cerca de la coordenada (0,0), esto se debe a que estas variables aportan poca información tanto en el primer vector como en el segundo. Las variables que tienen un coordenada “alta” en X y baja en Y es porque estas ayudan a explicar de mejor forma la relación entre X’s e Y. De la misma forma, si tienen un valor “alto” en ambas componentes es porque ayudan a explicar tanto la relación entre las variables predictoras y la variable de respuesta, como lo que no logra ser explicado por dicha proyección (el error).

En este trabajo, para ambos métodos utilizados, mediante el análisis del *loading plot* de las variables independientes, se tiene la opción de eliminar aquellas variables que estén cercanas a la coordenada (0,0) de las variables predictoras, consideradas como input de los modelos.

CAPÍTULO 4: DETERMINACIÓN DE PARÁMETROS A PARTIR DE REGISTROS DE ACELERACIÓN

Se trabaja con los registros obtenidos de RENADIC y ONEMI. Estos corresponden a los registros de aceleración de 256 eventos de diferentes estaciones. Por cada estación se tiene el registro en las direcciones NS, EW y Z ⁽³⁾ con lo que se cuenta con 1122 registros. Los registros corresponden a eventos ocurridos entre los años 2007 al 2015 y los registros de eventos importantes de los años 85', 95', 97', 99', 2001 y 2005.

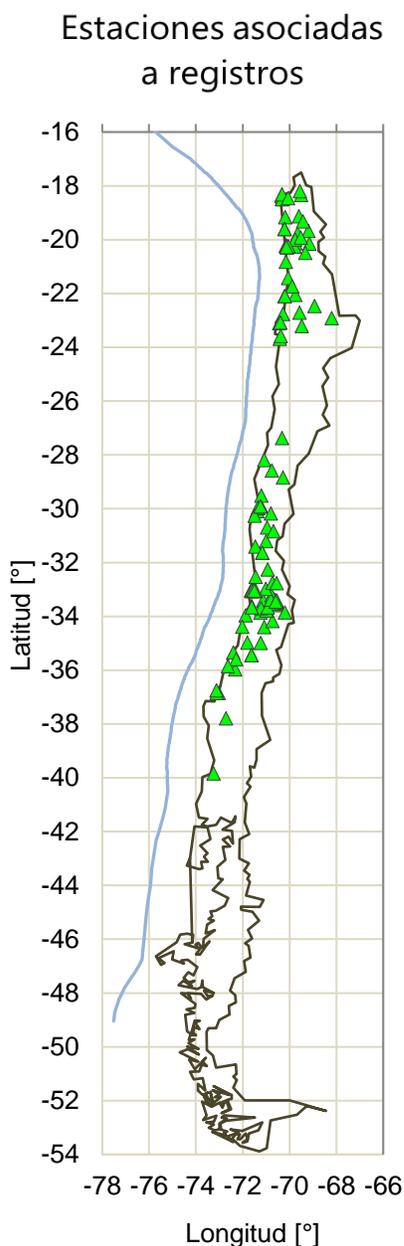


Figura 14: Distribución a lo largo de Chile de estaciones de las que se obtuvieron los registros. (Ordenes, 2017) [20]

³ NS: North-South, EW: East-West, Z: Vertical

Los registros deben ser asociados a un valor de la Intensidad de Mercalli Modificada, para esto se cuenta con un archivo Excel con la lista de los registros y la estación a la cual pertenecen. Además, se tiene un Excel generado por Fernando Muñoz (alumno de Ingeniería Civil de la Universidad de Chile) que contiene todos los eventos sensibles, es decir, aquellas que tienen intensidad registrada, desde el año 2007 al 2015. Por lo tanto, con la fecha y hora del registro, se asocia la IMM de la ciudad correspondiente a la ubicación de la estación.

Para los registros de eventos ocurridos antes del año 2007 el valor de la Intensidad de Mercalli no se encuentra en este Excel, pero por corresponder a eventos importantes la información está disponible en internet.

	B	C	G	H	J	K	L	M	N
1	Fecha	Hora	Mec.Focal	Tc [seg] (periodo corte)	Lugar Estacion	Lat EST	Lon EST	Prof. [km]	d hip [km]
75	2009-04-16	17:43:31	IPI	10	Arica	-18,48	-70,31	70,2	130,58
76	2009-04-16	17:43:31	IPI	10	Iquique- Escuela Chipana	-20,25	-70,13	70,2	118,03
77	2009-04-16	17:43:31	IPI	10	Iquique- Hospital	-20,21	-70,14	70,2	114,77
78	2009-04-16	17:43:31	IPI	10	Pisagua- Retén de Carabineros	-19,60	-70,21	70,2	78,47
79	2009-04-16	17:43:31	IPI	10	Poconchile- Retén de Carabineros	-18,45	-70,07	70,2	128,18
80	2009-04-17	02:08:08	ITT	8	● Alto Hospicio	-20,27	-70,10	37,2	97,14
81	2009-04-17	02:08:08	ITT	10	● Arica	-18,49	-70,31	37,2	141,06
82	2009-04-17	02:08:08	ITT	10	● Arica	-18,48	-70,31	37,2	141,79
83	2009-04-17	02:08:08	ITT	10	● Arica- Chacalluta	-18,31	-70,31	37,2	159,22
84	2009-04-17	02:08:08	ITT	8	Baquedano	-20,13	-69,75	37,2	115,74
85	2009-04-17	02:08:08	ITT	10	Iquique- Escuela Chipana	-20,25	-70,13	37,2	94,54
86	2009-04-17	02:08:08	ITT	10	Iquique- Hospital	-20,21	-70,14	37,2	90,92
87	2009-04-17	02:08:08	ITT	10	● Pica- Consultorio Municipal	-20,49	-69,33	37,2	171,92
88	2009-04-17	02:08:08	ITT	10	Pisagua- Retén de Carabineros	-19,60	-70,21	37,2	62,04
89	2009-04-17	02:08:08	ITT	10	Poconchile- Retén de Carabineros	-18,45	-70,07	37,2	153,79
90	2009-04-26	08:03:36	IPI	10	Santiago- Estación mirador	-33,51	-70,61	138,4	179,81

Figura 15: Excel con lista de los 1122 registros

	A	B	C	D	E	F	G	H	I	J
1	Fecha	Hora (UTC)	Magnitud	Profundidad	Latitud [°]	Longitud[°]	Ciudades	Intensidad	Latitud [°]	Longitud[°]
218	2009-04-17	1:11:35	4.0	58.5	-29.863	-71.390	Coquimbo	IV	29°57'	71°20'
219	2009-04-17	2:08:08	6.0	37.2	-19.666	-70.600	Alto Hospicio	V	20°15'	70°07'
220							Cuya	V	19°07'	70°08'
221							Huara	V	19°59'	69°47'
222							Pisagua	V	19°36'	70°13'
223							● Arica	IV	18°28'	70°18'
224							Camiña	IV	19°18'	69°26'
225							● Pica	IV	20°04'	69°14'
226							● Pozo Almonte	IV	20°16'	69°48'
227							Putre	IV	18°12'	69°35'
228	2009-04-17	3:34:19	4.9	101.5	-29.040	-70.581	Chañaral	III	29°02'	71°26'
229							Copiapó	III	27°22'	70°20'
230							Coquimbo	III	29°57'	71°20'
231							Tierra Amarilla	III	27°29'	70°17'
232							Vallenar	III	28°34'	70°45'
233							Diego de Almagro	II	26°22'	70°03'
234							La Serena	II	29°54'	71°15'

Figura 16: Excel que contiene el valor de la escala IMM de todos los sismos sensibles ocurridos entre los años 2007 a 2015

Luego de realizar la asociación antes mencionada, los registros se reducen a 749, que corresponden a 210 eventos. Esto es debido a que no existe información del valor de IMM para todos los registros que se tiene, ya que el Excel de Fernando Muñoz solo contiene los sismos sensibles, y por otro lado para el lugar que se tiene valor de IMM puede no coincidir con el lugar donde se encuentra la estación del registro en cuestión.

Los registros ya se encuentran filtrados por NGA (programa desarrollado por R. Boroschek) y luego por el periodo de corte asociado, teniendo la aceleración, velocidad y desplazamiento procesados. Con los cuales se calculan los parámetros necesarios.

Los parámetros en general se calculan como un valor para cada componente del registro, es decir, se va a tener un valor asociado a la dirección EW, NS y Z, independientes entre sí. Pero algunos utilizan la aceleración en dos o tres direcciones para su cálculo generando un solo valor, como es la Intensidad Sísmica de la Agencia Meteorológica de Japón y la Intensidad de Housner.

El cálculo de cada uno de ellos se realiza como se describe en el Capítulo 2.

En total son 16 parámetros distintos. Y dado que para la mayoría de ellos se tiene más de un valor, se tienen 45 valores que se introducirán como input en los distintos métodos estadísticos. Esto se resume en la Tabla 1.

Tabla 1: Parámetros de entrada

Parámetro		EW	NS	Z
PGA				
PGV				
Duración fase fuerte				
Ia				
SI				X
IJMA				
CAV				
Cruces por cero				
Frecuencia Central				
Profundidad				
Distancia de la estación al hipocentro				
Fuente Sismogénica				
Espectro de Desplazamiento S_d	$T = 0.2[s]$			
	$T = 1[s]$			
Espectro de Velocidad S_v	$T = 0.2[s]$			
	$T = 1[s]$			
Espectro de Aceleración S_a	$T = 0.2[s]$			
	$T = 1[s]$			
Tipo de Suelo				

4.2 Análisis parámetros

Una vez que los parámetros son calculados se realizan algunos gráficos para observar la relación que existe entre cada uno de ellos y la Intensidad de Mercalli Modificada (Anexo B), la relación entre cada parámetro y los demás (Anexo C), y por último un histograma de cada uno de ellos y de la IMM para observar la distribución de valores que tienen los datos con los que se trabaja (Anexo A).

De la realización de estos gráficos se rescata que para algunos de ellos es conveniente usar el logaritmo en base 10 del parámetro. De esta forma es posible observar una tendencia en los valores de la variable versus la Intensidad de Mercalli Modificada. En particular estos parámetros son: PGA, PGV, SI, Ia y CAV.

En la Figura 17 y Figura 18 es posible observar el cambio entre usar el parámetro sin o con logaritmo en base 10 para las variables mencionadas. Y en la Figura 19 un ejemplo de variables en las que el uso del logaritmo en base 10 no genera diferencia en la relación observada entre este y la IMM.

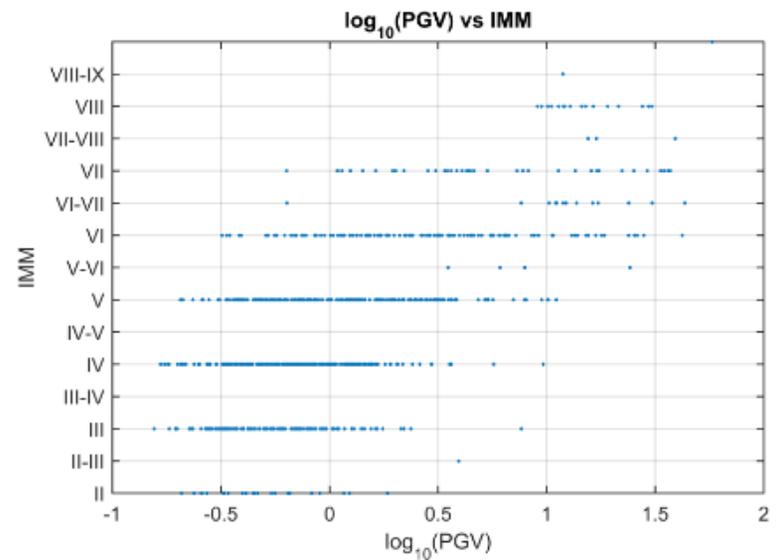
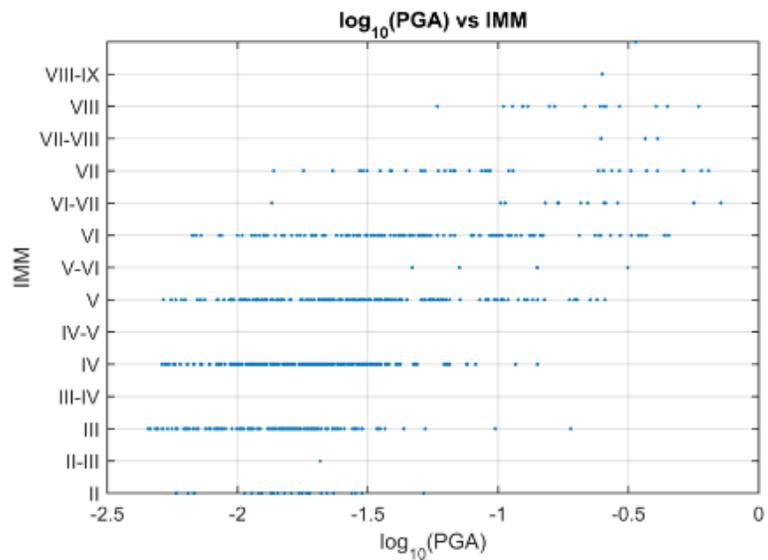
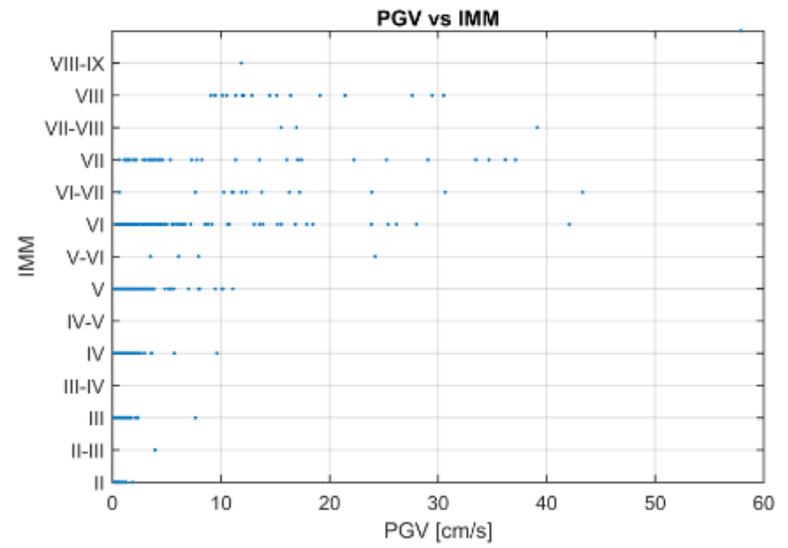
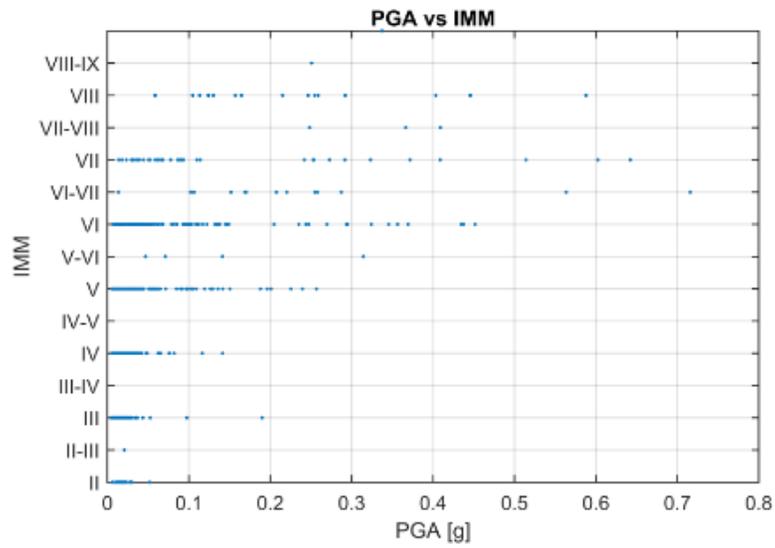


Figura 17: Comparación relación entre PGA-IMM y PGV-IMM con y sin uso de logaritmo en base 10

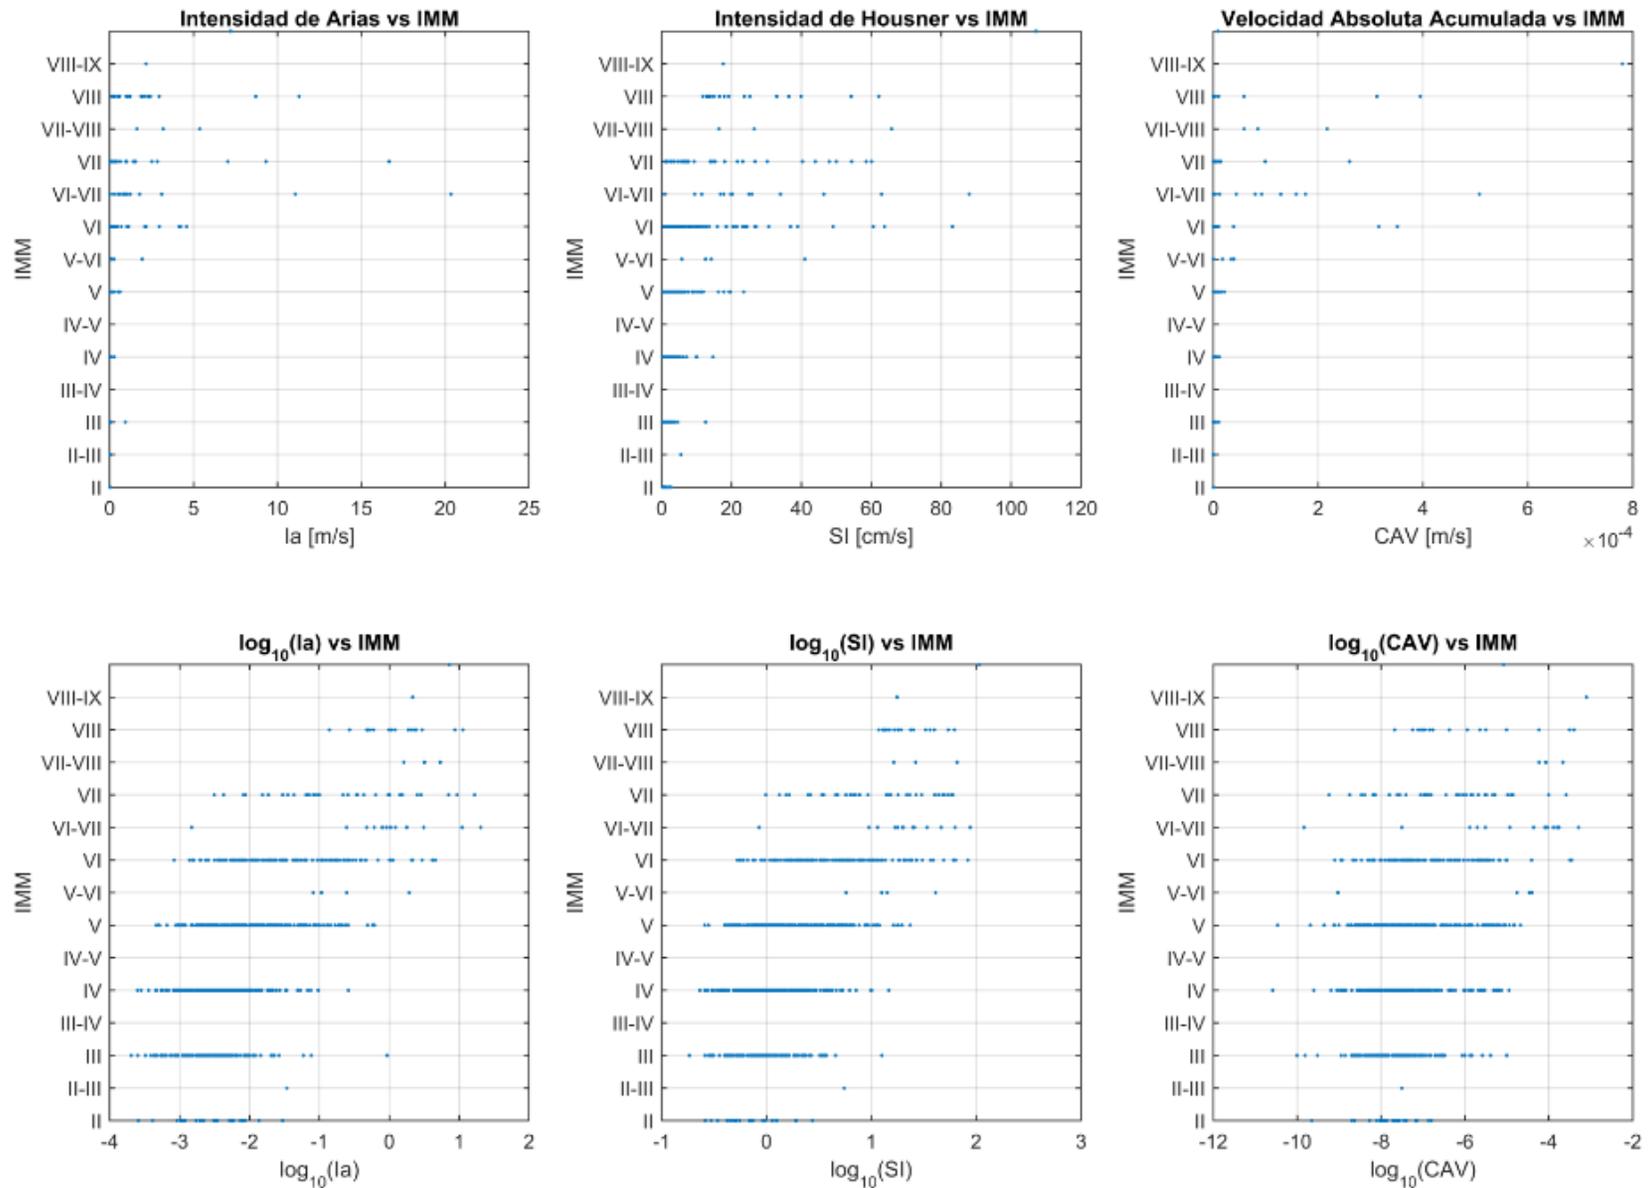


Figura 18: Comparación relación entre I_a -IMM, SI -IMM y CAV -IMM con y sin uso de logaritmo en base 10

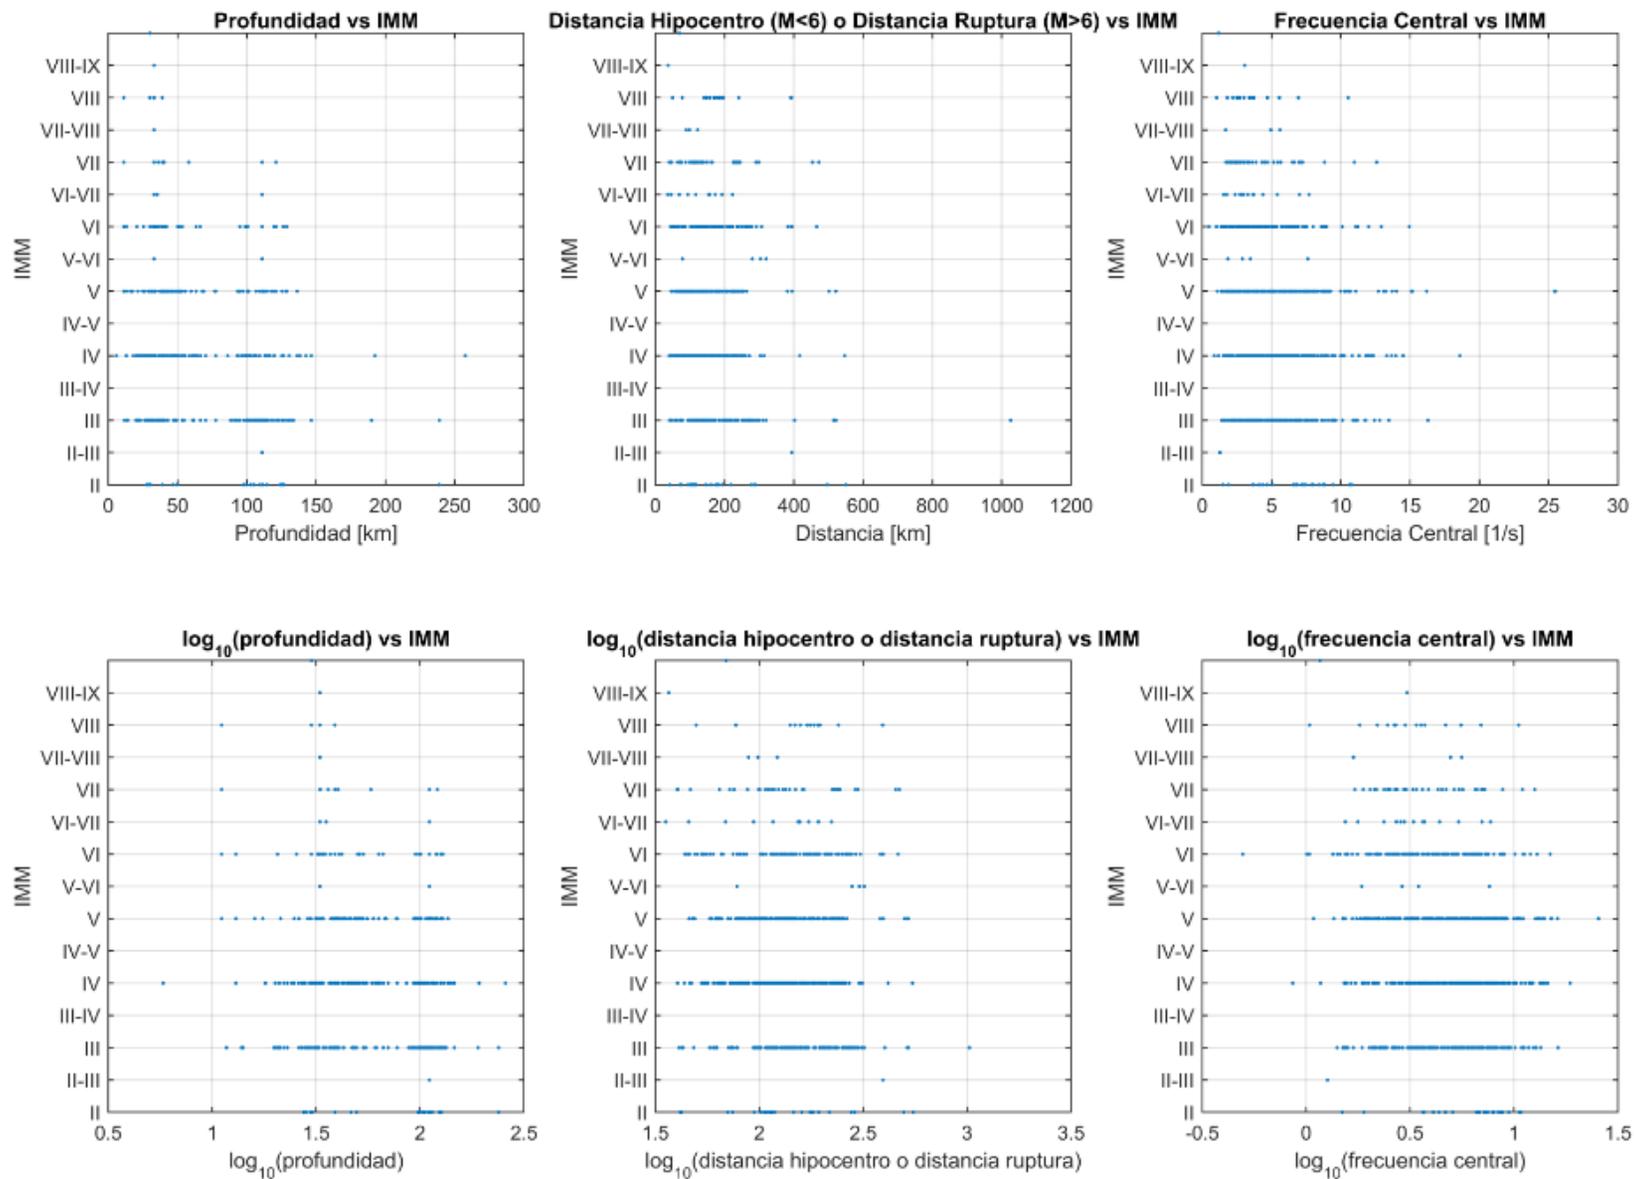


Figura 19: Comparación relación entre Profundidad-IMM, Distancia Hipocentro-IMM y Frecuencia Central-IMM con y sin uso de logaritmo en base 10

CAPÍTULO 5: PRUEBA DE MÉTODOS DE CLASIFICACIÓN

Este capítulo permite la familiarización con cada uno de los métodos de clasificación mencionados en el Capítulo 3. Se muestra la implementación en el software Matlab utilizando un set de datos “artificiales”. Este set de datos corresponde a 792 registros de cinco parámetros instrumentales calculados a partir de registros de aceleraciones los cuales son: PGA, PGV, IJMA, Ia y SI; y del valor IMM informado asociado a cada una de las observaciones. Los valores de la escala de la Intensidad de Mercalli Modificada pueden ir desde I a XII incluyendo valores entre escalas, como por ejemplo: I-II, II-III,..., VI-VII, etc. El vector de datos utilizados para estas pruebas contiene valores desde I-II a IX.

Ambos métodos trabajan con variables de entrada y variable/s de salida. Los parámetros instrumentales corresponden a las variables independientes o variables predictoras (variables de entrada). El valor de IMM es la variable dependiente o variable de respuesta (variable de salida).

5.1 Redes Neuronales Artificiales

Se utiliza el Toolbox de Redes Neuronales de Matlab 2015a.

5.1.1 Manejo del set de datos

En Matlab las Redes Neuronales Artificiales trabajan con variables numéricas, por lo que los valores nominales de IMM (números romanos) deben transformarse a números arábigos. Se elige asignarle el valor en números arábigos al correspondiente número romano en el caso de los valores asociados a un solo valor, y aquellos valores de la escala de IMM que están entre dos valores asignarles “la mitad” entre dos números arábigos consecutivos (Tabla 2).

Tabla 2: Transformación de números romanos a números arábigos de los valores de IMM

Valor Escala de Mercalli	Valor set de datos
I y II	1.5
II	2
II y III	2.5
III	3
III y IV	3.5
IV	4
IV y V	4.5
V	5
V y VI	5.5
VI	6
VI y VII	6.5
VII	7
VII y VIII	7.5
VIII	8
VIII y IX	8.5
IX	9

El set de datos se divide en tres sub-conjuntos de 60%, 20% y 20% del total, correspondientes a set de entrenamiento, validación y prueba respectivamente. Los datos que se utilizan para validación y prueba no deben estar contenidos en los valores seleccionados para entrenamiento, ni coincidir entre ellos.

El set de entrenamiento es el que se utiliza para entrenar la red, el set de validación sirve para identificar y evitar el sobre-ajuste y el set de prueba se utiliza una vez que se ha creado el modelo para comparar los resultados de salida del modelo con los valores de la IMM informados para el respectivo registro.

Previo a la división del set de datos estos se ordenan de acuerdo al valor de la Intensidad de la escala de Mercalli Modificada, ya que el set de datos de entrenamiento y validación debe ser heterogéneo (contener todo el rango de valores de la IMM). Los datos restantes conforman el set de prueba.

5.1.2 Entrenamiento de la red

Primero se crea la red neuronal tipo *feed forward* con la función del Toolbox de Matlab *newff* como sigue:

```
net=newff(P,T,S)
```

donde:

P: Set de datos de parámetros instrumentales de entrenamiento

T: Set de datos del valor de la Intensidad de Mercalli Modificada informada de entrenamiento

S: Número de neuronas en la capa oculta

Para el caso de los datos utilizados se determina que la capa oculta contiene 3 neuronas.

```
net=newff(X_train,Y_train,3);
```

El número de neuronas en la capa oculta se determina “manualmente”, es decir se comienza con una neurona en esta capa y se observa, en este caso, el porcentaje de clasificación correcto. Se adiciona una neurona y se vuelve a determinar el desempeño del modelo, se realiza esto hasta que ya no se observa un aumento significativo en el porcentaje de clasificación.

Luego se deben fijar algunos parámetros como el número máximo de *epoch*, el valor del error máximo aceptado (*goal*, con este valor se detiene el entrenamiento), las funciones de transferencia de la capa oculta y salida y la función de entrenamiento.

Definición del número de *epoch* y error máximo

```
net.trainParam.epochs=300;  
net.trainParam.goal=1e-5;
```

Las funciones de transferencia que se utilizan son:

```
net.layers{1}.transferFcn = 'tansig'; % capa oculta  
net.layers{2}.transferFcn = 'purelin'; % capa de salida
```

Para la definición de las funciones de transferencia de cada capa se prueban todas las que proporciona el Toolbox de Redes Neuronales de Matlab, y estas son las que arrojan mejores resultados. Además, coinciden con las funciones de transferencia más utilizadas en RNA.

La función de entrenamiento que se utiliza es la de Levenberg-Marquardt:

```
net.trainFcn = 'trainlm';
```

Por último, el entrenamiento de la red se realiza con el comando *train* de Matlab:

```
[net,tr]=train(net,X_train,Y_train,[],[],val);
```

donde:

net: Red neuronal creada con la función *newff*

X_train: Set de datos de parámetros instrumentales de entrenamiento

Y_train: Set de datos del valor de la Intensidad de Mercalli Modificada informada de entrenamiento

val: Set de datos de validación, contiene las variables de entrada y la variable de salida

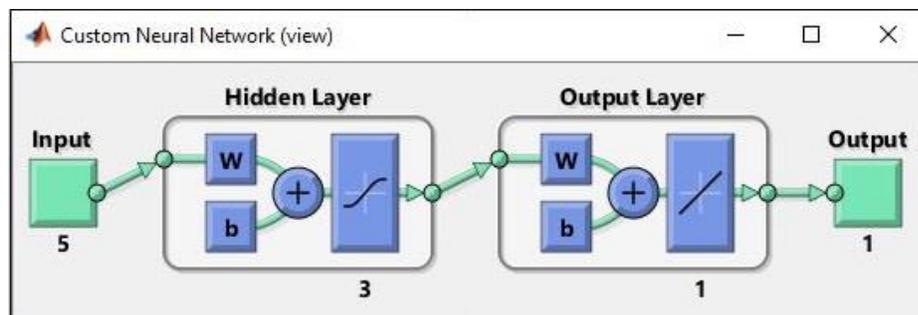


Figura 20: Estructura Red Neuronal. (Fuente: Matlab, resultado entrenamiento de la RNA)

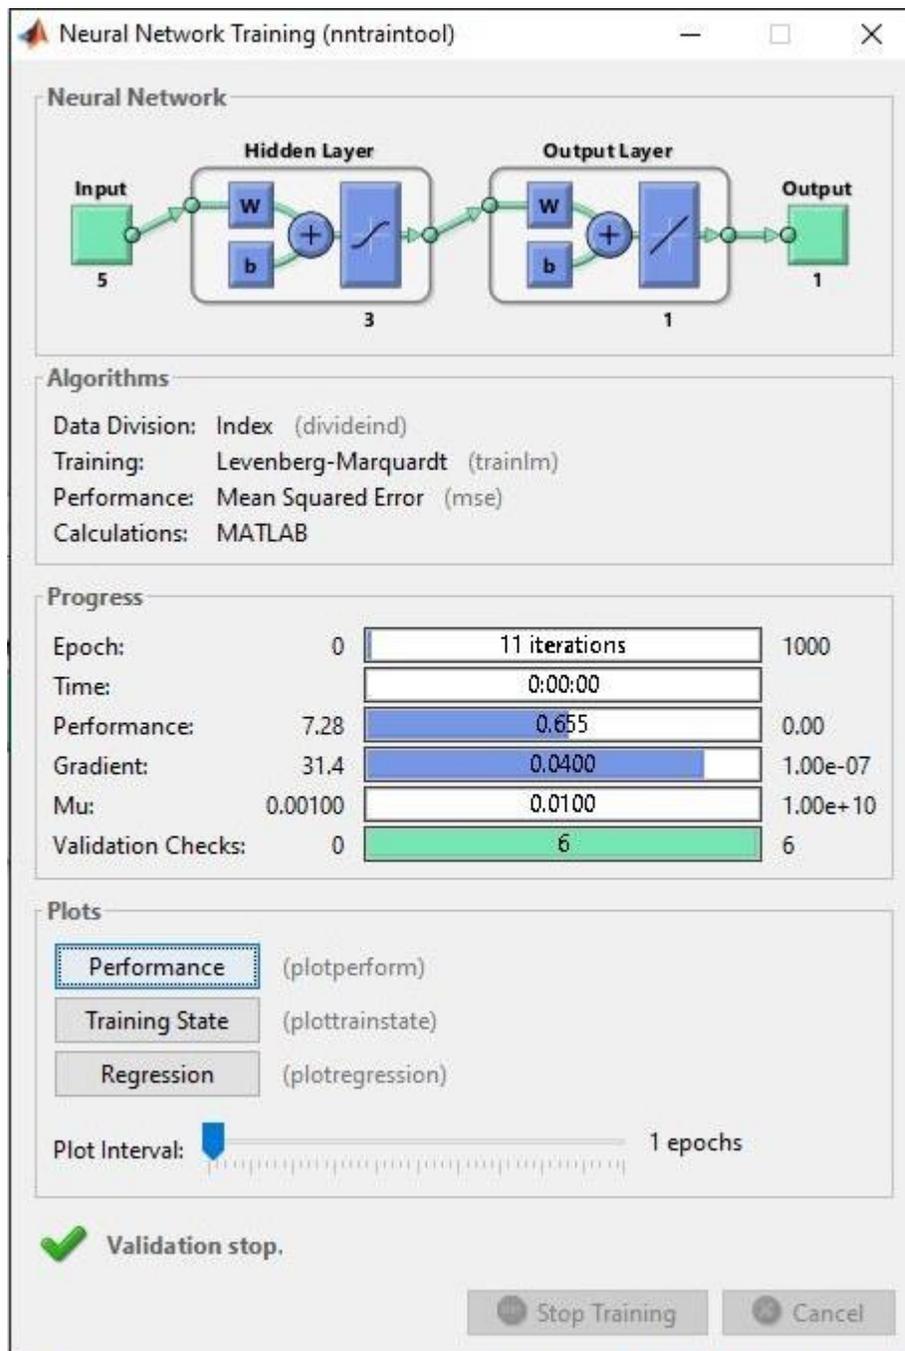


Figura 21: Interfaz entrenamiento Redes Neuronales en Matlab. (Fuente: Matlab, resultado entrenamiento de la RNA)

5.1.3 Prueba de la Red Neuronal

La prueba del modelo generado mediante el método de Redes Neuronales Artificiales se realiza con la función *sim* y utilizando la matriz de parámetros instrumentales seleccionados para el set de prueba, lo que genera un vector de salida. Dado que en este caso la función de transferencia para la capa de salida es la función lineal (*purelin*) los valores obtenidos pertenecen a los \mathbb{R} por lo que para llevarlos a los valores con los que se realiza la clasificación, se realiza la siguiente aproximación: para valores con decimales ≤ 0.25 serán llevados al entero menor; para valores con decimales ≥ 0.75 serán llevados al entero mayor; y para valores de decimales > 0.25 y < 0.75 serán llevados al número con decimal 0.5, que corresponde a aquellos valores de IMM entre escalas.

```
Y_output=sim(net,X_prueba);
```

donde:

Y_output: Vector de predicciones generado por el modelo de Redes Neuronales

net: Red neuronal creada con la función newff

X_prueba: Matriz de 5x158 de los parámetros instrumentales seleccionados para prueba

El vector de predicciones, con los valores \mathbb{R} ya aproximados, se compara con el vector de datos de valores de la escala de Mercalli Modificada previamente seleccionado para prueba (Y_prueba), de esta forma se determina el porcentaje de clasificación correcta que realiza el modelo.

Con este modelo el porcentaje correcto de clasificación es de aproximadamente el 27%. Además, de la Figura 22 se desprende que un 87.3% de los registros son clasificados en el rango $[-1,1]$, y considerando el rango $[0,1]$ el porcentaje es de 56.3%. Al considerar solo este último rango se podría decir que el modelo actúa de forma conservadora. Sin embargo, si se consideran todos los demás valores, un 34.2% de los registros son clasificados en un valor mayor al informado por la ONEMI versus un 38.6% de los registros son clasificados con un valor menor.

De la Figura 23 se observa que las salidas del modelo se concentran entre los valores III y IV de la IMM. Por otro lado, existe un alto número de predicciones para el valor III-IV aunque el número de registros del set de pruebas asociados a este valor es 3 veces menor. Lo anterior se puede deber a que la salida del modelo es un número continuo que se debe aproximar, y en esta aproximación tan solo por una diferencia pequeña puede ser llevado a este valor en vez de a los valores III o IV.

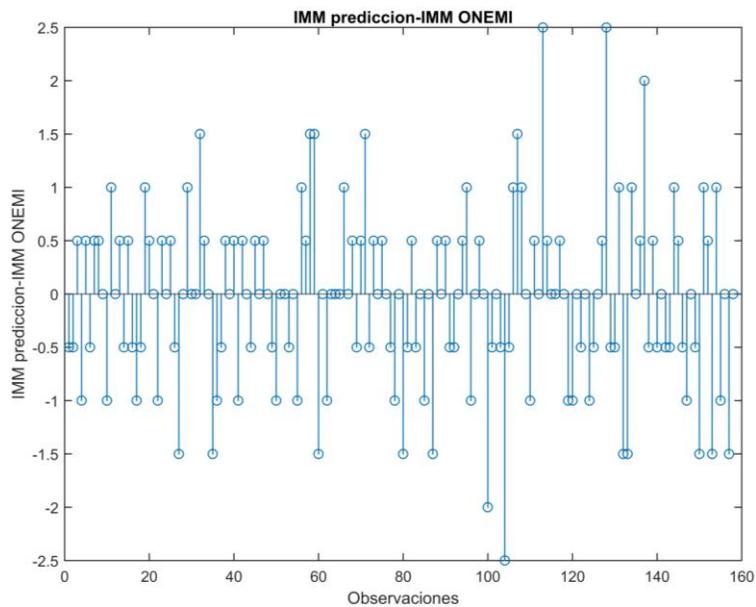


Figura 22: Diferencia entre IMM predicho e IMM informado por la ONEMI. Red Neuronal Artificial.

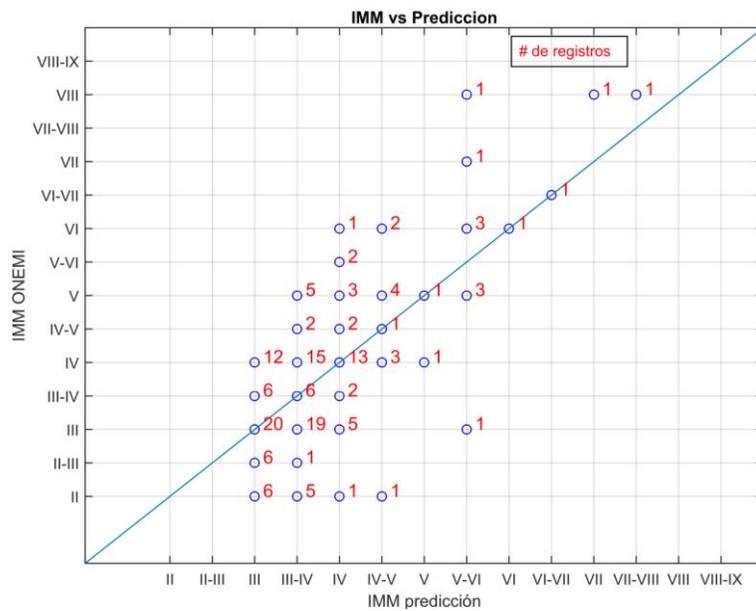


Figura 23: Predicción de IMM vs IMM ONEMI. Red Neuronal Artificial.

5.2 Regresión Logística Multinomial

5.2.1 Manejo del set de datos

Se trabaja con los datos de dos formas distintas. En el primer caso se utilizan todos los valores de la escala de Mercalli como una clase individual. En el segundo caso se agrupan ciertos valores en una clase, en este caso se trabaja con cinco clases que son descritas en la Tabla 4.

Para ambos casos el set de datos utilizados se divide en dos sub-conjuntos, el primero corresponde al set de entrenamiento que contiene un 60% del total de datos, y el restante 40% es utilizado como set de prueba. Para la división del set de datos, primero se ordenan de acuerdo al valor de la escala de Mercalli para que el set de datos de entrenamiento sea heterogéneo.

Las observaciones que pertenecen al set de entrenamiento no pueden pertenecer al set de prueba.

Para el primer caso, dado que Regresión Logística trabaja con datos nominales, como se tienen valores del estilo 1.5, 2.5, que corresponden a los valores de la escala de Mercalli I-II, para el primer caso; y II-III para el segundo, se trabaja con los valores numéricos mostrados en la Tabla 3. Se asigna el valor de la clase 2 al valor más bajo de la IMM que contiene el set de datos (I-II) y así se va sumando una clase por cada valor distinto que posee el set de datos, hasta alcanzar la clase 17 asociado al valor IX.

Tabla 3: Valores vector de salida para Regresión Logística

Valor Escala de Mercalli	Valor set de datos	Valor con el que se trabaja (clases)
I y II	1.5	2
II	2	3
II y III	2.5	4
III	3	5
III y IV	3.5	6
IV	4	7
IV y V	4.5	8
V	5	9
V y VI	5.5	10
VI	6	11
VI y VII	6.5	12
VII	7	13
VII y VIII	7.5	14
VIII	8	15
VIII y IX	8.5	16
IX	9	17

Se debe tener presente que el valor con el que se trabaja es un valor nominal, es decir que no influye en sí su valor.

Para el segundo caso los datos se agruparán en cinco clases de la siguiente manera en:

Tabla 4: Valores vector de salida para Regresión Logística Multinomial agrupados en 5 clases

Valor Escala de Mercalli	Valor set de datos	Valor clase
I y II	1.5	1
II	2	1
II y III	2.5	1
III	3	1
III y IV	3.5	1
IV	4	2
IV y V	4.5	2
V	5	2
V y VI	5.5	2
VI	6	3
VI y VII	6.5	4
VII	7	5
VII y VIII	7.5	5
VIII	8	5
VIII y IX	8.5	5
IX	9	5

5.2.2 Método de Regresión Logística Multinomial en Matlab

De acuerdo a la Ecuación 3.4, el método de RLM se basa en determinar una regresión lineal de las variables independientes (α_i), donde los coeficientes son calculados utilizando la estimación por máxima verosimilitud.

Para este método los coeficientes de la mencionada regresión lineal se calculan de dos formas:

Forma 1: Función *mnrfit* de Matlab

Se utilizan los datos de entrenamiento (X_{train} y T_{train}) y la función que genera una regresión logística (*mnrfit*), se obtiene una matriz b de $(m+1) \times (n-1)$, con m igual al número de parámetros utilizados como input; y n el número de clases con el que se trabaja. Esta matriz contiene los coeficientes β_0 a β_j de la regresión lineal de la ecuación que representa al modelo de Regresión Logística Multinomial.

Forma 2: Mínimos Cuadrados Parciales (PLS, siglas por su nombre en inglés)

Primero, se utilizan todos los registros del set de datos (X y T) y con la función *mnrfit* se realiza una regresión logística, con esto se obtiene la matriz b con los coeficientes de la regresión lineal. Luego, con la matriz b , la matriz de las variables independientes (X) y la función *mnrval* se genera una matriz con las posibilidades de pertenecer a cada clase. La matriz obtenida se utiliza en PLS como los valores de la variable dependiente, en vez de los valores de IMM.

Se utiliza el método PLS para determinar la matriz b , para esto solo se trabaja con un set de datos de entrenamiento (60% de los registros), el cual coincide con el set de entrenamiento de la RLM, ya que los datos de entrenamiento no pueden pertenecer al set de datos de prueba.

5.2.3 Prueba de la Regresión Logística Multinomial

Con la matriz b obtenida (independiente de la forma en la que se obtuvo) y los datos de prueba de los parámetros instrumentales se utiliza una función de Matlab (*mnrval*) que entrega las posibilidades de pertenecer a cada clase, asociada a cada observación.

Luego, para poder clasificar los resultados, y asignarle una sola clase a cada observación, se considera la clase con la mayor posibilidad como el valor de la escala de Mercalli. De esta forma se obtiene un valor de escala de Mercalli para cada observación del grupo de datos de prueba.

Para determinar el porcentaje de clasificación correcta se compara el resultado obtenido del paso anterior con los valores de IMM pertenecientes al grupo de *targets* de prueba. Además, se compara este valor con las clases asociadas a la segunda y tercera mayor posibilidad.

Los resultados obtenidos mediante este método considerando 17 clases, es un porcentaje de clasificación del 37.3% si se considera solo la primera posibilidad. Al considerar la segunda y tercera, el porcentaje total es del 78.1%.

De la Figura 24 se tiene que un 89.9% de los valores de salida del modelo están en el rango [-1,1], es decir que presentan máximo 1 grado de diferencia con el valor informado por la ONEMI. Y si se considera el rango [0,1] el porcentaje es de 61.7%. Al considerar solo este último rango se podría decir que el modelo actúa de forma conservadora. Sin embargo, si se consideran todos los demás valores, un 29.7% de los registros son clasificados en un valor mayor al informado por la ONEMI versus un 32.9% en que los registros son clasificados con un valor menor.

En la Figura 25 se puede observar el desempeño del modelo por cada clase.

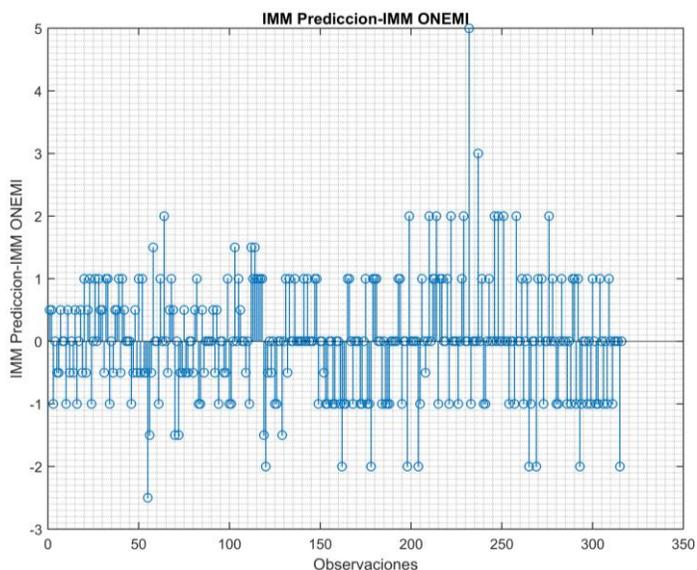


Figura 24: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases.

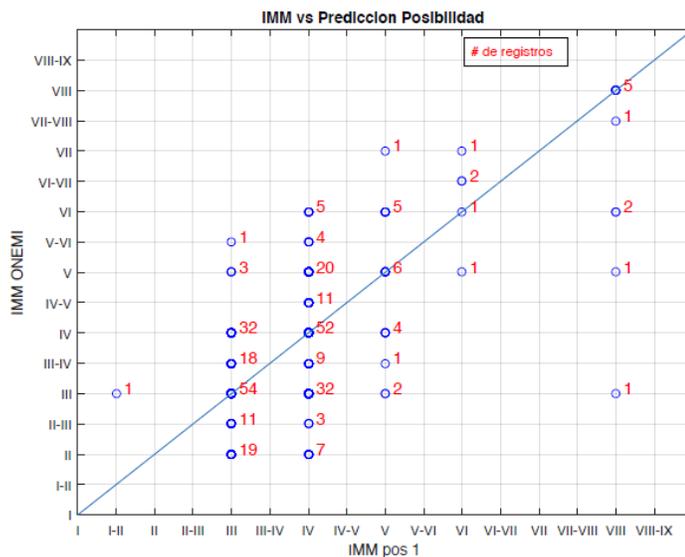


Figura 25: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases.

Los resultados obtenidos mediante este método considerando 5 clases, es un porcentaje de clasificación del 64.6% si se considera solo la primera posibilidad. Al considerar la segunda y tercera, el porcentaje total es del 98.1%.

De la Figura 26 se tiene que un 98.4% de los valores de salida del modelo están en el rango [-1,1]. Si bien este es un porcentaje bastante alto, en este caso la diferencia de una clase no corresponde a 1 grado de la escala de MM, sino como estas están agrupadas en clases, la diferencia de una clase puede llegar a ser una diferencia máxima de 3 grados. Y debido a que están agrupadas en clases no se puede saber cuál es la diferencia real.

En la Figura 27 se puede observar el desempeño del modelo por clase.

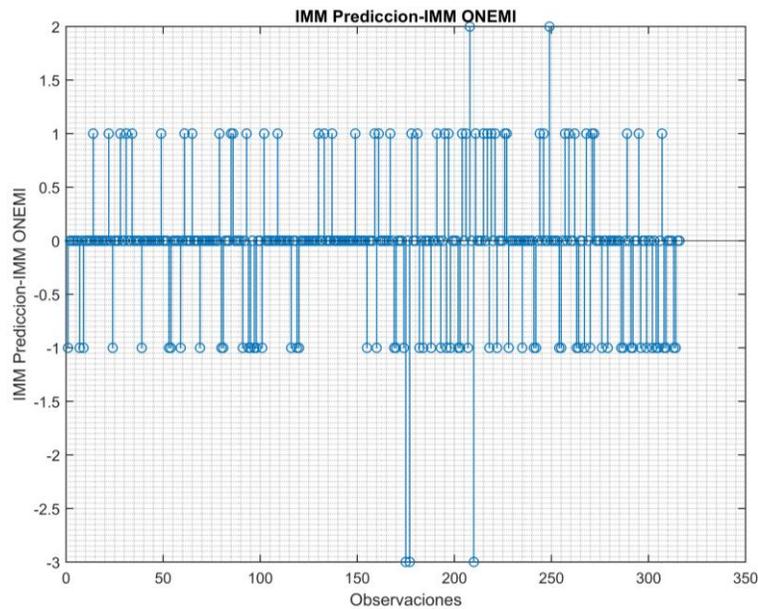


Figura 26: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases.

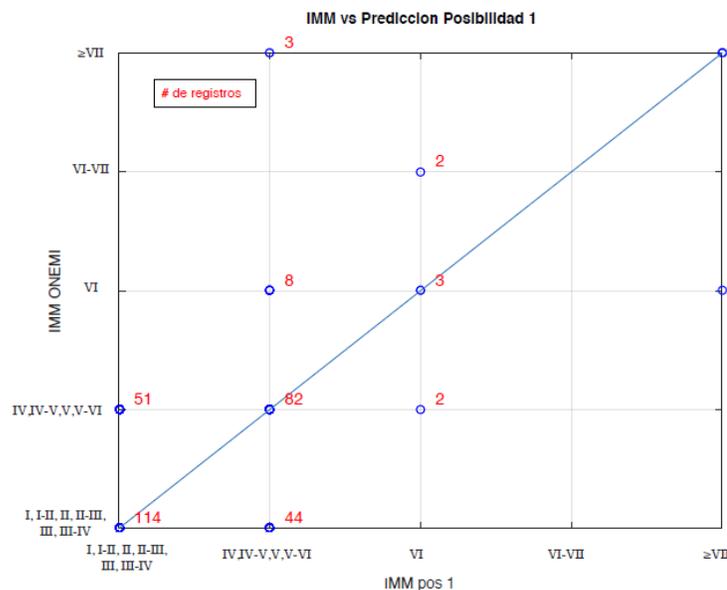


Figura 27: Predicción de IMM vs IMM ONEMI. RLM 5 clases.

5.3 Resumen Resultados

Tabla 5: Resumen porcentajes de clasificación de registros (RNA por parámetro)

Modelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
RNA	27.0	87.3	56.3
RL 17 clases	37.3 (solo primera posibilidad)	89.9	61.7
RL 5 clases	64.6 (solo primera posibilidad)	98.4(*)	79.1(*)

(*) La diferencia de una clase no corresponde a 1 grado de la escala de MM, sino como estas están agrupadas en clases, la diferencia de una clase puede llegar a ser una diferencia máxima de 3 grados.

De la Tabla 5 se compara el modelo de RNA con el de RLM 17 clases, el de RLM 5 clases no es comparable por que las salidas del modelo no son las mismas que para los otros dos. Al compararlos se observan mejores resultados para el modelo de Regresión Logística Multinomial (17 clases) que para Redes Neuronales Artificiales, una diferencia de 10 puntos porcentuales del porcentaje de clasificación correcta, diferencia que disminuye si se consideran los rangos [-1,1] y [0,1], pero manteniéndose levemente superior RLM.

CAPÍTULO 6: APLICACIÓN DE MÉTODOS DE CLASIFICACIÓN

Para la evaluación de ambos métodos, Redes Neuronales Artificiales y Regresión Logística Multinomial, se utilizan los datos obtenidos en el Capítulo 4.

Se generan varios modelos para cada uno de los métodos dependiendo de diferentes criterios. Algunos de ellos son comunes para ambos. El primer criterio corresponde al tipo de suelo donde se ubica la estación en donde fue grabado el registro, generando 5 casos distintos (Criterio 1):

1. Caso 0: Todos los tipos de suelo
 Caso 1: Solo suelo tipo A (roca dura)
 Caso 2: Solo suelo tipo B
 Caso 3: Solo suelo tipo C
 Caso 4: Todos los suelos menos roca dura

El set de datos que se tiene formado por 749 registros, dependiendo del método utilizado y el caso según el tipo de suelo, se divide en sub conjuntos de entrenamiento, validación y prueba. Para el caso de Redes Neuronales Artificiales y en sub conjuntos de entrenamiento y prueba para Regresión Logística Multinomial.

Tabla 6: Conjunto de datos y división en sub conjuntos de entrenamiento, validación y prueba para Redes Neuronales Artificiales. Casos según criterio 1.

Caso	Registros Totales	Set de Entrenamiento	Set de Validación	Set de Prueba
0	749	450	150	149
1	48	29	10	9
2	212	128	42	42
3	304	183	61	60
4	701	421	140	140

Tabla 7: Conjunto de datos y división en sub conjuntos de entrenamiento, validación y prueba para Regresión Logística Multinomial. Casos según criterio 1.

Caso	Registros Totales	Set de Entrenamiento	Set de Prueba
0	749	450	299
1	48	29	19
2	212	128	84
3	304	183	121
4	701	421	280

Los tres primeros criterios mencionados a continuación son comunes para ambos métodos, el cuarto es solo aplicado a Regresión Logística Multinomial.

2. Normalización de los valores de las variables predictoras: Esta normalización es la utilizada por Alvarez, Hurtado y Bedoya en su trabajo "Prediction of modified Mercalli intensity from PGA, PGV, moment magnitude, and epicentral distance using several nonlinear statistical algorithms" [2]. Cada uno de los valores de las variables predictoras es llevado al intervalo [-1,1].

$$z_k = 2 \frac{X_k - \min(X_k)}{\max(X_k) - \min(X_k)} - 1$$

donde:

z_k : Valor final de cada observación para variable predictora k .

X_k : Valor original de cada observación para variable predictora k .

3. Para los parámetros que poseen un valor distinto para cada dirección (transversal, longitudinal y vertical) se calcula la media geométrica entre el valor de la dirección transversal con la longitudinal generando un valor que corresponde a la dirección horizontal.
4. Eliminación de algunos parámetros según el análisis del *loading plot* generado mediante Mínimos Cuadrados Parciales (PLS).
5. Realizar la regresión lineal α_i , necesaria para determinar la posibilidad de pertenecer a cada clase, mediante PLS.

Para el criterio número 4 se realiza PLS para generar el *Loading Plot*, como se explica en el Capítulo 3 (Sección 3.3), y con el análisis de este se define qué parámetros se eliminan del set de variables predictoras.

Como se observa en la Figura 28 los input que se encuentran más cercanos al origen, (coordenada 0,0) son los cruces por cero, la frecuencia central y la distancia al hipocentro, por esto estos son los parámetros seleccionados para eliminar del set de variables predictoras (decisión arbitraria). Además se observa que $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{Ia})$, $\log(\text{SI})$ e IJMA son las variables independientes que más información aportan al modelo. Esto coincide con lo observado en los gráficos (Anexo B) donde se muestra la relación que existe entre los valores de la Escala de Mercalli y cada una de las variables predictoras, y estas son las que presentan una relación visible entre cada una de ellas e IMM.

Por otro lado, en la Figura 28 es posible observar grupos de variables que se encuentran cercanas entre sí, es decir que tienen una ubicación similar en el plano observado. Esto se condice con lo observado en el Anexo C, donde se muestra la relación entre las distintas variables predictoras. En este caso las que se encuentran más alejadas del origen: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{Ia})$, $\log(\text{SI})$ e IJMA están fuertemente correlacionadas entre sí. El grupo encerrado en un cuadro purpura corresponden a los espectros de desplazamiento, velocidad y aceleración tanto para el periodo $T=0.2$ [s] y $T=1$ [s]; y CAV. Nuevamente esto tiene relación con lo observado en el Anexo C, donde se muestra que los distintos espectros para un mismo periodo y dirección (vertical u horizontal) tienen una relación lineal, y si bien entre los distintos espectros, en el caso que no coincide periodo ni dirección la relación no es tan marcada, igualmente se observa una correlación entre ellas. Dentro de este mismo grupo se encuentra el parámetro CAV, parámetro con el cual es posible observar una correlación entre este y los espectros, esto probablemente debido a que su cálculo está basado en el espectro de velocidad.

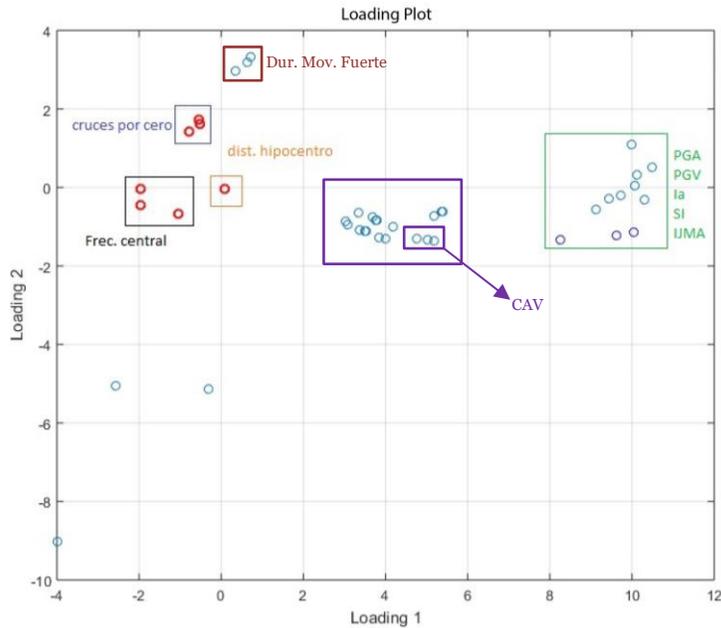


Figura 28: *Loading Plot*, define el nivel de información que aporta cada variable para realizar la regresión. Los parámetros que se encuentran encerrados por el cuadro verde son las que mayor información de la varianza de los datos aportan: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(Ia)$, $\log(\text{SI})$ e IJMA .

6.1 Redes Neuronales Artificiales

De la misma manera que se describe en el Capítulo 5 se realiza el manejo de datos, el entrenamiento de la red neuronal y la prueba de esta.

Además, se realiza un modelo aparte del descrito en el Capítulo 5, Sección 5.1.1. Este consiste en el trabajo con 5 parámetros de los 16 calculados en el Capítulo 4: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{SI})$, $\log(Ia)$ e IJMA , utilizando solo uno a la vez.

6.1.1 Red Neuronal Artificial utilizando 16 parámetros

La estructura de la Red Neuronal utilizada para el entrenamiento de los datos se muestra en la Figura 29.

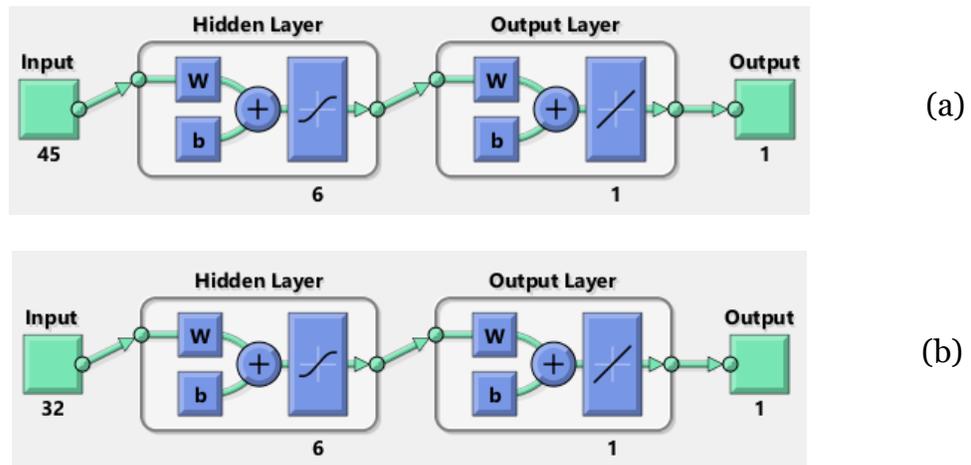


Figura 29: Estructura Red Neuronal

La Figura 29 muestra que la Red Neuronal Artificial está formada por tres capas de neuronas. La capa de entrada está formada por (Figura 29 (a)) 45 neuronas que corresponde al número total de parámetros, considerando para cada uno de ellos dirección transversal, longitudinal y vertical en el caso que corresponda; o por (Figura 29 (b)) 32 neuronas en el caso que se ha calculado la media geométrica de la dirección transversal y longitudinal; la capa oculta está formada por 6 neuronas (el número de neuronas se determina mediante la forma descrita en la Sección 5.1.2), con una función de transferencia o activación *tansig*; y la capa de salida por 1 neurona, con una función de transferencia *purelin*. La función de entrenamiento que se utiliza es la de Levenberg-Marquardt backpropagation (*trainlm*).

La neurona de salida es una, ya que la red entrega el valor de la Escala de Mercalli Modificada, que puede ir desde I hasta XII, pero en este caso solo se entrena la red con valores hasta IX, por lo que solo puede entregar hasta este valor.

El número de modelos generados, considerando los diferentes criterios mencionados anteriormente, son 40 (8 modelos por cada caso dependiente del tipo de suelo). En la Tabla 8 se muestra a qué corresponde cada uno de los 8 modelos, el valor 1 es si está aplicado el criterio y 0 si no.

Tabla 8: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Eliminación de Variables
1	1	1	1
2	1	1	0
3	1	0	0
4	0	0	0
5	0	0	1
6	0	1	1
7	0	1	0
8	1	0	1

Tabla 9: Resumen porcentajes de clasificación según caso por tipo de suelo y casos según criterios utilizados

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
1	18.1	33.4	16.7	11.7	13.6
2	14.8	11.2	21.4	10.0	8.6
3	19.5	33.4	16.7	25.0	20.0
4	18.8	33.4	14.3	16.7	29.3
5	25.5	22.3	11.9	21.7	30.7
6	16.8	11.2	16.7	25.0	17.9
7	20.8	11.2	31.0	26.7	20.0
8	20.1	0.0	19.0	20.0	12.9

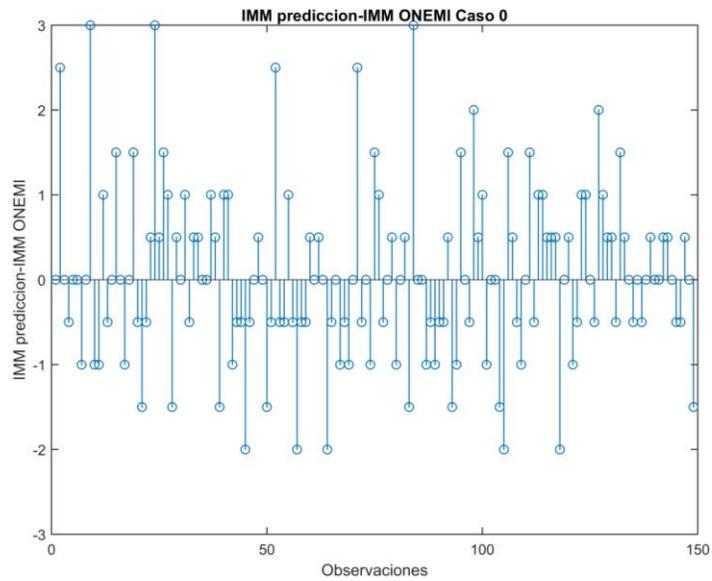
Se muestran los resultados del modelo que mejor desempeño tiene por caso según tipo de suelo. Los resultados del Caso 1 no son considerados ya que este corresponde al caso donde se consideran solo los registros asociados al suelo tipo A (roca dura), de los cuales se tienen solo 48 registros, por lo que son muy pocos para poder generar alguna conclusión. Por esto se muestran los resultados de cuatro modelos.

En la página 49 se observan las figuras que muestran la diferencia entre los valores de Intensidad de la Escala de Mercalli Modificada obtenidos mediante el modelo (predicción) y aquellos informados por la ONEMI (Para los modelos que muestran mejor desempeño).

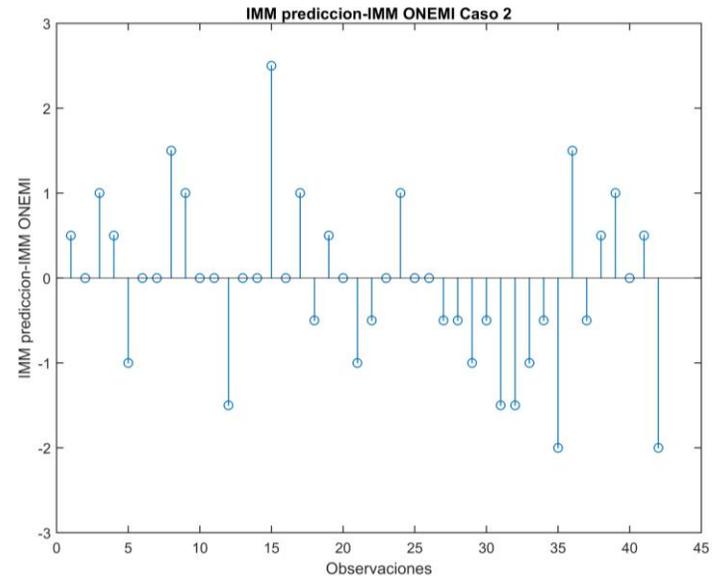
De ellos se puede desprender que en los cuatro casos aproximadamente el 60% de los registros son clasificados con una diferencia máxima en el valor de 0.5 grados, es decir que si se clasifica como IV podría corresponder a III-IV o IV-V; en tres de los 4 casos (Caso 0, Caso 2 y Caso 4) aproximadamente el 80% son clasificados con una diferencia máxima de 1 grado; y en los cuatro casos aproximadamente el 90% es clasificado con una diferencia máxima de 1.5 grados (Figura 31).

Se calcula el porcentaje de los registros del set de prueba que son clasificados correctamente y/o con un valor mayor para cada valor de IMM. En la Tabla 10 se observa que en general para los casos en que el valor de la Intensidad de la Escala de Mercalli es “entero” un 50% o más de las predicciones de los registros coinciden con el valor informado por la ONEMI, o bien con un valor informado mayor. Es decir, que para estos casos el modelo de Redes Neuronales Artificiales se comporta de manera conservadora. Para aquellos valores de la IMM en que están entre dos valores (Ej: III-IV, IV-V, etc.) el porcentaje, en la mayoría, es menor o igual al 50%.

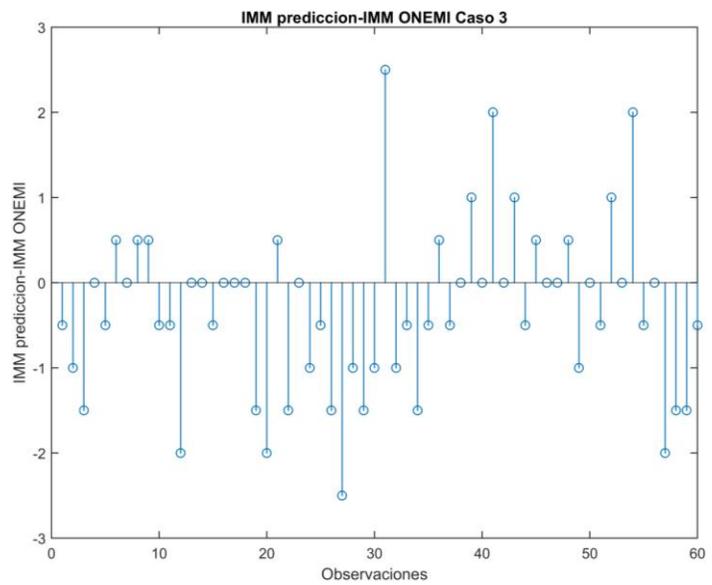
En la Tabla 11 se muestran los porcentajes de los registros del set de pruebas en que la predicción del valor de la IMM es igual o mayor en máximo 1 grado al valor informado por la ONEMI. Se observa que para la mayoría de los registros que están asociados a un solo valor de la escala de la IMM, el porcentaje es de aproximadamente un 50% o mayor. A diferencia de los registros asociados a una intensidad que está entre dos valores, en que este porcentaje va desde aproximadamente un 15% a un 50%.



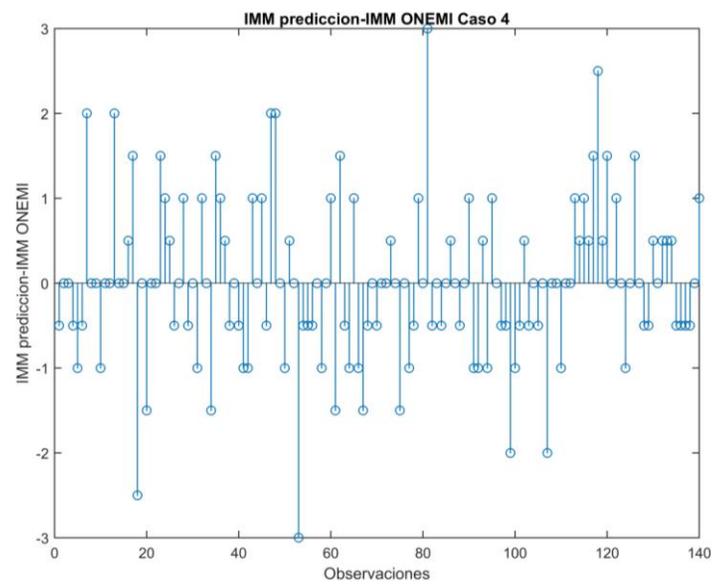
(a)



(b)



(c)



(d)

Figura 30: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) Caso 0, (b) Caso 2, (c) Caso 3, (d) Caso 4. Método RNA.

Tabla 10: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
0	--	-----	1/2	11/21	22/26	17/35	21/33	4/12	9/12	3/5	1/1	0/1	1/1	-----
	--	-----	50.0	52.4	84.6	48.6	63.6	33.4	75.0	60.0	100.0	0.0	100.0	-----
2	--	-----	-----	-----	8/8	3/13	7/11	1/1	2/3	1/1	3/3	0/1	-----	1/1
	--	-----	-----	-----	100.0	23.1	63.6	100.0	66.7	100.0	100.0	0.0	-----	100.0
3	--	-----	4/4	6/21	16/21	2/9	1/3	-----	0/2	-----	-----	-----	-----	-----
	--	-----	100.0	28.6	76.2	22.3	33.4	-----	0.0	-----	-----	-----	-----	-----
4	0/1	-----	6/9	8/18	21/27	13/26	23/29	3/13	7/9	1/2	2/2	2/4	-----	-----
	0	-----	66.7	44.5	77.8	50.0	79.3	23.1	77.8	50.0	100.0	50.0	-----	-----

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Tabla 11: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
0	--	-----	1/1	10/21	21/26	10/35	19/33	2/12	7/12	2/5	1/1	0/1	1/1	-----
	--	-----	100.0	47.6	80.8	28.6	57.6	16.7	58.4	40.0	100.0	0.0	100.0	-----
2	--	-----	-----	-----	8/8	2/13	7/11	0/1	2/3	0/1	2/3	0/0	-----	1/1
	--	-----	-----	-----	100.0	15.4	63.6	0.0	66.7	0.0	66.7	0.0	-----	100.0
3	--	-----	4/4	6/21	14/21	1/9	1/3	-----	0/2	-----	-----	-----	-----	-----
	--	-----	100.0	28.6	66.7	11.2	33.4	-----	0.0	-----	-----	-----	-----	-----
4	0/1	-----	5/9	8/18	20/27	6/26	19/29	2/13	7/9	1/2	2/2	2/4	-----	-----
	0	-----	55.6	44.5	74.1	23.1	65.5	15.4	77.8	50.0	100.0	50.0	-----	-----

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

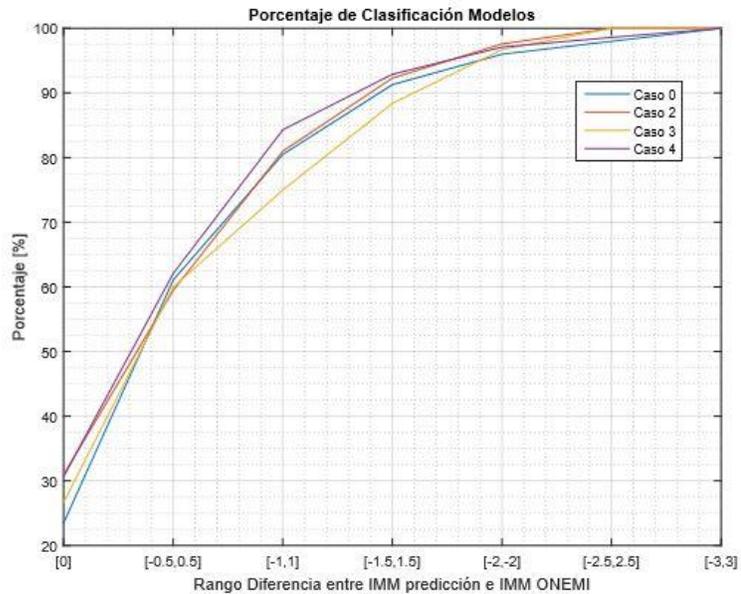


Figura 31: Porcentaje de clasificación por rango, para cada uno de los casos según tipo de suelo. Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

De la Figura 32 a la Tabla 35 se puede observar lo resumido en la Tabla 10 y Tabla 11. En ellos se grafica el número de registros clasificados en cada uno de los diferentes valores de la IMM.

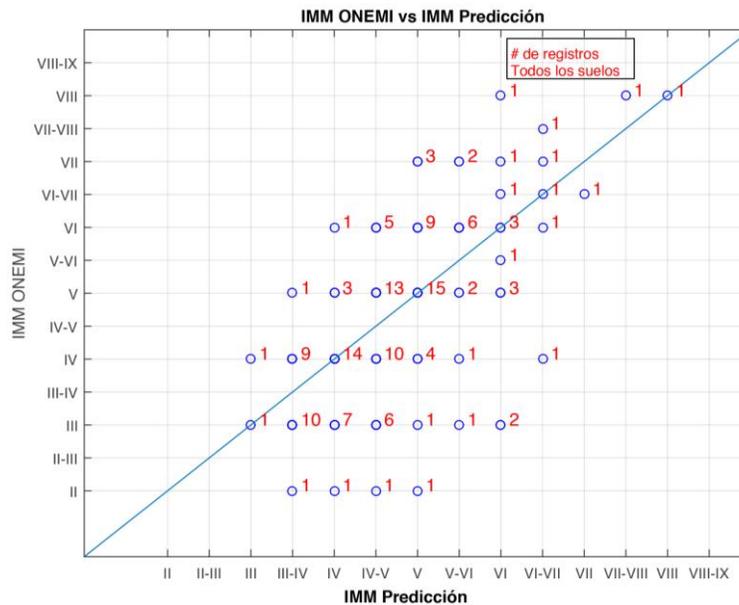


Figura 32: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 0.

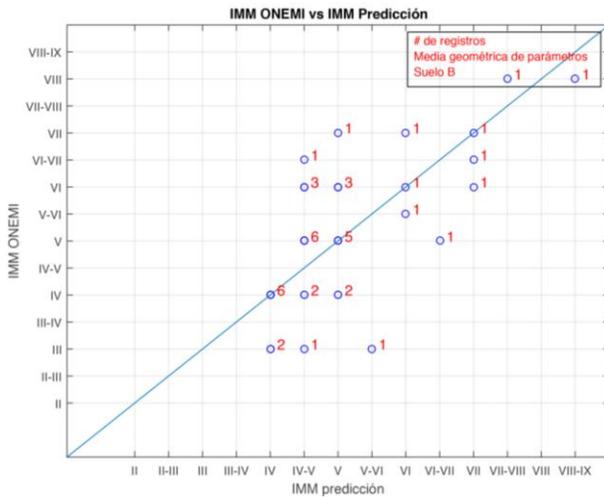


Figura 33: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 2.

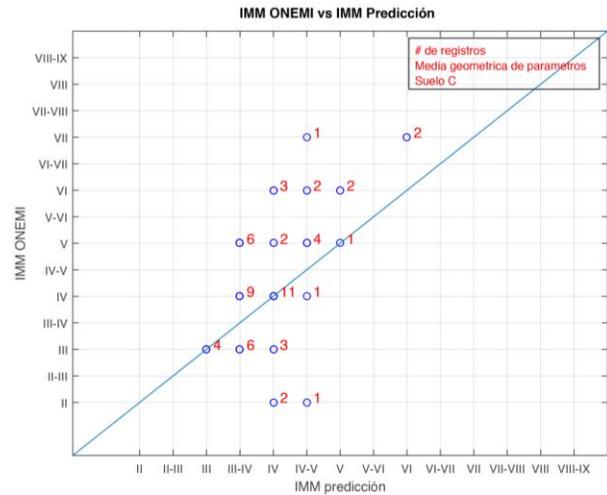


Figura 34: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 3.

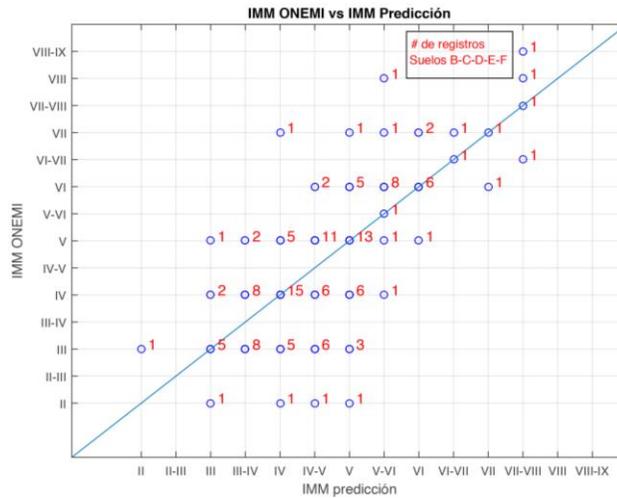


Figura 35: Predicción de IMM vs IMM ONEMI. Redes Neuronales Artificiales Caso 4.

En la Figura 36, Figura 37, Figura 38 y Figura 39 se encuentra la regresión lineal que mejor se ajusta entre los valores de salida del modelo (*output*) y los pertenecientes al set de prueba (*target*). Esta regresión considera el valor de la IMM como variable dependiente y el valor generado por el modelo como la variable independiente. En los cuatro casos, la regresión en los extremos de la escala de la IMM no se comporta de buena forma. Para valores bajos de la escala de Mercalli (<III) actúa de forma conservadora, es decir que la predicción da un valor mayor al informado por la ONEMI; en cambio para valores altos de la escala (>VI) la regresión actúa de manera no conservadora, es decir que arroja un valor menor al informado por la ONEMI.

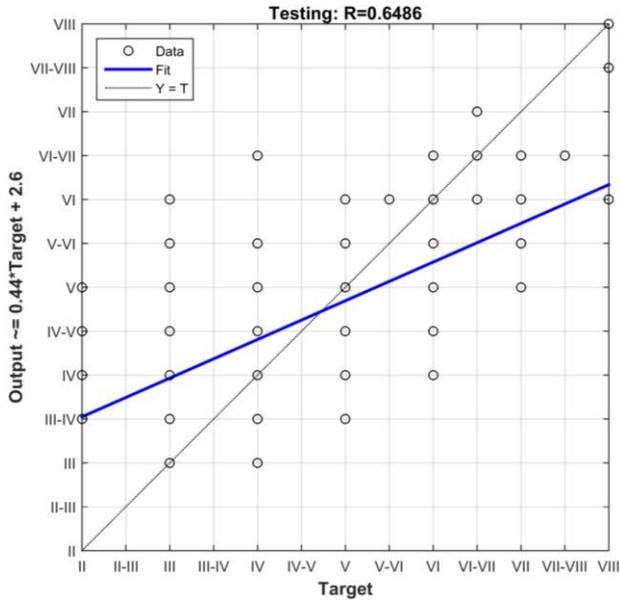


Figura 36: Regresión Lineal. Caso 0

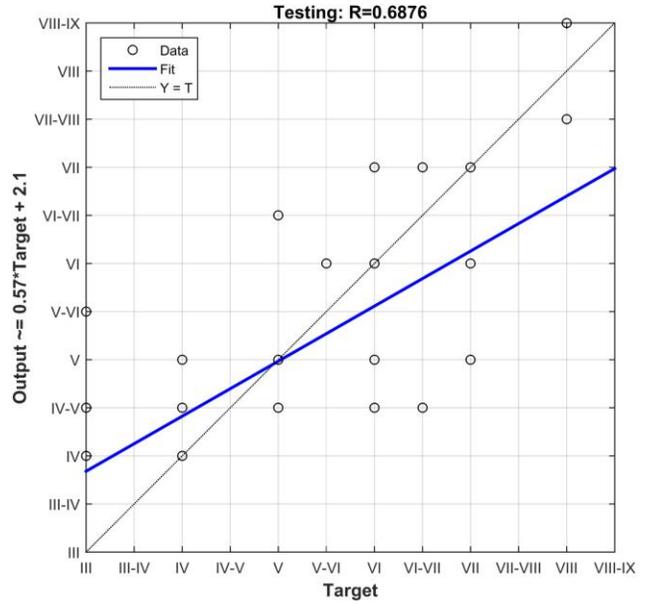


Figura 37: Regresión Lineal. Caso 2

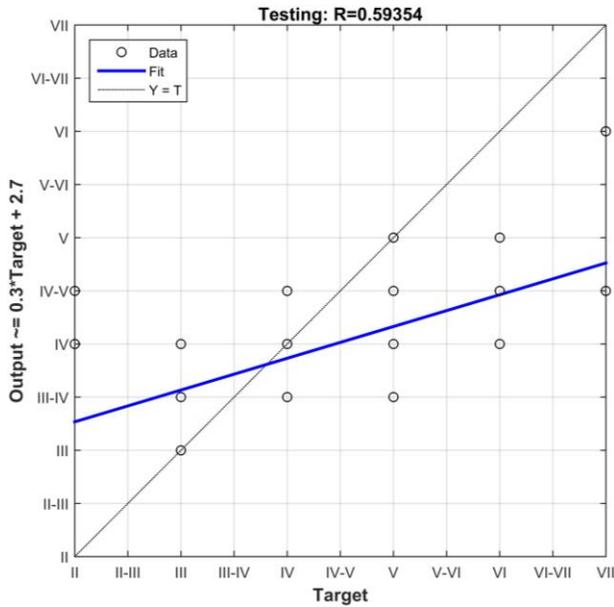


Figura 38: Regresión Lineal. Caso 3

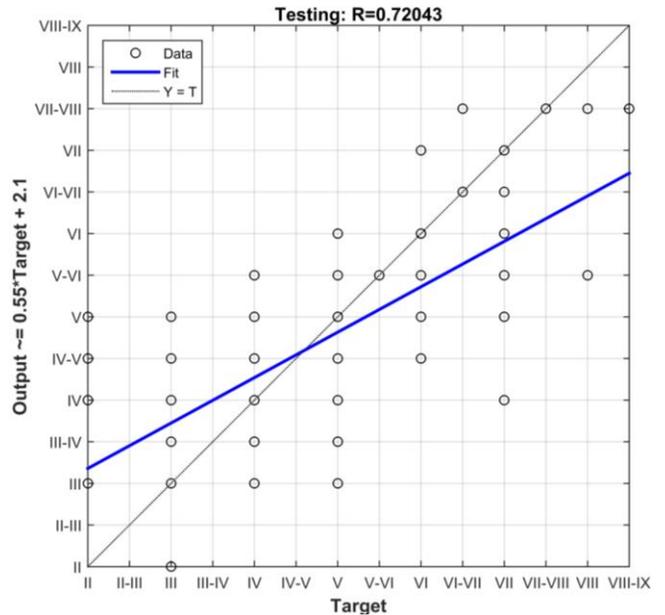


Figura 39: Regresión Lineal. Caso 4

Caso Extra

Para la generación de este modelo se consideran los parámetros que de acuerdo al *loading plot* son los que aportan mayor información al modelo. Estos son: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{SI})$, $\log(\text{Ia})$ e IJMA . Cabe mencionar que para este caso son considerados todos los tipos de suelos (Caso 0).

En este caso son generados 4 modelos diferentes, los cuales están definidos en la Tabla 12 según qué criterios son considerados y cuáles no.

Tabla 12: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica
1	1	1
2	1	0
3	0	0
4	0	1

En la Tabla 13 se resumen los porcentajes obtenidos para cada uno de los modelos.

Tabla 13: Resumen porcentajes de clasificación según caso por tipo de suelo y casos según criterio utilizado

Modificación	[%]
1	14.8
2	20.1
3	21.5
4	24.2

La celda marcada en verde corresponde al modelo que obtuvo un mayor porcentaje de clasificación.

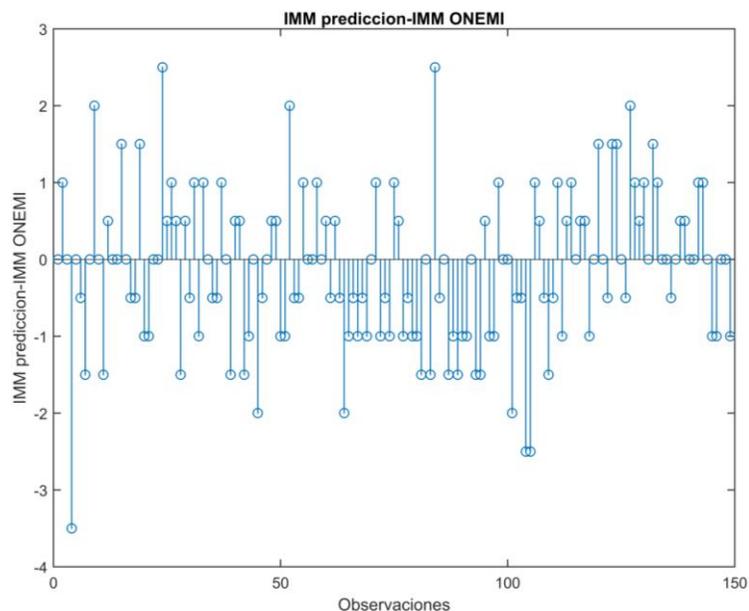


Figura 40: Diferencia entre IMM predicho e IMM informado por la ONEMI. RNA Caso Extra.

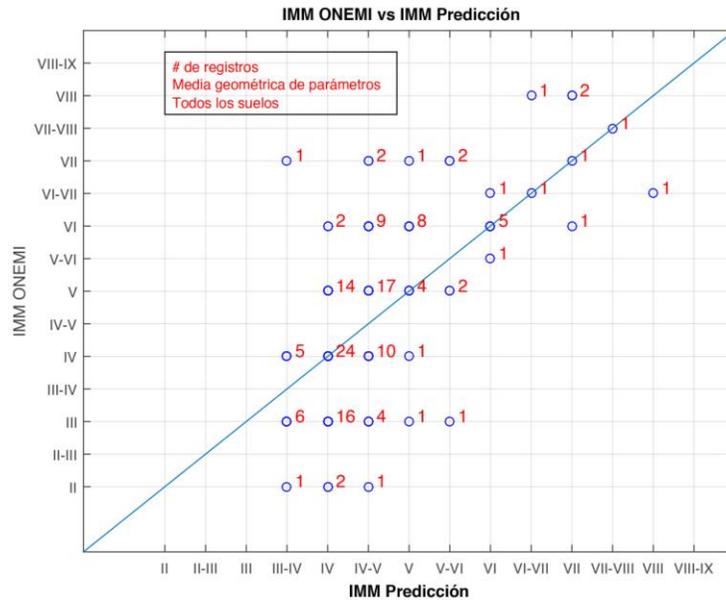


Figura 41: Predicción de IMM vs IMM ONEMI. RNA Caso Extra.

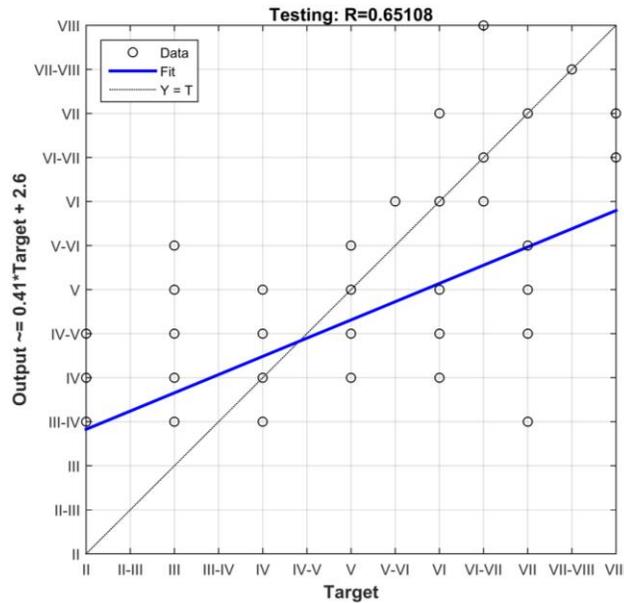


Figura 42: Regresión lineal entre valor IMM ONEMI e IMM predicho. Caso Extra.

De la Figura 40 se tiene que el 57.5% de los valores predichos por el modelo de Redes Neuronales Artificiales son menores a los informados por la ONEMI, por esto se puede decir que el modelo tiene una tendencia no conservadora.

Por otro lado, la diferencia máxima alcanzada entre ambos valores es 3.5 grados. Un 52.3% de los registros del set de prueba en la banda correspondiente de diferencia de $[-0.5, 0.5]$, 84.2% entre $[-1, 1]$ y un 96.6% entre $[-2, 2]$.

La Tabla 14 muestra el número de registros, por escala, en que el valor de salida del modelo (Intensidad de Mercalli predicha) es igual o mayor al informado por la ONEMI, y la Tabla 15 muestra el número de registros en que el valor de salida del modelo es igual o mayor en máximo 1 grado.

De la Tabla 14 y Tabla 15 se desprende que en la mayoría de los casos el modelo generado mediante Redes Neuronales Artificiales se comporta de forma conservadora, ya que los valores de salida del modelo son mayores a los informados por la ONEMI. Este hecho se ve más marcado en los valores de escala asociados a un solo valor.

En particular para los valores de III-IV y IV-V el modelo no tuvo un buen comportamiento ya que para el primer caso (III-IV) son 13 los registros para los que el modelo predice como salida este valor, siendo que ninguno tiene este valor asociado; para el segundo caso (IV-V) el número de registros que tienen el mismo comportamiento son 43.

Tabla 14: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
Extra	--	-----	---	7/13	42/58	15/43	6/15	3/5	6/7	1/2	2/4	1/1	1/1	-----
	--	-----	---	53.8	72.4	34.9	40.0	60.0	85.7	50.0	50.0	100.0	100.0	-----

*Caso Extra: 5 parámetros y todos los suelos.

Tabla 15: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
Extra	--	-----	---	6/13	40/58	10/43	5/15	2/5	6/7	1/2	4/4	1/1	0/1	-----
	--	-----	---	46.2	69.0	23.3	33.4	40.0	85.7	50.0	100.0	100.0	0.0	-----

*Caso Extra: 5 parámetros y todos los suelos.

Tabla 16: Resumen porcentajes de clasificación de registros (RNA 16 parámetros)

Caso Según Tipo de Suelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
0	25.5	80.5	49.7
2	31.0	81.0	54.8
3	26.7	75.0	43.4
4	30.7	84.3	52.1
Caso Extra	24.2	80.5	49.0

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

6.1.2 Red Neuronal Artificial considerando un parámetro a la vez

Como se menciona en la Sección 6.1 se realizan modelos mediante Redes Neuronales Artificiales considerando un parámetro a la vez. Se utilizan los siguientes 5 parámetros: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(I_a)$, $\log(\text{SI})$ e IJMA . Estas variables son consideradas ya que son las que según el *loading plot* (Figura 28) son las que mayor información aportan en la generación del modelo.

Tabla 17: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica
1	1	1
2	1	0
3	0	0
4	0	1

La Tabla 17 muestra a que corresponde cada caso según el criterio utilizado, que para estos modelos pueden ser la normalización de los parámetros y/o el cálculo de la media geométrica.

De la Tabla 18 a la Tabla 22 se muestran los resultados obtenidos para cada parámetro.

Se muestran los gráficos asociados a aquel modelo que mayor porcentaje de clasificación obtiene por cada parámetro (celda color verde).

Tabla 18: $\log(\text{PGA})$

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
1	17.4	22.3	16.7	16.7	15.7
2	17.4	33.4	11.9	13.4	14.3
3	29.5	11.2	11.9	23.4	24.3
4	16.1	11.2	19.0	16.7	19.3

Tabla 19: $\log(\text{PGV})$

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
1	16.8	22.3	14.3	30.0	19.3
2	22.1	33.4	9.5	26.7	18.6
3	26.2	0.0	23.8	25.0	22.9
4	16.8	0.0	16.7	28.4	21.4

Tabla 20: log(Ia)

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
1	20.8	22.3	21.4	16.7	26.4
2	21.5	22.3	11.9	20.0	13.6
3	26.8	22.3	19.0	28.3	21.4
4	21.5	0.0	16.7	23.4	20.7

Tabla 21: log(SI)

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
2	10.7	22.3	16.7	8.4	15.0
3	20.1	22.3	11.9	28.4	20.7

Tabla 22: IJMA

Modelos Según Criterios	Caso Según Tipo de Suelo				
	Caso 0	Caso 1	Caso 2	Caso 3	Caso 4
2	18.1	22.3	14.3	13.7	20.0
3	28.2	11.2	19.0	25	27.1

Del análisis de los gráficos de la Figura 43, se tiene que en general para los cinco parámetros utilizados aproximadamente un 50% de los registros son clasificados con una diferencia máxima de un grado con respecto al valor informado por la ONEMI. Y al considerar el rango [-1,1] el porcentaje es aproximadamente del 80% (Tabla 23).

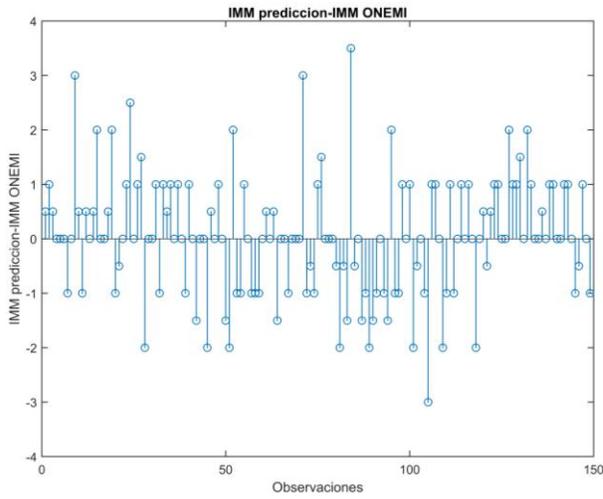
Tabla 23: Resumen porcentajes de clasificación de registros (RNA por parámetro)

Parámetro utilizado en el modelo	% registros clasificados con máximo 1 grado de diferencia	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
log(PGA) (Caso 0)	48.3	80.5	59.7
log(PGV) (Caso 0)	49.7	78.5	57.7
log(Ia) (Caso 3)	51.7	80.0	48.4
log(SI) (Caso 3)	51.7	80.0	48.4
IJMA (Caso 0)	52.3	80.5	53.7

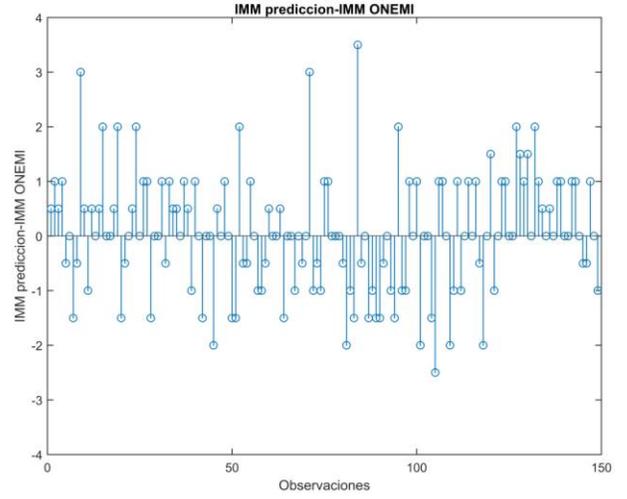
*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

En la Tabla 24 se observa que en general para los casos en que el valor de la Intensidad de la Escala de Mercalli está asociado a solo un valor un 50% o más de las predicciones de los registros coinciden con el valor informado por la ONEMI, o bien con un valor informado mayor. Es decir, que para estos casos el modelo de Redes Neuronales Artificiales se comporta de manera conservadora. Para aquellos valores que están entre dos escalas (Ej: III-IV, IV-V, etc.) el porcentaje, en la mayoría, es menor o igual al 50%.

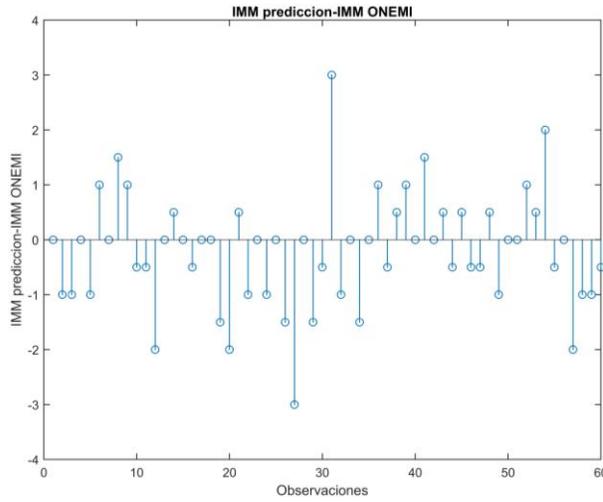
En la Tabla 25 se muestra el porcentaje de los registros del set de pruebas en que la predicción del valor de la IMM es igual o mayor en máximo 1 grado al valor informado por la ONEMI. Se observa que para la mayoría de los registros asociados a solo un valor de IMM el porcentaje es de aproximadamente un 50% o mayor. A diferencia de los registros asociados a valores entre dos escalas de la IMM, en que este porcentaje va desde aproximadamente un 14% a un 50%.



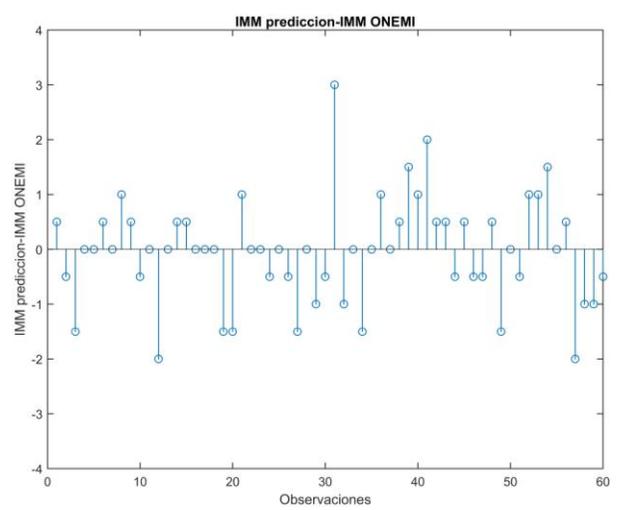
(a)



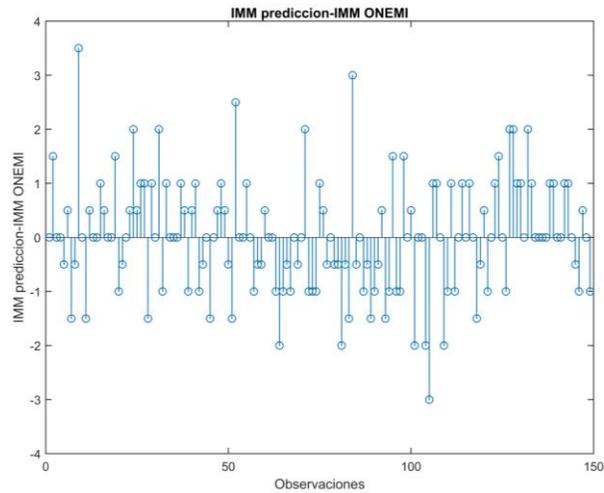
(b)



(c)



(d)



(e)

Figura 43: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) $\log(PGA)$, (b) $\log(PGV)$, (c) $\log(Ia)$, (d) $\log(SI)$, (e) IJMA. RNA por parámetro.

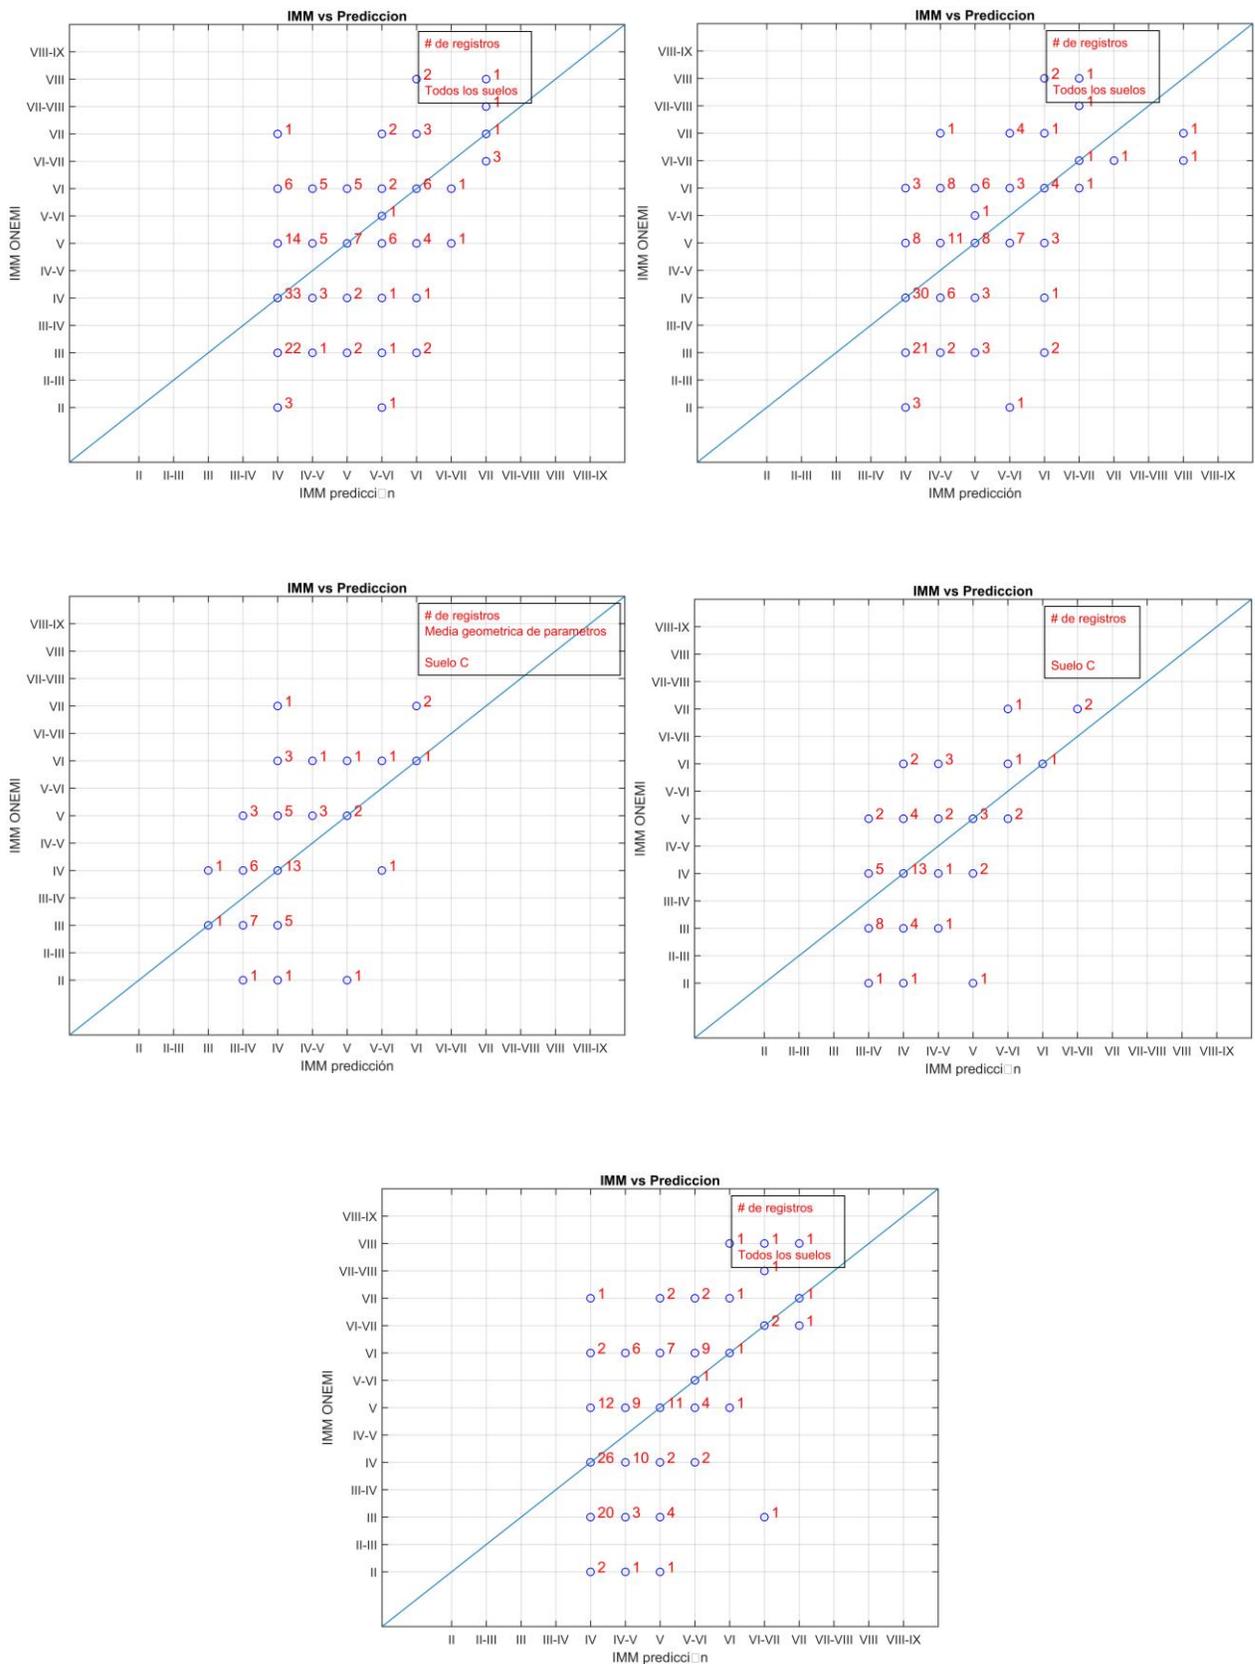


Figura 44: Predicción de IMM vs IMM ONEMI. RNA por parámetro (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(SI), (e) IJMA. RNA por parámetro.

Tabla 24: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
log(PGA)	--	-----	---	-----	58/79	4/14	11/16	10/14	13/18	2/2	4/6	-----	----	-----
	--	-----	---	-----	73.4	28.6	68.8	71.4	72.3	100.0	66.7	-----	----	-----
log(PGV)	--	-----	---	-----	54/65	8/28	14/21	8/15	10/13	2/4	1/1	-----	2/2	-----
	--	-----	---	-----	83.1	28.6	66.7	53.4	76.9	50.0	100.0	-----	100.0	-----
log(Ia)	--	-----	1/2	8/17	19/28	0/4	3/4	1/2	1/3	-----	-----	-----	----	-----
	--	-----	50.0	47.1	67.9	0.0	75.0	50.0	33.4	-----	-----	-----	----	-----
log(SI)	--	-----	---	9/16	18/24	2/7	6/6	2/4	1/1	0/2	-----	-----	----	-----
	--	-----	---	56.3	75.0	28.6	100.0	50.0	100.0	0.0	-----	-----	----	-----
IJMA	--	-----	---	-----	48/63	14/29	18/27	7/18	2/4	3/5	2/3	-----	----	-----
	--	-----	---	-----	76.2	48.3	66.7	38.9	50.0	60.0	66.7	-----	----	-----

Tabla 25: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
log(PGA)	--	-----	---	-----	55/79	3/14	9/16	7/14	10/18	1/2	4/6	-----	----	-----
	--	-----	---	-----	69.6	21.4	56.2	50.0	55.6	50.0	66.7	-----	----	-----
log(PGV)	--	-----	---	-----	51/65	6/28	11/21	7/15	7/13	2/4	1/1	-----	1/2	-----
	--	-----	---	-----	78.5	21.4	52.4	46.7	53.8	50.0	100.0	-----	50.0	-----
log(Ia)	--	-----	1/2	7/17	18/28	0/4	2/4	0/2	1/3	-----	-----	-----	----	-----
	--	-----	50.0	41.2	64.3	0.0	50.0	0.0	33.4	-----	-----	-----	----	-----
log(SI)	--	-----	---	8/16	17/24	1/7	5/6	2/4	1/1	0/2	-----	-----	----	-----
	--	-----	---	50.0	70.8	14.3	83.4	50.0	100.0	0.0	-----	-----	----	-----
IJMA	--	-----	---	-----	46/63	10/29	13/27	5/18	2/4	2/5	2/3	-----	----	-----
	--	-----	---	-----	73.0	34.5	48.1	27.8	50.0	40.0	66.7	-----	----	-----

Tabla 26: Regresión entre valor IMM salida del modelo y valor IMM informado por la ONEMI

	Regresión	R ²
log(PGA)	$IMM_{salida} = 0.38 * IMM_{ONEMI} + 2.9$	0.57
log(PGV)	$IMM_{salida} = 0.38 * IMM_{ONEMI} + 3.0$	0.59
log(Ia)	$IMM_{salida} = 0.30 * IMM_{ONEMI} + 2.8$	0.54
log(SI)	$IMM_{salida} = 0.38 * IMM_{ONEMI} + 2.6$	0.62
IJMA	$IMM_{salida} = 0.35 * IMM_{ONEMI} + 3.0$	0.61

Tabla 27: Pesos entre neuronas de la capa entrada y neuronas de la capa oculta

Parámetro	Neurona	Pesos			
		$N_{oculta\ 1}$	$N_{oculta\ 2}$	$N_{oculta\ 3}$	$N_{oculta\ 4}$
log(PGA)	$N_{entrada\ 1}$	-0.752	3.594	0.664	2.221
	$N_{entrada\ 2}$	-1.177	1.512	1.731	0.650
	$N_{entrada\ 3}$	-2.500	0.538	0.469	0.030
log(PGV)	$N_{entrada\ 1}$	0.348	3.358	-0.133	-0.733
	$N_{entrada\ 2}$	-0.399	-0.772	3.391	-1.470
	$N_{entrada\ 3}$	2.362	0.540	-0.958	1.179
log(Ia)	$N_{entrada\ 1}$	-0.234	0.233	3.131	-7.212
	$N_{entrada\ 2}$	-0.018	1.633	16.227	-16.595
log(SI)	$N_{entrada\ 1}$	3.584	-1.431	1.988	9.642
IJMA	$N_{entrada\ 1}$	5.153	-4.748	-2.844	4.912

Tabla 28: Pesos entre neuronas de la capa oculta y neurona de la capa salida

Parámetro	Neurona	Pesos			
		$N_{oculta\ 1}$	$N_{oculta\ 2}$	$N_{oculta\ 3}$	$N_{oculta\ 4}$
log(PGA)	$N_{salida\ 1}$	-0.236	0.375	-0.242	0.407
log(PGV)	$N_{salida\ 1}$	0.389	0.197	0.133	0.074
log(Ia)	$N_{salida\ 1}$	-2.257	0.778	-0.147	-0.243
log(SI)	$N_{salida\ 1}$	0.617	-0.519	0.412	-0.275
IJMA	$N_{salida\ 1}$	-0.553	-0.225	-0.246	-0.205

6.2 Regresión Logística Multinomial

En este capítulo se agregan dos modelos, además de los descritos en Capítulo 5, Sección 5.2.1.

El primero de ellos consiste en agrupar de la forma descrita en la Tabla 29 los valores de la IMM. La razón de esta división es dividir la escala de la IMM en aquellos valores asociados a daño ($> V$) y aquellos que no ($\leq V$).

Tabla 29: Valores vector de salida para Regresión Logística agrupados en 2 clases

Valores Escala de Mercalli	Valor clase
$\leq V$	1
$> V$	2

En el segundo de ellos se trabaja con 5 parámetros de los 16 calculados en el Capítulo 4: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{SI})$, $\log(\text{Ia})$ e IJMA . Se utiliza uno a la vez.

6.2.1 Clasificación con 17 clases

Este caso corresponde a la utilización de valores de la Escala de Mercalli Modificada considerando cada valor como una clase (según lo descrito en el Capítulo 5, Sección 5.2.1).

Tabla 30: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Regresión con PLS	Eliminación de Variables
1	1	1	1	1
2	1	1	1	0
3	1	1	0	0
4	1	0	0	0
5	0	0	0	0
6	0	0	0	1
7	0	0	1	1
8	0	1	1	1
9	0	1	0	0
10	0	0	1	0
11	1	0	0	1
12	0	1	1	0
13	1	0	1	0
14	0	1	0	1
15	1	1	0	1
16	1	0	1	1

El número de modelos generados, considerando los diferentes criterios mencionados anteriormente, son 80 (16 modelos por cada caso dependiente del tipo de suelo). En la Tabla 30 se muestra a qué corresponde cada uno de los 16 modelos, el valor 1 es si está aplicado el criterio y 0 si no.

En la Tabla 31 se muestran los porcentajes de clasificación de cada modelo. Se pueden ver los porcentajes de clasificación asociados a las tres clases que tienen las tres mayores posibilidades; y el porcentaje que suman entre ellas.

En la Tabla 31, las celdas de color rojo indican cuál de los modelos tiene un mayor porcentaje de clasificación sumando las tres mayores. Y las celdas de color verde indican cuál modelo tiene un mayor porcentaje de clasificación considerando solo la primera posibilidad.

Los resultados del Caso 1 no son considerados ya que este corresponde al caso donde se consideran solo los registros asociados al suelo tipo A (roca dura), de los cuales se tienen solo 48 registros, por lo que son muy pocos para poder generar alguna conclusión.

Tabla 31: Resumen porcentajes de clasificación según caso y modificaciones

	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
1	41.1	28.1	16.4	X	X	X	38.1	15.5	25.0	17.4	25.6	22.3	43.9	28.9	15.4
	85.6			-----			78.6			65.3			88.2		
2	44.5	26.4	16.7	26.3	10.5	15.8	36.9	34.5	11.9	13.2	19.8	21.5	42.5	31.8	16.4
	87.6			52.6			83.3			54.5			90.7		
3	15.7	21.1	14.4	0.0	0.0	5.3	1.2	0.0	9.8	27.3	14.1	6.6	14.6	19.6	25.4
	51.2			5.3			11.0			48.0			59.6		
4	12.4	13.7	11.7	5.3	5.3	5.3	2.4	8.4	10.7	7.4	5.0	8.3	13.9	10.7	12.5
	37.8			15.9			21.5			20.7			37.1		
5	24.1	22.1	22.1	15.8	0.0	15.8	11.9	16.7	17.9	19.8	26.4	19.8	14.6	16.8	18.4
	68.3			31.6			46.5			66.0			49.8		
6	21.4	23.1	22.7	10.5	0.0	0.0	14.3	22.6	19.4	17.4	19.0	28.9	20.7	22.9	21.8
	67.2			1.5			56.3			65.3			65.4		
7	41.5	28.1	14.4	52.6	5.3	10.5	11.9	10.7	16.7	13.2	11.6	18.2	46.1	27.1	14.6
	84.0			68.4			39.3			43.0			87.8		
8	41.1	28.1	16.4	X	X	X	38.1	15.5	25.0	17.4	25.6	22.3	43.9	28.9	15.4
	85.6			-----			78.6			65.3			88.2		
9	32.4	31.1	20.4	21.1	10.5	15.8	16.7	23.8	22.6	24.0	23.1	18.2	27.5	27.1	20.0
	83.9			47.4			63.1			65.3			74.6		
10	37.1	26.4	18.1	47.4	0.0	0.0	10.7	11.9	8.4	12.4	18.2	15.7	33.9	29.6	23.2
	81.6			47.4			31.0			46.3			86.7		
11	9.4	19.4	17.7	5.3	10.5	5.3	2.4	4.8	6.0	1.7	0.0	0.8	10.4	13.6	12.9
	46.5			21.1			13.2			2.5			36.9		
12	44.5	26.4	16.7	26.3	10.5	15.8	36.9	34.5	11.9	13.2	19.8	21.5	42.5	31.8	16.4
	87.6			52.6			83.3			54.5			90.7		
13	37.1	26.4	18.1	47.4	0.0	0.0	10.7	11.9	8.4	12.4	18.2	15.7	33.9	29.6	23.2
	81.6			47.4			31.0			46.3			86.7		
14	30.1	30.1	24.4	21.1	31.6	10.5	13.1	17.9	15.5	19.8	28.9	22.3	35.7	30.4	18.9
	84.6			62.7			46.5			71.0			85.0		
15	13.7	17.1	22.7	10.5	21.1	5.3	20.2	11.9	10.7	33.9	16.5	5.0	17.5	22.9	20.0
	53.5			36.9			42.8			55.4			60.4		
16	41.5	28.1	14.4	52.6	5.3	10.5	11.9	10.7	16.7	13.2	11.6	18.2	46.1	27.1	14.6
	84.0			68.4			39.3			43.0			87.8		

Caso 0 según tipo de suelo-Caso 2 según criterios utilizados

En la Figura 45 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística Multinomial y el valor informado por la ONEMI. De ella se puede desprender que el 54.8% de los registros pertenecientes al set de prueba que son mal clasificados (91 de 166) son clasificados en un valor menor al informado por la ONEMI. En consecuencia, se puede decir que el modelo tiene una tendencia no conservadora.

La diferencia entre el valor de IMM predicho y el informado por la ONEMI va desde 0.5 a 5 grados. El porcentaje de registros que se encuentran en el rango $[-1,1]$ de clasificación es de 84.6%, y si se consideran solo aquellos con diferencia de un grado hacia el lado conservador, es decir el rango $[0,1]$ el porcentaje es de 63.2%.

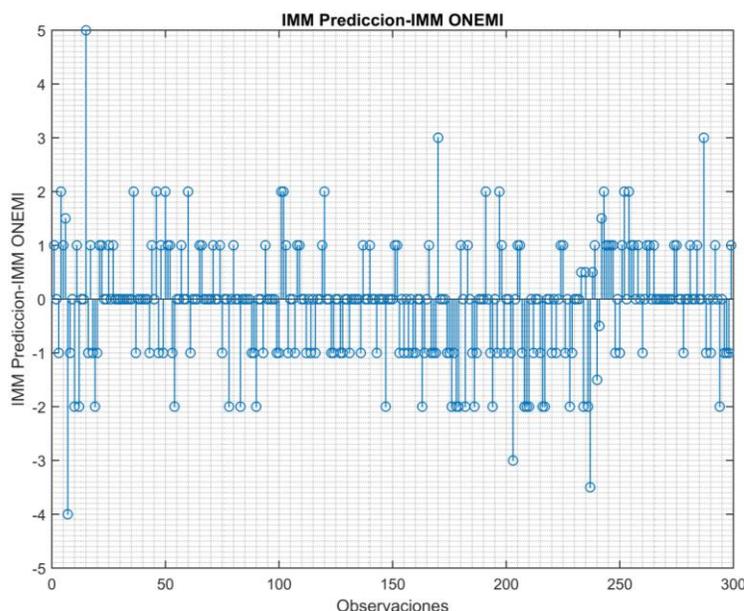


Figura 45: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases. Caso 0.

En la Figura 46 se observan los valores de salida del modelo por clase (=escala). En esta, lo primero que se puede notar es que no hay registros con valores entre dos escalas (Ej: II-III, III-IV, etc.) por lo que respecto a estas clases no se puede realizar un análisis.

En esta figura también es posible observar que para las clases menores ($< IV$) en general la predicción del modelo genera un valor de salida menor al informado por la ONEMI, mientras que para las clases mayores ($> V$) no hay una tendencia clara en las predicciones, ya sea conservadora o no conservadora.

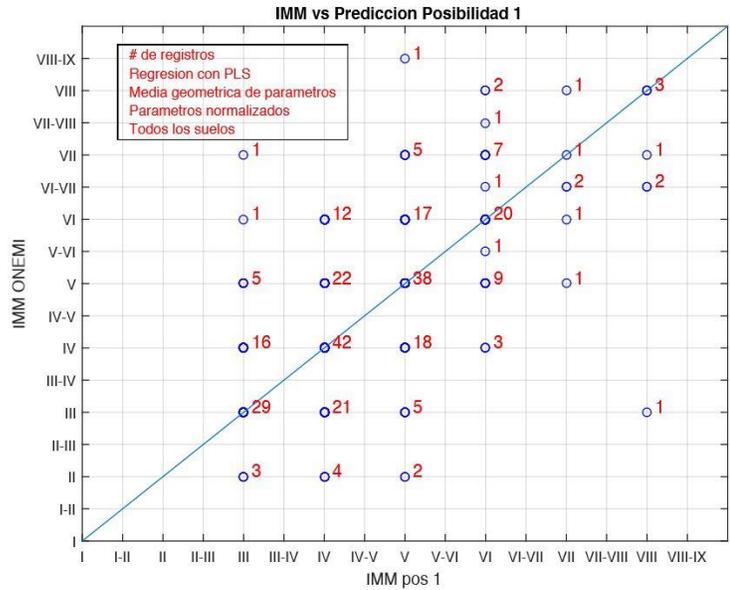


Figura 46: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 0.

Caso 2 según tipo de suelo-Caso 1 según criterios utilizados

En la Figura 47 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística Multinomial y el valor informado por la ONEMI. De ella se puede desprender que el 63.5% de los registros pertenecientes al set de prueba que fueron mal clasificados (52 de 84) son clasificados en un valor menor al informado por la ONEMI. En consecuencia, se puede decir que el modelo tiene una tendencia no conservadora.

La diferencia entre el valor de IMM predicho y el informado por la ONEMI va desde 0.5 a 3 grados. El porcentaje de registros que se encuentran en el rango $[-1,1]$ de clasificación es de 81.0%, y si se consideran solo aquellos con diferencia de un grado hacia el lado conservador, es decir el rango $[0,1]$ el porcentaje es de 58.4%.

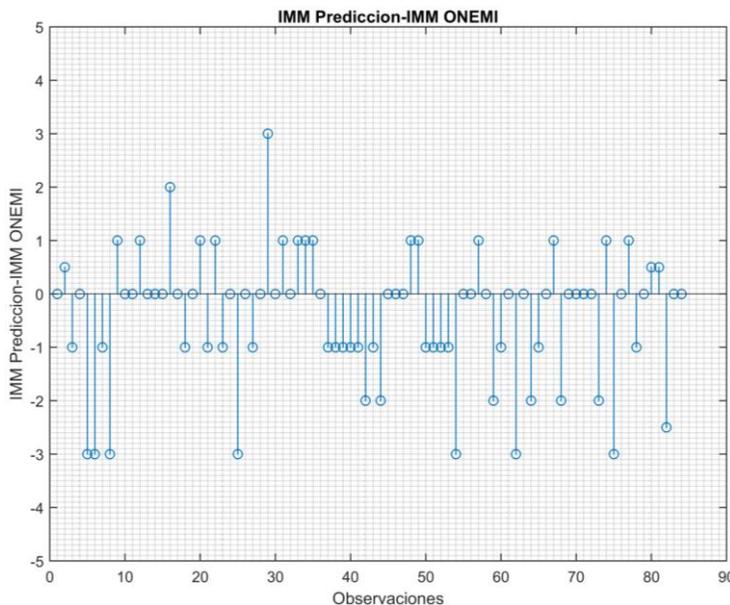


Figura 47: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases, Caso 2.

En la Figura 48 se puede apreciar la predicción realizada por el modelo por clase.

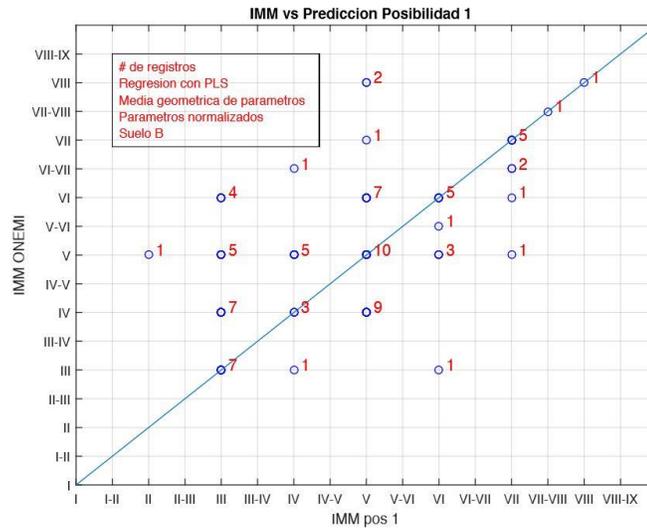


Figura 48: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 2.

Caso 3 según tipo de suelo-Caso 15 según criterios utilizados

En la Figura 49 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística y el valor informado por la ONEMI. De ella se puede desprender que el 61.3% de los registros pertenecientes al set de prueba que fueron mal clasificados (80 de 121) son clasificados en un valor menor al informado por la ONEMI, por lo que se puede decir, de forma general, que el modelo se comporta de manera no conservadora.

La diferencia entre el valor de IMM predicho y el informado por la ONEMI va desde 0.5 a 4 grados. El porcentaje de registros que se encuentran en el rango $[-1,1]$ de clasificación es de 73.6%, y si se consideran solo aquellos con diferencia de un grado hacia el lado conservador, es decir el rango $[0,1]$ el porcentaje es de 48.8%.

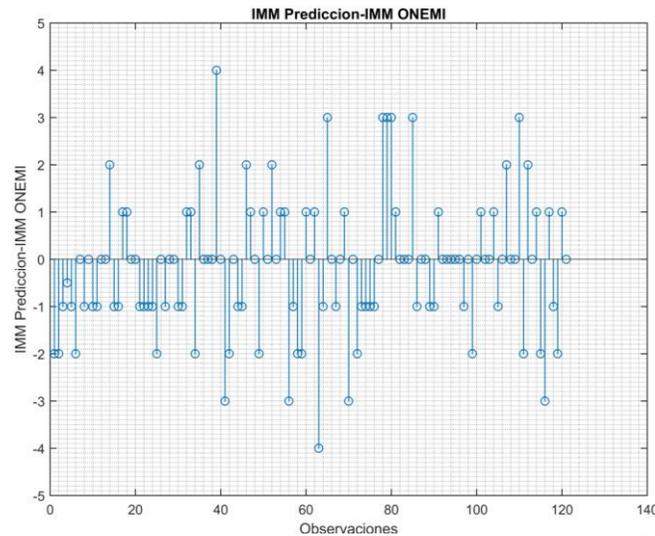


Figura 49: Diferencia entre IMM predicho e IMM informado por la ONEMI. Regresión Logística Multinomial 17 clases, Caso 3.

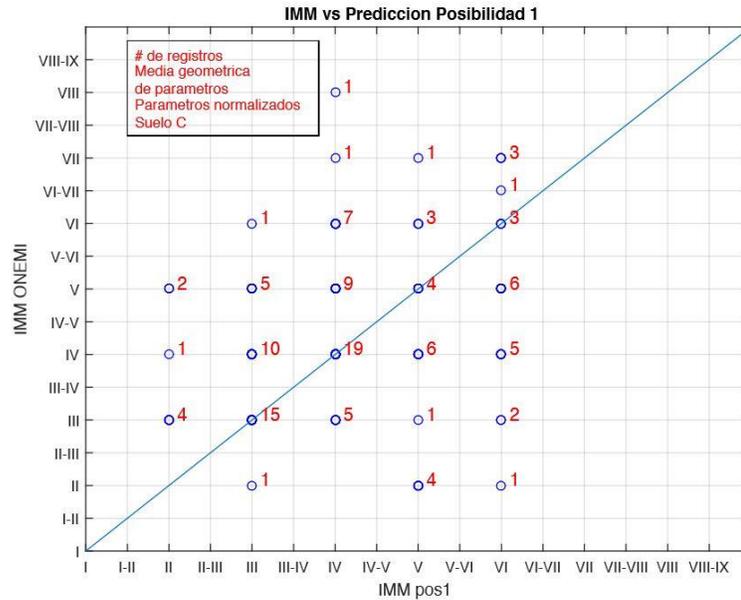


Figura 50: Predicción de IMM vs IMM ONEMI. Regresión Logística Multinomial 17 clases, Caso 3.

Caso 4 según tipo de suelo-Caso 1 según criterios utilizados

En la Figura 51 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística y el valor informado por la ONEMI. De ella se puede desprender que el 54.1% de los registros pertenecientes al set de prueba que fueron mal clasificados (157 de 280) son clasificados en un valor mayor al informado por la ONEMI. En consecuencia, se puede decir que el modelo tiene una tendencia no conservadora.

La diferencia entre el valor de IMM predicho y el informado por la ONEMI va desde 0.5 a 5 grados. El porcentaje de registros que se encuentran en el rango $[-1,1]$ de clasificación es de 86.4%, y si se consideran solo aquellos con diferencia de un grado hacia el lado conservador, es decir el rango $[0,1]$ el porcentaje es de 64.2%.

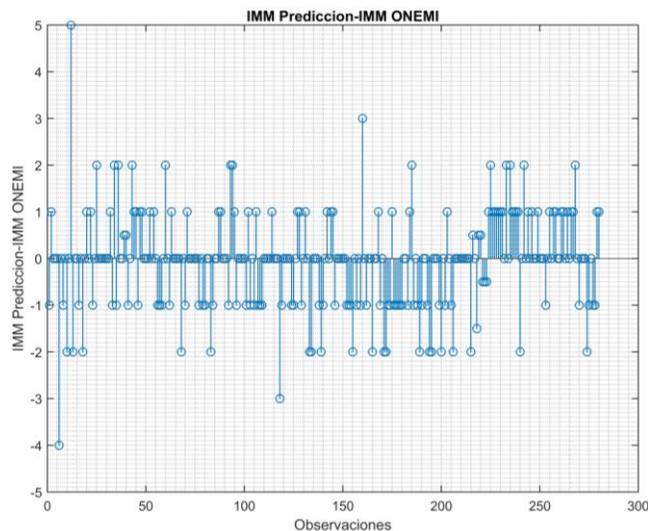


Figura 51: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 17 clases, Caso 4.

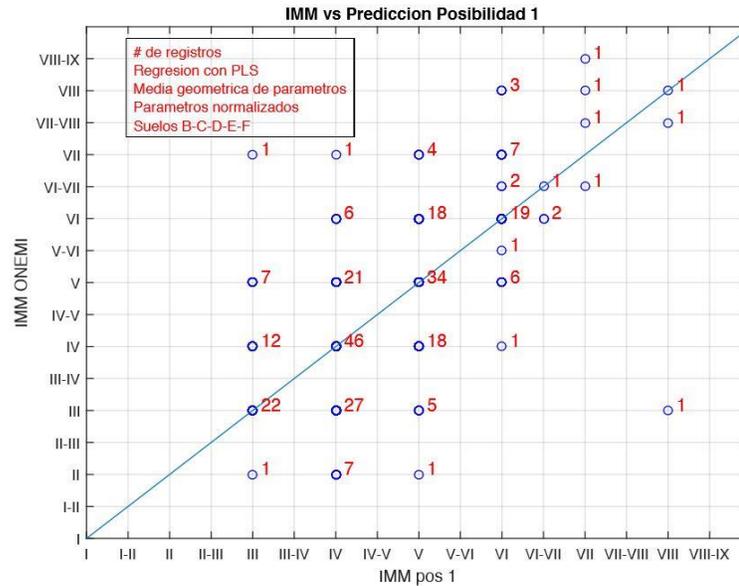


Figura 52: Predicción de IMM vs IMM ONEMI. RLM 17 clases, Caso 4.

En la Tabla 32 se observa que en general para los casos en que el valor de la Intensidad de la Escala de Mercalli está asociado a un solo valor y es $\geq IV$ ~ un 60% o más de las predicciones de los registros coinciden con el valor informado por la ONEMI, o bien con un valor informado mayor (excepto Caso 2, grado IV). Es decir, que para estos casos el modelo de Regresión Logística Multinomial se comporta de manera conservadora. Para aquellos valores asociados aun solo valor y $\leq III$ este porcentaje varía desde ~ un 30% a ~ un 58%. En particular para el grado VIII los resultados no son buenos en cuanto a la dispersión en la predicción, ya que es muy grande y el porcentaje de clasificación correcto para este valor es muy cercano al 0%, aunque cabe destacar que los datos asociados a este valor son muy pocos, por lo que no se puede realizar un análisis concluyente.

Con respecto a las intensidad de MM que representan un valor entre dos intensidades de la escala (Ej: III-IV, IV-V, etc.) se puede realizar análisis para valores mayores o iguales a VI-VII ya que para valores menores casi no existen registros. Este análisis se efectúa a pesar de que aun para estos valores los números de registros no son suficientes para determinar un comportamiento claro de los modelos. Considerando lo anterior, de la Tabla 32 se vislumbra que todos los modelos tienen un comportamiento conservador, dado que para estos valores más de un 50% de los registros son clasificados con un valor igual o mayor que el informado por la ONEMI.

En la Tabla 33 se muestran los porcentajes de los registros del set de pruebas en que la predicción del valor de la IMM es igual o mayor en 1 grado al valor informado por la ONEMI. En ella se observa que el comportamiento general de la Tabla 32 para los valores de IMM asociados a una sola escala se mantiene. Para los valores $\leq III$ no existen cambios en los porcentajes, y dentro de los valores $\geq IV$, para los grados IV, V y VI los porcentajes disminuyen un poco, pero en la mayoría no son menores al 50%. Para los grados VII y VIII, en 3 de los 4 modelos, el porcentaje es alrededor de un 80%. Con respecto a los valores de la escala de IMM asociados a dos valores, los resultados de la tabla anterior se mantienen.

Tabla 32: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	I	I-II	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
0	----	----	----	-----	32/55	-----	67/101	-----	63/86	-----	33/44	-----	5/6	-----	7/7	-----
	----	----	----	-----	58.2	-----	66.3	-----	73.3	-----	75.0	-----	83.4	-----	100.0	-----
2	----	----	0/1	-----	7/23	-----	4/10	-----	19/29	-----	9/10	-----	8/9	1/1	1/1	-----
	----	----	0.0	-----	30.4	-----	40.0	-----	65.5	-----	90.0	-----	88.9	100.0	100.0	-----
3	----	----	0/7	-----	16/32	-----	24/42	-----	15/19	-----	17/21	-----	----	-----	----	-----
	----	----	0.0	-----	50.0	-----	57.1	-----	78.9	-----	81.0	-----	----	-----	----	-----
4	----	----	----	-----	23/43	-----	80/108	-----	58/72	-----	27/39	3/3	1/4	-----	3/3	-----
	----	----	----	-----	53.5	-----	74.1	-----	80.6	-----	69.2	100.0	25.0	-----	100.0	-----

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Tabla 33: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI

Caso	I	I-II	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
0	----	----	----	-----	32/55	-----	63/101	-----	56/86	-----	30/44	-----	4/6	-----	7/7	-----
	----	----	----	-----	58.2	-----	62.4	-----	65.1	-----	68.2	-----	66.7	-----	100.0	-----
2	----	----	0/1	-----	7/23	-----	4/10	-----	19/29	-----	9/10	-----	8/9	1/1	1/1	-----
	----	----	0.0	-----	30.4	-----	40.0	-----	65.5	-----	90.0	-----	88.9	100.0	100.0	-----
3	----	----	0/7	-----	16/32	-----	24/42	-----	10/19	-----	9/21	-----	----	-----	----	-----
	----	----	0.0	-----	50.0	-----	57.1	-----	52.6	-----	42.9	-----	----	-----	----	-----
4	----	----	----	-----	23/43	-----	73/108	-----	52/72	-----	26/39	3/3	1/4	-----	2/3	-----
	----	----	----	-----	53.5	-----	67.6	-----	72.3	-----	66.7	100.0	25.0	-----	66.7	-----

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Caso Extra

Para la generación de este modelo se consideran los parámetros que de acuerdo al *loading plot* son los que aportan mayor información al modelo. Estos son: log(PGA), log(PGV), log(SI), log(Ia) e IJMA. Cabe mencionar que para este caso son considerados todos los tipos de suelos (Caso o).

En este caso son generados 8 modelos diferentes, los cuales están definidos en la Tabla 34 según qué criterios son considerados y cuáles no.

Tabla 34: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Regresión con PLS
1	1	1	1
2	1	1	0
3	1	0	0
4	0	0	0
5	0	0	1
6	0	1	1
7	0	1	0
8	1	0	1

En la Tabla 35 se resumen los resultados obtenidos para cada uno de los modelos. La fila marcada en verde corresponde a la que obtuvo un mayor porcentaje de clasificación considerando las tres primeras probabilidades más altas.

Tabla 35: Resumen porcentajes de clasificación según caso y modificaciones

Modificación	Posibilidad 1 [%]	Posibilidad 2 [%]	Posibilidad 3 [%]	Total [%]
1	39.1	31.1	12.0	82.2
2	36.1	29.1	19.1	84.3
3	32.8	29.1	22.4	84.3
4	34.4	32.4	17.4	84.2
5	35.5	32.8	15.1	83.4
6	39.1	31.1	12.0	82.2
7	39.5	29.4	15.4	84.3
8	35.5	32.8	15.1	83.4

En la Figura 53 se muestra la diferencia entre los valores de salida del modelo y el valor de la escala de IMM informado por la ONEMI. En ella se puede observar que el 76.2% de los resultados presentan una diferencia de máxima de 1 grado y el 96.1% de máximo 2 grados. Es decir que considerando los registros que fueron bien clasificados, el 85.6% del total de los registros del set de pruebas son bien clasificados o con una diferencia máxima de 1 grado.

Además, se puede desprender, a modo general, que el modelo tiene una tendencia de comportamiento conservador ya que el 54.7% de los registros son clasificados en valores mayores a los informados por la ONEMI. En la Figura 54 se analiza por clase el comportamiento del modelo.

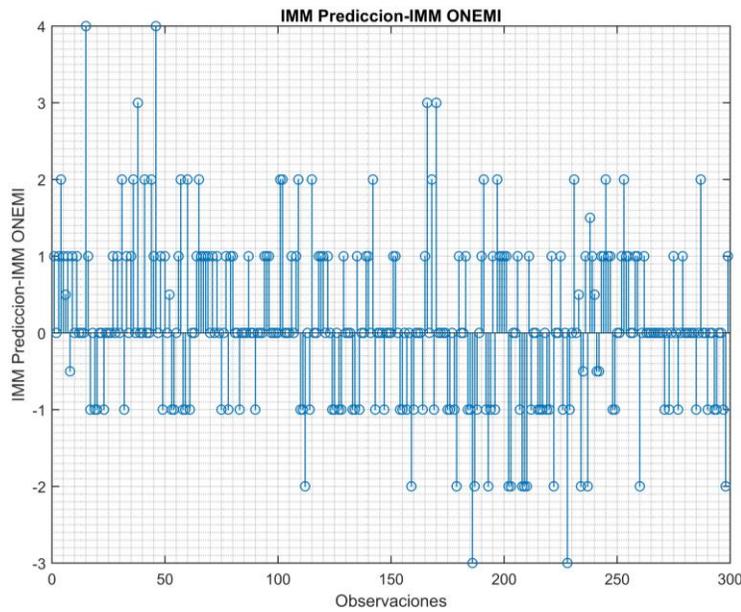


Figura 53: Diferencia entre valor de la escala de la IMM predicho por el modelo y valor informado por la ONEMI. Modelo generado mediante RLM considerando 17 clases, Caso Extra.

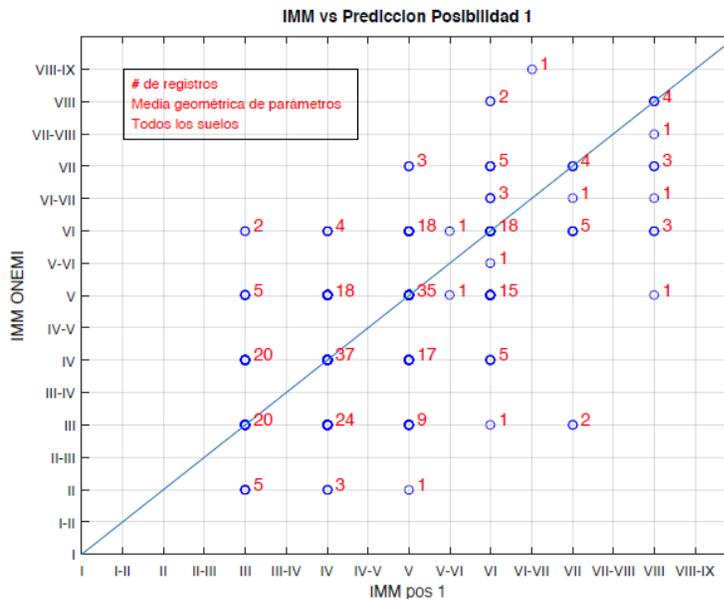


Figura 54: Predicción de IMM vs IMM ONEMI. RLM 17 clases, Caso Extra.

De la Figura 54 se observa que para todos los valores $\geq IV$ el modelo se comporta de forma conservadora ya que realiza una clasificación de la mayoría de los registros en un valor igual o mayor al informado por la ONEMI. En la Tabla 36 y la Tabla 37 se observa por cada valor de la escala de IMM el comportamiento. La Tabla 36 muestra el número de registros en que el valor de salida del modelo (Intensidad de Mercalli predicha) es igual o mayor al informado por la ONEMI, y la Tabla 37 muestra el número de registros en que el valor de salida del modelo es igual o mayor en 1 grado.

Al igual que en casos anteriores, para las clases que corresponden a valores de IMM entre dos escalas, los registros son muy pocos para concluir. Con respecto a las otras

clases, de la Tabla 36 se observa que en general al menos un 50% de los registros son clasificados en un valor igual o mayor al informado por la ONEMI. Cuando solo se considera 1 grado mayor al informado por la ONEMI los porcentajes disminuyen (no en todos los casos) pero se siguen manteniendo por sobre el 50% en la mayoría de los casos.

Tabla 36: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
Extra	--	-----	25/52	-----	64/86	-----	62/83	1/2	40/50	0/1	12/12	-----	13/13	-----
	--	-----	48.1	-----	74.4	-----	74.7	50.0	80.0	0.0	100.0	-----	100.0	-----

*Caso Extra: 5 parámetros y todos los suelos.

Tabla 37: Porcentaje de registros clasificados con máximo 1 grado por sobre el valor informado por la ONEMI

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
Extra	--	-----	25/52	-----	61/86	-----	52/83	1/2	34/50	0/1	10/12	-----	8/13	-----
	--	-----	48.1	-----	70.9	-----	62.7	50.0	68.0	0.0	83.4	-----	61.5	-----

*Caso Extra: 5 parámetros y todos los suelos.

Tabla 38: Resumen porcentajes de clasificación de registros RLM 17 clases

Caso Según Tipo de Suelo	% registros clasificados correctamente (posibilidad 1)	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
0	32.4	81.9	53.5
2	16.7	57.1	40.5
3	27.3	63.6	41.3
4	35.0	79.2	57.5
Caso Extra	39.5	85.6	63.9

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

6.2.2 Clasificación con 5 clases

Este caso corresponde a la utilización de cinco clases, las cuales agrupan valores de la Escala de Mercalli Modificada según lo descrito en el Capítulo 5, Sección 5.2.1.

Tabla 39: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Regresión con PLS	Eliminación de Variables
1	1	1	1	1
2	1	1	1	0
3	1	1	0	0
4	1	0	0	0
5	0	0	0	0
6	0	0	0	1
7	0	0	1	1
8	0	1	1	1
9	0	1	0	0
10	0	0	1	0
11	1	0	0	1
12	0	1	1	0
13	1	0	1	0
14	0	1	0	1
15	1	1	0	1
16	1	0	1	1

El número de modelos generados, considerando los diferentes criterios mencionados anteriormente, son 80 (16 modelos por cada caso dependiente del tipo de suelo). En la Tabla 39 se muestra a qué corresponde cada uno de los 16 modelos, el valor 1 es si está aplicado el criterio y 0 si no.

En la Tabla 40 se muestran los porcentajes de clasificación de cada modelo. Se pueden ver los porcentajes de clasificación asociados a las tres clases que tienen las mayores posibilidades entre las cinco clases, y el porcentaje que suman entre ellas.

En la Tabla 40, las celdas de color rojo indican cuál de los modelos tiene un mayor porcentaje de clasificación sumando las tres mayores. Y las celdas de color verde indican cuál modelo tiene un mayor porcentaje de clasificación considerando solo la primera posibilidad.

Los resultados del Caso 1 no son considerados ya que este corresponde al caso donde se consideran solo los registros asociados al suelo tipo A (roca dura), de los cuales se tienen solo 48 registros, por lo que son muy pocos para poder generar alguna conclusión.

Tabla 40: Resumen porcentajes de clasificación según caso y criterios

	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
1	55.2	31.4	6.0	36.8	21.1	15.8	56.0	27.4	6.0	63.6	27.3	5.8	57.1	29.6	6.1
	92.6			73.7			89.4			96.7			92.8		
2	55.9	31.1	6.0	26.3	15.8	10.5	59.5	22.6	6.0	68.6	24.0	4.1	57.5	30.0	6.4
	93.0			52.6			88.1			96.7			93.9		
3	45.5	36.1	11.1	10.5	10.5	31.6	22.6	22.6	9.5	43.0	12.4	0.0	47.5	34.3	7.9
	92.7			52.6			54.7			55.4			89.7		
4	43.8	28.8	15.7	21.1	21.1	21.1	23.8	22.6	15.5	23.1	9.9	14.0	46.8	31.1	15.0
	88.3			63.3			61.9			47.0			92.9		
5	54.2	32.4	9.0	21.1	26.3	5.3	39.3	29.8	15.5	57.0	28.1	4.1	57.5	32.9	6.1
	95.6			52.7			84.6			89.2			96.5		
6	54.8	31.0	10.4	15.8	0.0	21.1	45.2	27.4	15.5	60.3	28.1	4.1	58.2	32.9	5.7
	96.2			36.9			88.1			92.5			96.8		
7	54.2	32.4	6.7	57.9	10.5	10.5	58.4	25.0	6.0	63.6	27.3	5.0	57.1	31.4	6.8
	93.3			78.9			89.4			95.9			95.3		
8	55.2	31.4	6.0	36.8	21.1	15.8	56.0	27.4	6.0	63.6	27.3	5.8	57.1	29.6	6.1
	92.6			73.7			89.4			96.7			92.8		
9	55.2	32.8	9.7	15.8	36.8	15.8	39.3	38.1	11.9	62.0	26.4	8.3	59.3	30.4	7.9
	97.7			68.4			89.3			96.7			97.6		
10	56.2	29.8	6.7	42.1	5.3	10.5	60.7	21.4	6.0	70.2	21.5	4.1	58.2	30.0	5.7
	92.7			57.9			88.1			95.8			93.9		
11	49.5	29.4	12.0	5.3	36.8	15.8	20.2	9.5	14.3	24.0	10.7	14.9	51.4	29.3	10.4
	90.9			57.9			44.0			49.6			91.1		
12	55.9	31.1	6.0	26.3	15.8	10.5	59.5	22.6	6.0	68.6	24.0	4.1	57.5	30.0	6.4
	93.0			52.6			88.1			96.7			93.9		
13	56.2	29.8	6.7	42.1	5.3	10.5	60.7	21.4	6.0	70.2	21.5	4.1	58.2	30.0	5.7
	92.7			57.9			88.1			95.8			93.9		
14	55.2	32.8	8.4	52.6	21.1	0.0	50.0	28.6	9.5	59.5	32.2	6.6	56.1	33.6	8.2
	96.4			73.7			88.1			98.3			97.9		
15	50.1	33.4	9.7	36.8	5.3	10.5	32.1	17.9	7.1	44.6	9.9	9.1	52.9	30.4	8.2
	93.2			52.6			57.1			63.6			91.5		
16	54.2	32.4	6.7	57.9	10.5	10.5	58.4	25.0	6.0	63.6	27.3	5.0	57.1	31.4	6.8
	93.3			78.9			89.4			95.9			95.3		

Caso 0 según tipo de suelo-Caso 9 según criterios utilizados

En la Figura 55 se observa la diferencia entre la clase predicha por el modelo de Regresión Logística y la clase a la cual corresponde el valor informado por la ONEMI del set de datos de prueba. De esta figura se desprende que el 51.0% de los registros pertenecientes al set de prueba (76 de 149 registros) son clasificados en una clase menor a la clase que contiene al valor informado por la ONEMI y, como corresponde a aproximadamente el 50% no se puede definir un comportamiento conservador o no conservador.

Por otro lado, dado que los diferentes valores de la escala de la IMM fueron agrupados en clases, el que sea clasificado en una, dos o hasta tres clases de diferencia es importante, debido a que al incluir más de un valor en cada una de las clases, se podría dar que sea una diferencia real de 0.5 o 1 grado hasta una diferencia de 5 grados en el peor de los casos.

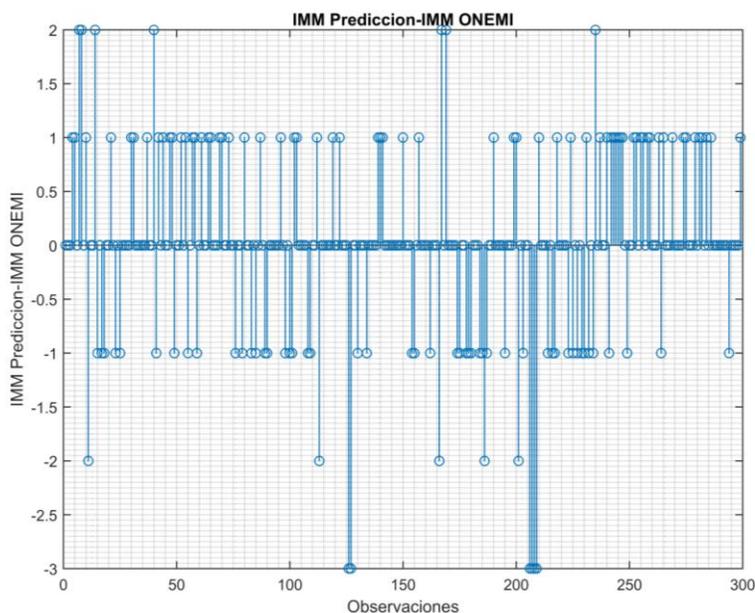


Figura 55: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso 0.

En la Figura 56 se observa de mejor manera lo mencionado anteriormente. Se ve por clases la diferencia que existe entre lo predicho mediante Regresión Logística Multinomial y lo informado por la ONEMI.

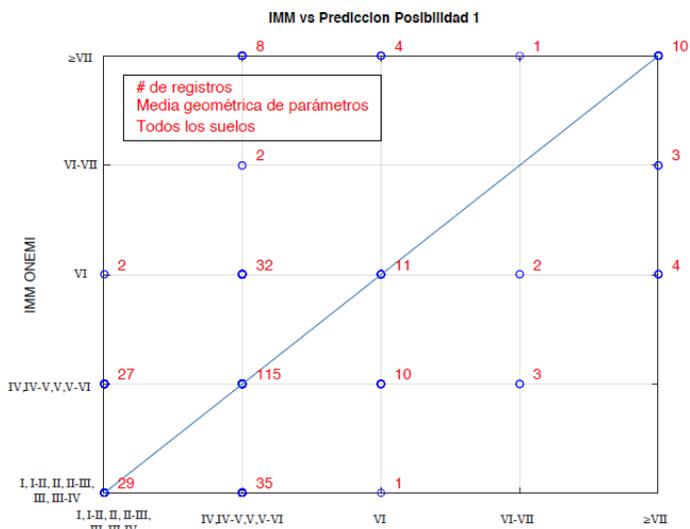


Figura 56: Predicción de IMM vs IMM ONEMI. RLM5 clases, Caso 0.

De la Figura 56 se desprende que para las clases menores (1 y 2) el modelo genera un valor de salida menor al informado por la ONEMI, mientras que para las clases mayores (3, 4 y 5) el valor de salida del modelo es mayor al informado, por lo que en estas clases actúa de forma conservadora.

Caso 2 según tipo de suelo-Caso 10 según criterios utilizados

En la Figura 57 se observa la diferencia entre la clase predicha por el modelo de Regresión Logística y la clase a la cual corresponde el valor informado por la ONEMI.

Del 39.3% de los registros que no fueron bien clasificados, el 66.7% (22) son clasificados en un valor menor al informado por la ONEMI, por lo que se puede decir que este modelo se comporta de forma no conservadora. En la Figura 57 se observa por clase la clasificación del modelo considerando solo la clasificación según la mayor posibilidad.

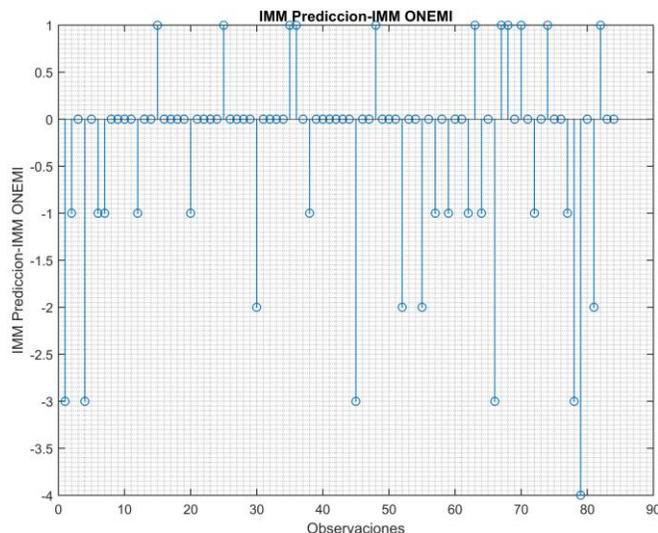


Figura 57: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso 2.

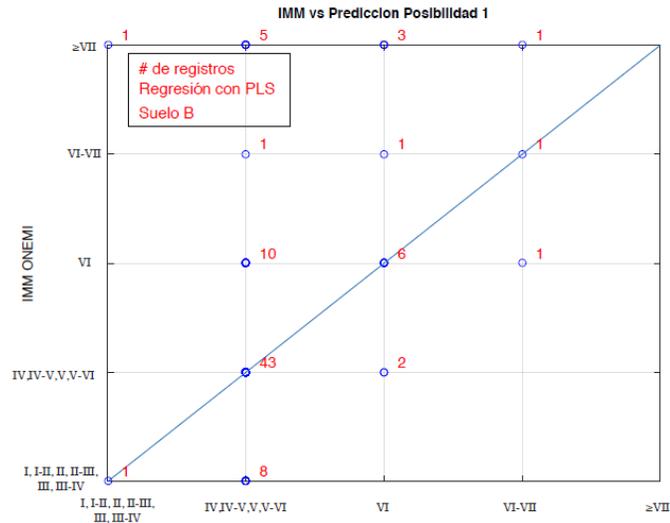


Figura 58: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 2.

En la Figura 58 se observa que para todas las clases el modelo tiene el mismo comportamiento no conservador, sin considerar la Clase 4 que tiene muy pocos datos para concluir algo. Además, también se puede observar que todos los registros pertenecientes a la Clase 5 fueron mal clasificados.

Caso 3 según tipo de suelo-Caso 10 según criterios utilizados

En la Figura 59 se observa la diferencia entre la clase predicha por el modelo de Regresión Logística Multinomial y la clase a la cual corresponde el valor informado por la ONEMI.

Del 29.8% de los registros que fueron mal clasificados, el 63.9% (23) son clasificados con un valor menor al informado por la ONEMI, por lo que se puede decir que este modelo se comporta de forma no conservadora.

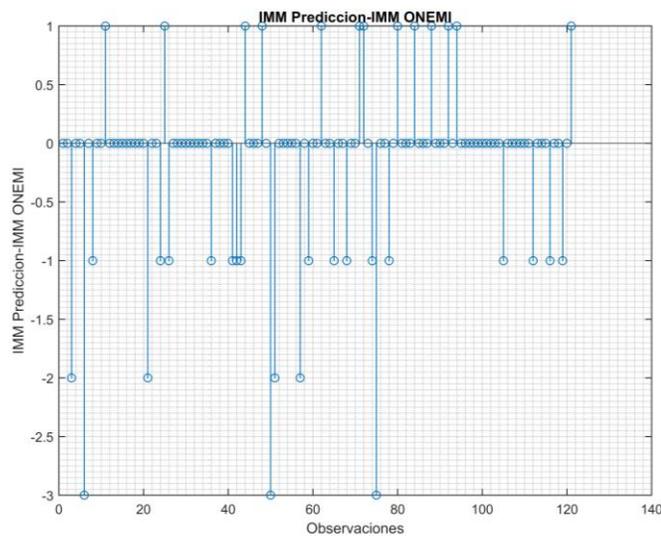


Figura 59: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso 3.

En la Figura 60 se observa por clase la clasificación del modelo considerando solo la clasificación según la mayor posibilidad.

Con respecto a las clases mayores (4 y 5) todos los registros fueron mal predichos por el modelo (excepto 1). En cuanto a las otras tres clases se podría decir que, como se ha observado en los casos anteriores, el modelo actúa de manera no conservadora.

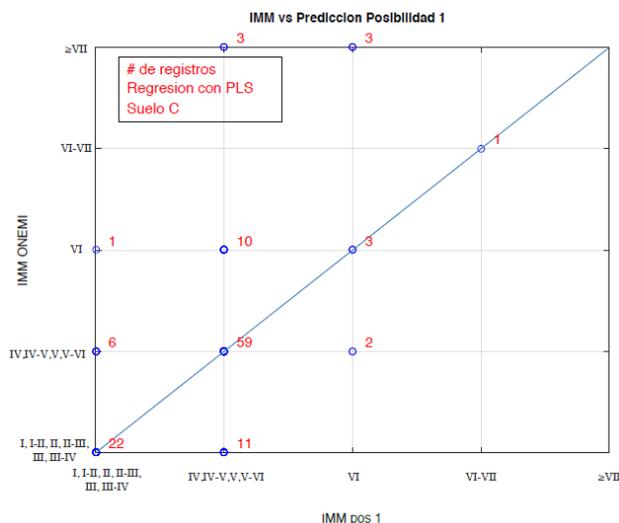


Figura 60: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 3.

Caso 4 según tipo de suelo-Caso 9 según criterios utilizados

En la Figura 61 se observa la diferencia entre la clase predicha por el modelo de Regresión Logística Multinomial y la clase a la cual corresponde el valor informado por la ONEMI. Del 40.7% de los registros que no fueron bien clasificados, el 60.1% (69) son clasificados con un valor mayor al informado por la ONEMI, por lo que se puede decir que este modelo se comporta de forma conservadora. Además, de los 114 registros que fueron mal clasificados en 100 de ellos (87.7%) el desfase es de 1 clase (1 clase mayor o 1 clase menor).

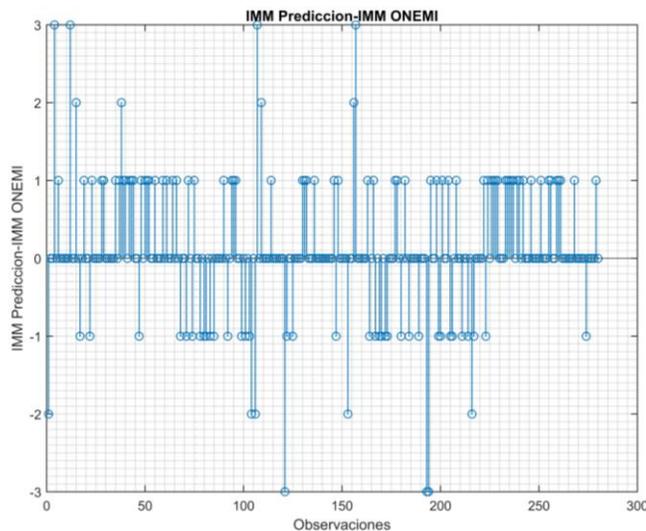


Figura 61: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso 4.

En la Figura 62 se muestra la clasificación por clase. En general para las clases 2, 3, 4 y 5 los registros mal clasificados pertenecen a una clase menor. En el caso de la clase 1 solo existe la posibilidad de que sea clasificado en una clase mayor. Además se observa que si bien no todos los registros pertenecientes a la Clase 5 son bien clasificados, la mitad de ellos sí, sin embargo existe una gran dispersión en los valores obtenidos de la predicción de esta clase.

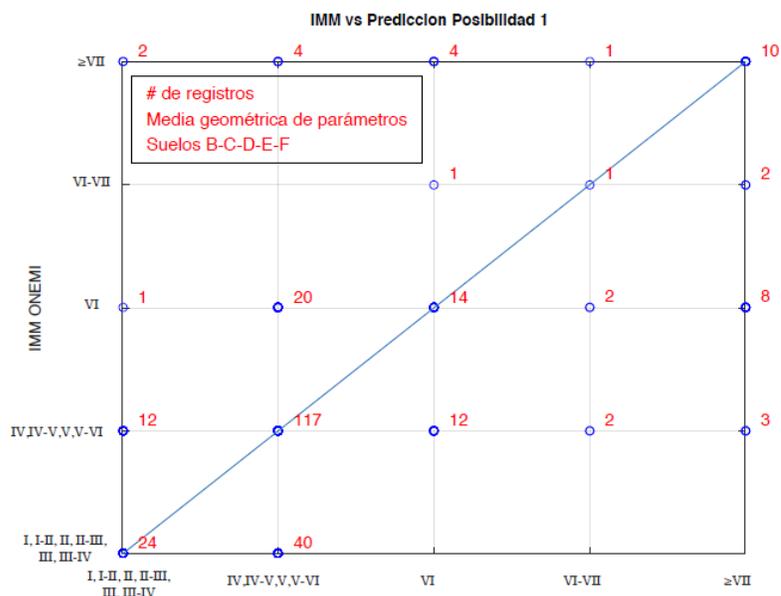


Figura 62: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso 4.

Caso Extra

Para la generación de este modelo se consideran los parámetros que de acuerdo al *loading plot* son los que aportan mayor información al modelo. Estos son: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{SI})$, $\log(\text{Ia})$ e IJMA . Cabe mencionar que para este caso son considerados todos los tipos de suelos (Caso 0).

En este caso son generados 8 modelos diferentes, los cuales están definidos en la Tabla 41 según qué criterios son considerados y cuáles no.

Tabla 41: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Regresión con PLS
1	1	1	1
2	1	1	0
3	1	0	0
4	0	0	0
5	0	0	1
6	0	1	1
7	0	1	0
8	1	0	1

En la Tabla 42 se resumen los resultados obtenidos para cada uno de los modelos. La fila marcada en verde corresponde a la que obtuvo un mayor porcentaje de clasificación considerando las tres mayores posibilidades.

Tabla 42: Resumen porcentajes de clasificación según caso y modificaciones

Modificación	Posibilidad 1 [%]	Posibilidad 2 [%]	Posibilidad 3 [%]	Total [%]
1	55.5	30.1	7.0	92.6
2	55.2	33.8	8.7	97.7
3	55.2	31.8	10.0	97.0
4	55.6	33.4	8.0	97.0
5	55.2	29.4	8.0	92.6
6	55.5	30.1	7.0	92.6
7	55.5	35.8	6.0	97.3
8	55.5	29.4	7.0	91.9

En la Figura 63 se observa la diferencia entre la clase predicha por el modelo de Regresión Logística Multinomial y la clase a la cual corresponde el valor informado por la ONEMI. De ella se puede desprender que 66 de los 134 registros mal clasificados fueron clasificados en valores menores a los informados por la ONEMI, por lo que los 68 restantes son clasificados en clases de valor mayor al informado. Por esto, dado que aproximadamente el 50% de los valores son subestimados y el otro 50% sobreestimados, no se puede decir si corresponde a un modelo conservador o no conservador.

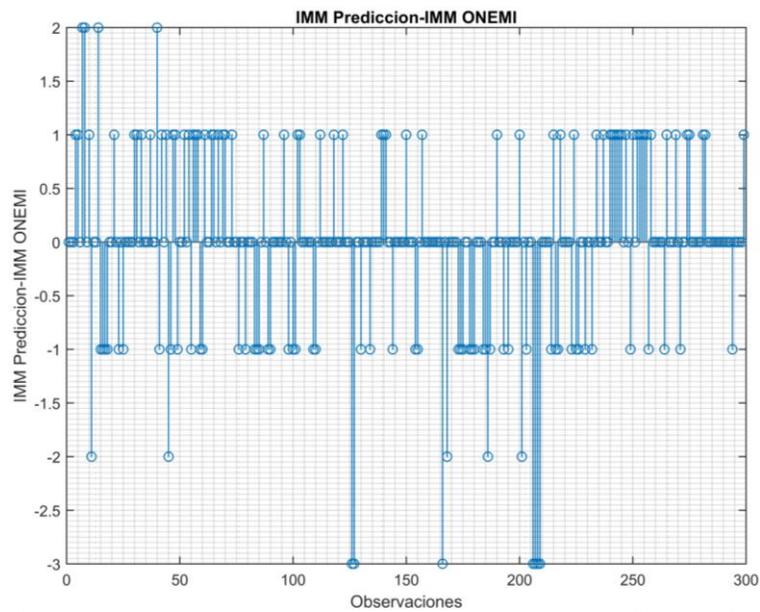


Figura 63: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 5 clases, Caso Extra.

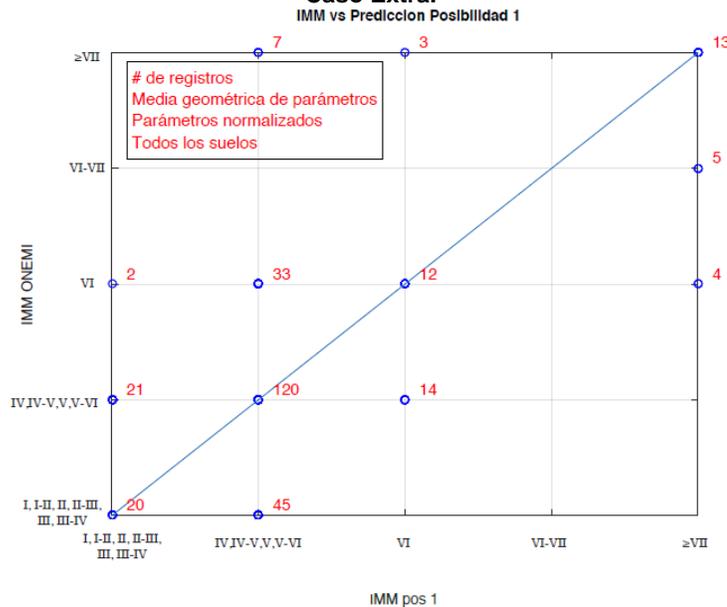


Figura 64: Predicción de IMM vs IMM ONEMI. RLM 5 clases, Caso Extra.

En la Figura 64 se observa que para las Clases 1, 2 y 3 la diferencia entre el valor predicho por el modelo y la clase correspondiente al valor informado por la ONEMI es de máximo una clase (no considerando la Clase 5). Sin embargo, como en este caso dado que son clases y agrupan a más de un valor de la escala de IMM no se puede decir de cuantos grados es la diferencia, podría ser de 0.5 a 4 grados.

Para las clases 1 y 2 el modelo actúa de manera no conservadora y para las clases 3 y 5 de forma conservadora.

6.2.3 Clasificación con 2 clases

Este caso corresponde a la utilización de dos clases, distinguiendo aquellos valores de $IMM \leq V$ e $IMM > V$.

Tabla 43: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	Regresión con PLS	Eliminación de Variables
1	1	1	1	1
2	1	1	1	0
3	1	1	0	0
4	1	0	0	0
5	0	0	0	0
6	0	0	0	1
7	0	0	1	1
8	0	1	1	1
9	0	1	0	0
10	0	0	1	0
11	1	0	0	1
12	0	1	1	0
13	1	0	1	0
14	0	1	0	1
15	1	1	0	1
16	1	0	1	1

El número de modelos generados, considerando los diferentes criterios mencionados anteriormente, son 80 (16 modelos por cada caso dependiente del tipo de suelo). En la Tabla 43 se muestra a qué corresponde cada uno de los 16 modelos, el valor 1 es si está aplicado el criterio y 0 si no.

En la Tabla 44 se muestran los porcentajes de clasificación de cada modelo. En este caso, dado que son solo dos clases, el 100% de los registros son clasificados entre la primera y segunda posibilidad.

En la Tabla 44, las celdas de color verde indican cuál modelo tiene un mayor porcentaje de clasificación considerando solo la primera posibilidad.

Los resultados del Caso 1 no son considerados ya que este corresponde al caso donde se consideran solo los registros asociados al suelo tipo A (roca dura), de los cuales se tienen solo 48 registros, por lo que son muy pocos para poder generar alguna conclusión.

Tabla 44: Resumen porcentajes de clasificación según caso y modificaciones

	Caso 0		Caso 1		Caso 2		Caso 3		Caso 4	
	Pos1 [%]	Pos2 [%]								
1	75.9	24.1	47.4	52.6	70.2	29.8	85.1	14.9	77.9	22.1
	100.0		100.0		100.0		100.0		100.0	
2	75.3	24.7	42.1	57.9	70.2	29.8	85.1	14.9	77.1	22.9
	100.0		100.0		100.0		100.0		100.0	
3	76.9	23.1	42.1	57.9	54.8	45.2	62.8	37.2	80.0	20.0
	100.0		100.0		100.0		100.0		100.0	
4	73.6	26.4	57.9	42.1	60.7	39.3	52.1	44.6	76.4	23.6
	100.0		100.0		100.0		100.0		100.0	
5	84.9	15.1	36.8	52.6	73.8	26.2	86.8	13.2	85.4	14.6
	100.0		100.0		100.0		100.0		100.0	
6	86.0	14.0	63.2	36.8	81.9	19.0	83.5	16.5	85.0	15.0
	100.0		100.0		100.0		100.0		100.0	
7	75.9	24.1	42.1	57.9	71.4	28.6	85.1	14.9	78.6	21.4
	100.0		100.0		100.0		100.0		100.0	
8	75.9	24.1	47.4	52.6	70.2	29.8	85.1	14.9	77.9	22.1
	100.0		100.0		100.0		100.0		100.0	
9	84.6	15.4	57.9	42.1	78.6	21.4	86.0	14.0	84.6	15.4
	100.0		100.0		100.0		100.0		100.0	
10	75.3	24.7	57.9	42.1	70.2	29.8	85.1	14.9	78.2	21.8
	100.0		100.0		100.0		100.0		100.0	
11	75.9	24.1	47.4	52.6	39.3	31.0	66.9	33.1	77.1	22.9
	100.0		100.0		100.0		100.0		100.0	
12	75.3	24.7	42.1	57.9	70.2	29.8	85.1	14.9	77.1	22.9
	100.0		100.0		100.0		100.0		100.0	
13	75.3	24.7	57.9	42.1	70.2	29.8	85.1	14.9	78.2	21.8
	100.0		100.0		100.0		100.0		100.0	
14	86.0	14.0	42.1	57.9	81.0	19.0	87.6	12.4	86.1	13.9
	100.0		100.0		100.0		100.0		100.0	
15	80.3	19.7	68.4	31.6	64.3	35.7	79.3	20.7	80.0	20.0
	100.0		100.0		100.0		100.0		100.0	
16	75.9	24.1	42.1	57.9	71.4	28.6	85.1	14.9	78.6	21.4
	100.0		100.0		100.0		100.0		100.0	

Caso 0 según tipo de suelo-Caso 14 según criterios utilizados

En la Figura 65 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística y el valor informado por la ONEMI. De ella se puede desprender que el 78.6% de los registros pertenecientes al set de prueba que son mal clasificados (33 de 42) son clasificados en un valor menor al informado por la ONEMI. En consecuencia, se puede decir que es un modelo no conservador.

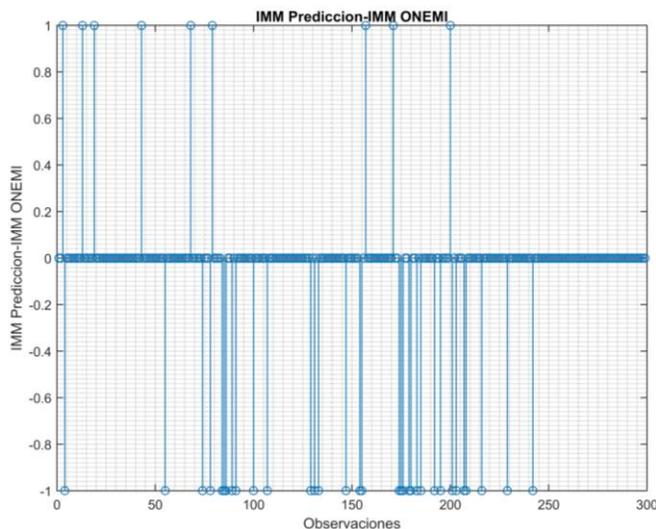


Figura 65: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases. Caso 0.

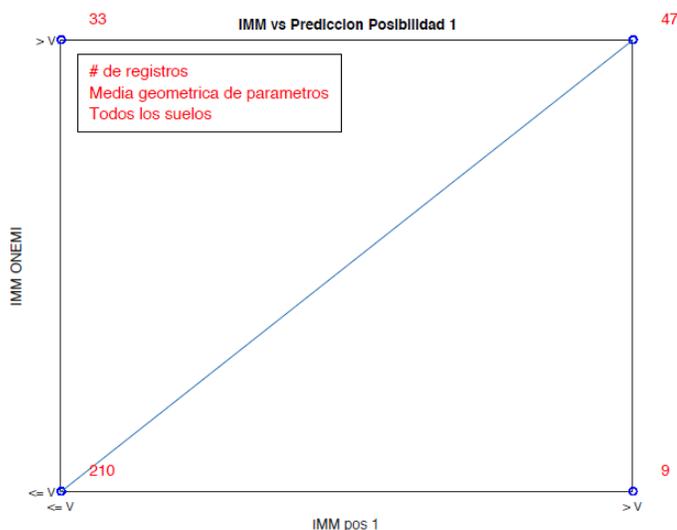


Figura 66: Predicción de IMM vs IMM ONEMI. RLM 2 clases. Caso 0.

De la Figura 66 se desprende que si bien son más los registros mal clasificados para la clase “ $\leq V$ ”, en proporción al número de registros totales de cada clase, el mayor error de clasificación ocurre en la clase “ $> V$ ” con un 19.1% versus un 15.7 de la clase “ $\leq V$ ”. Sin embargo, el error es bajo y similar en ambas clases.

Caso 2 según tipo de suelo-Caso 14 según criterios utilizados

En la Figura 67 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística Multinomial y el valor informado por la ONEMI. De ella se puede desprender que 8 de los 16 registros del set de prueba que son mal clasificados, son clasificados en un valor menor al informado por la ONEMI y los otros 8 con un valor mayor. Por lo que este modelo no se puede definir ni como conservador o no conservador.

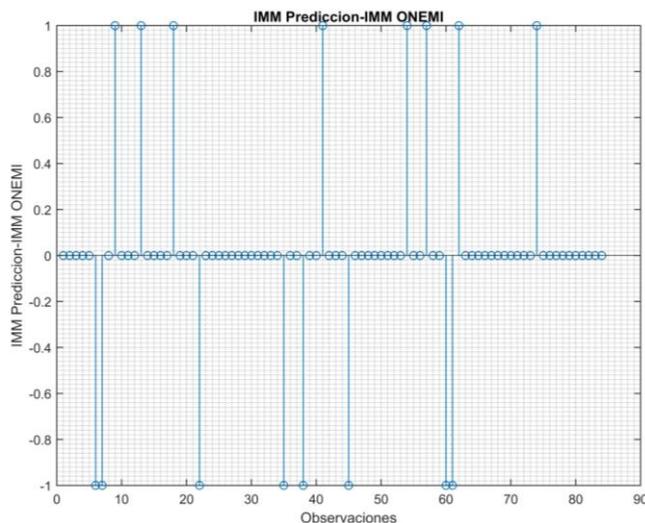


Figura 67: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases. Caso 2.

En la Figura 68 se observa que para ambas clases son 8 los registros mal clasificados considerando la primera posibilidad. Sin embargo, el porcentaje equivalente de acuerdo al total de registros de cada clase es de 17.8% y 34.8%, para la clase “ $\leq V$ ” y “ $> V$ ” respectivamente.

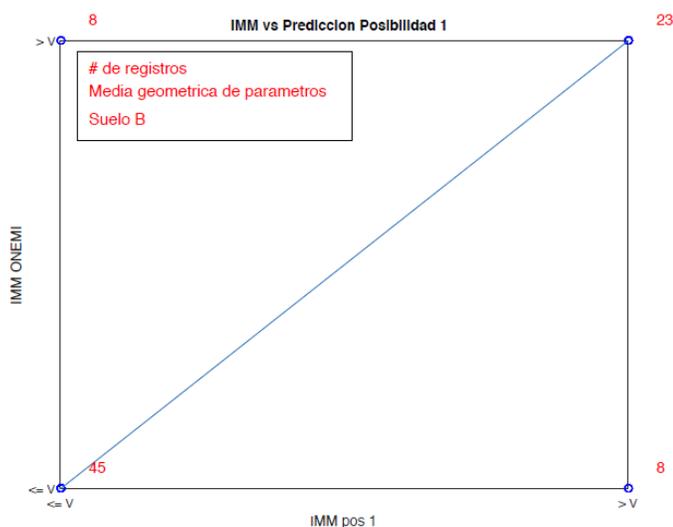


Figura 68: Predicción de IMM vs IMM ONEMI. RLM 2 clases. Caso 2.

Caso 3 según tipo de suelo-Caso 14 según criterios utilizados

En la Figura 69 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística Multinomial y el valor informado por la ONEMI. De ella se puede desprender que el 80.0% de los registros pertenecientes al set de prueba que son mal clasificados (12 de 15) son clasificados en un valor menor al informado por la ONEMI. En consecuencia, se puede decir que es un modelo no conservador.

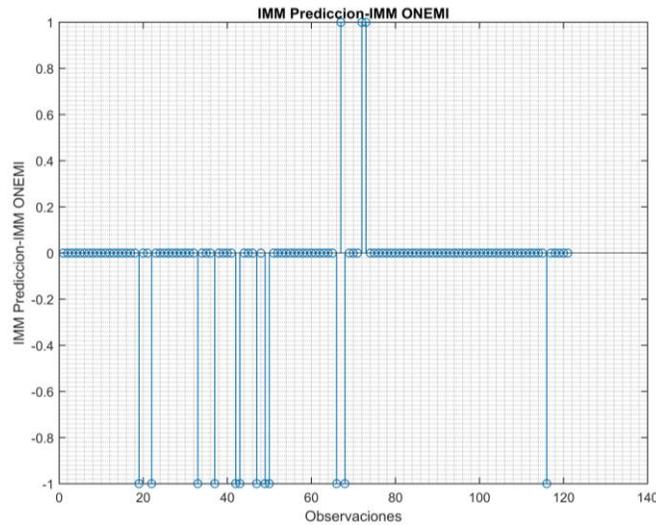


Figura 69: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases. Caso 3.

La Figura 70 muestra por clase los registros bien y mal clasificados. Para la clase “ $\leq V$ ” el porcentaje de registros mal clasificados es de un 12.4%; y para la clase “ $> V$ ” es de un 33.4%.

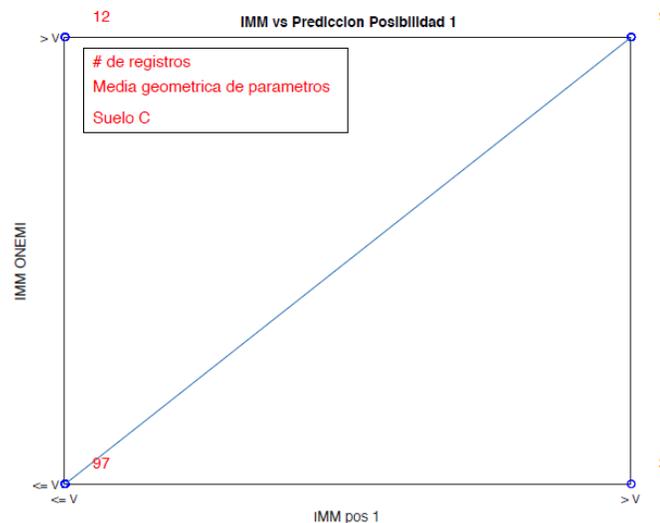


Figura 70: Predicción de IMM vs IMM ONEMI. RLM 2 clases. Caso 3.

Caso 4 según tipo de suelo-Caso 14 según criterios utilizados

En la Figura 71 se observa la diferencia entre el valor de la Intensidad de Mercalli Modificada predicho por el modelo de Regresión Logística Multinomial y el valor informado por la ONEMI. De ella se puede desprender que el 69.2% de los registros pertenecientes al set de prueba que son mal clasificados (27 de 39) son clasificados en un valor menor al informado por la ONEMI. En consecuencia, se puede decir que es un modelo no conservador.

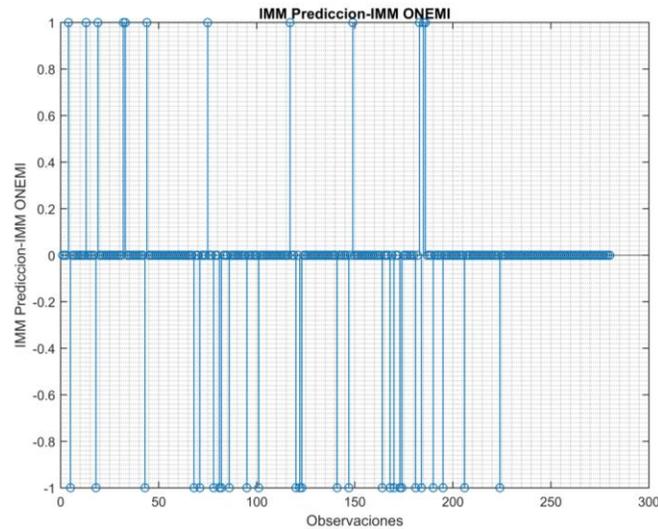


Figura 71: Diferencia entre IMM predicho e IMM informado por la ONEMI. RLM 2 clases. Caso 4.

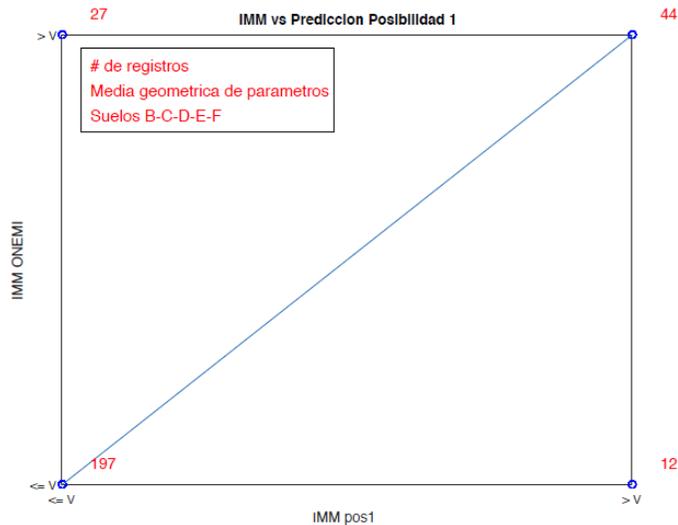


Figura 72: Predicción de IMM vs IMM ONEMI. RLM 2 clases. Caso 4.

La Figura 72 muestra por clase los registros bien y mal clasificados. Para la clase “ $\leq V$ ” el porcentaje de registros mal clasificados es de un 13.7%; y para la clase “ $> V$ ” es de un 27.3%.

En resumen, para los 4 casos analizados de Regresión Logística considerando 2 clases, el porcentaje de clasificación correcta es mayor al 80% (Tabla 45). Y si la clasificación se analiza por clases, en todos los casos el porcentaje de los registros mal clasificados para la clase “> V” es mayor que para la clase “≤ V”. Este último hecho puede ser debido a que el número de registros del set de entrenamiento pertenecientes a la clase “≤ V” es mayor que aquellos parte de la clase “> V”, porcentajes muy similares para el set de datos de prueba (Tabla 46).

Tabla 45: Resumen resultados Regresión Logística Multinomial considerando 2 clases

	% Clasificación correcta	% (Pred – ONEMI) < 0 (total registros set de prueba)	% mal clasificado clase ≤ V	% mal clasificado clase > V
Caso 0	86.0	11.0	15.7	19.1
Caso 2	81.0	11.8	17.8	34.8
Caso 3	87.6	9.9	12.4	33.4
Caso 4	86.1	9.6	13.7	27.3

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Tabla 46: Porcentaje de los registros pertenecientes a la clase “≤ V” para el set de entrenamiento y prueba

	% registros ≤ V, set de entrenamiento	% registros ≤ V, set de prueba
Caso 0	82.5	82.6
Caso 2	64.0	63.1
Caso 3	73.2	73.2
Caso 4	74.8	74.6

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

6.2.4 Clasificación considerando un parámetro a la vez

La Tabla 47 muestra a que corresponde cada caso según el criterio utilizado, que para estos modelos pueden ser la normalización de los parámetros, el cálculo de la media geométrica y/o realizar el cálculo de la regresión lineal utilizada en Regresión Logística Multinomial mediante Mínimos Cuadrados Parciales.

Tabla 47: Modelos según los criterios que se aplican en ellos

Caso	Normalización	Media Geométrica	PLS
1	1	1	1
2	1	1	0
3	1	0	0
4	0	0	0
5	0	0	1
6	0	1	1
7	0	1	0
8	1	0	1

De la Tabla 49 a la Tabla 53 se muestran los resultados obtenidos para cada parámetro.

En las Tabla 49 a la Tabla 53, las celdas de color naranja corresponden al caso que mayor porcentaje de clasificación presenta, considerando la primera posibilidad. En este trabajo se muestran los gráficos asociados a aquel modelo que mayor porcentaje de clasificación obtiene por parámetro (celda color verde).

Del análisis de los gráficos de la Figura 73 se tiene que el porcentaje de los registros clasificados con una diferencia máxima de 1 grado va desde ~40% a ~50%. Siendo 51.2% en el caso del modelo generado utilizando solo la IJMA, y un 40.5% para el modelo que utiliza la Intensidad de Arias. Al considerar el rango [-1,1] en todos los modelos este porcentaje es mayor al 80%, superando el 90% en el caso del modelo que utiliza el PGV. En la Tabla 48 se muestra el resumen de estos valores.

Tabla 48: Resumen porcentajes de clasificación de registros (RLM por parámetro)

Parámetro utilizado en el modelo	% registros clasificados correctamente (posibilidad 1)	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
log(PGA) (Caso 3)	39.7	82.6	62.8
log(PGV) (Caso 3)	45.5	91.7	79.3
log(Ia) (Caso 3)	40.5	83.5	61.2
log(SI) (Caso 3)	42.1	86.8	71.9
IJMA (Caso 3)	38.0	89.3	71.9

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Se calcula el porcentaje de los registros del set de prueba que son clasificados correctamente y/o con un valor mayor al informado por la ONEMI, datos mostrados en la Tabla 54. Una primera observación importante de esta tabla es que casi no existen salidas del modelo con valores entre dos escalas (I-II, II-III, etc), esto debido a que el set de entrenamiento tiene muy pocos valores de este tipo. Y en el set de pruebas solo hay 2 registros asociados a este tipo de valores. Además en esta tabla se observa que en general el porcentaje de los registros del set de prueba que son clasificados correctamente y/o con un valor mayor al informado por la ONEMI es mayor al 60%, con algunas excepciones que son del 40%.

En la Tabla 55 se muestran los porcentajes de los registros del set de pruebas en que la predicción del valor de la IMM es igual o mayor en máximo 1 grado al valor informado por la ONEMI, en este caso no existe mayor diferencia con la Tabla 54. Solo en algunos casos ocurre una disminución, en general de 5 puntos porcentuales, por lo que el porcentaje se mantiene ~60%

Tabla 49: log(PGA)

	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
1	36.8	26.8	19.1	31.6	26.3	26.3	35.7	25.0	22.6	35.5	31.4	18.2	36.1	30.7	15.4
	82.7			84.2			83.3			85.1			82.2		
2	27.1	29.4	19.1	31.6	15.8	10.5	34.5	22.6	13.1	33.1	28.9	15.7	32.1	22.5	22.1
	75.6			57.9			70.2			77.7			76.7		
3	28.4	28.4	16.7	15.8	15.8	31.6	29.8	21.4	11.9	33.1	28.1	14.9	30.0	23.6	22.5
	73.5			63.2			63.1			76.1			76.1		
4	31.4	26.8	24.7	10.5	52.6	10.5	31.0	28.6	20.3	39.7	24.0	16.5	35.7	29.3	20.0
	82.9			73.6			79.9			80.2			85.0		
5	35.8	28.8	18.1	26.3	42.1	10.5	35.7	20.2	26.2	38.8	28.9	19.0	35.7	30.4	16.8
	82.7			78.9			82.1			86.7			82.9		
6	36.8	26.8	19.1	31.6	26.3	26.3	35.7	25.0	22.6	35.5	31.4	18.2	36.1	30.7	15.4
	82.7			84.2			83.3			85.1			82.2		
7	31.1	29.1	22.4	10.5	47.4	10.5	36.9	26.2	16.7	37.2	30.6	15.7	35.4	28.6	21.1
	82.6			68.4			79.8			83.5			85.1		
8	35.8	28.8	18.1	26.3	42.1	10.5	35.7	20.2	26.2	38.8	28.9	19.0	35.7	30.4	16.8
	82.7			78.9			82.1			86.7			82.9		

Tabla 50: log(PGV)

	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
1	36.5	29.4	16.7	36.8	31.6	10.5	35.7	28.6	17.9	37.2	37.2	14.0	36.8	31.4	17.1
	82.6			78.9			82.2			88.4			85.3		
2	33.8	32.8	16.1	26.3	21.1	21.1	36.9	21.4	22.6	45.5	28.9	12.4	35.4	28.9	22.9
	82.7			65.5			80.9			86.8			87.2		
3	31.8	35.8	16.4	10.5	26.3	15.8	29.8	29.8	23.8	43.0	31.4	8.3	36.8	30.4	20.4
	84.0			52.6			83.4			82.7			87.6		
4	36.5	31.1	16.1	42.1	5.3	26.3	36.9	31.0	20.2	43.8	28.9	13.2	38.2	30.4	17.9
	83.7			73.7			88.1			85.9			86.5		
5	39.1	25.8	18.4	21.1	36.8	10.5	34.5	31.0	15.5	39.7	32.2	17.4	38.9	29.6	15.7
	83.3			68.4			81.0			89.3			84.2		
6	36.5	29.4	16.7	36.8	31.6	10.5	35.7	28.6	17.9	37.2	37.2	14.0	36.8	31.4	17.1
	82.6			78.9			82.2			88.4			85.3		
7	36.1	30.1	18.1	31.6	31.6	10.5	39.3	25.0	20.2	43.8	30.6	14.0	37.5	30.0	18.9
	84.3			73.7			84.5			88.4			86.4		
8	39.1	25.8	18.4	21.1	36.8	10.5	34.5	31.0	15.5	39.7	32.2	17.4	38.9	29.6	15.7
	83.3			68.4			81.0			89.3			84.2		

Tabla 51: log(la)

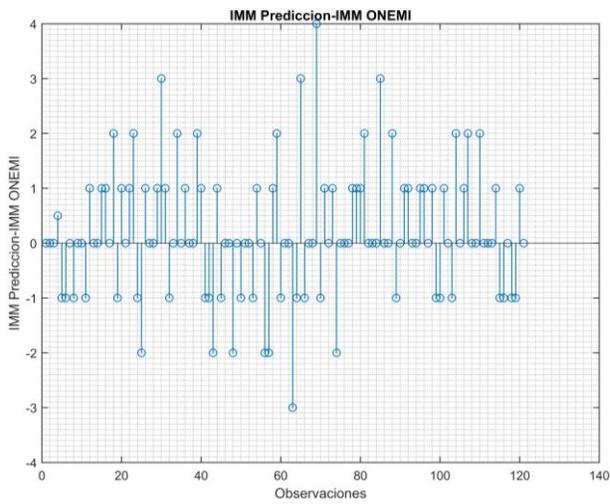
	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
1	36.8	27.8	18.7	31.6	42.1	10.5	34.5	26.2	25.0	37.2	30.6	18.2	36.1	28.2	19.6
	83.3			84.2			85.7			86.0			83.9		
2	31.8	29.8	16.4	36.8	26.3	10.5	34.5	22.6	19.0	35.5	28.9	11.6	32.5	25.4	21.1
	78.0			73.6			76.1			76.0			79.0		
3	29.8	29.0	20.4	21.1	36.8	10.5	32.1	17.9	21.4	38.8	24.8	11.6	32.1	25.4	19.6
	79.2			68.4			71.4			75.2			77.1		
4	32.4	30.8	22.1	36.8	21.1	15.8	31.0	35.7	20.2	36.4	33.1	14.9	34.6	30.7	21.8
	85.3			73.7			86.9			84.4			87.1		
5	37.5	27.4	17.7	31.6	31.6	15.8	33.4	26.2	23.8	40.5	28.1	16.5	35.4	30.4	17.9
	82.6			79.0			83.4			85.1			83.7		
6	36.8	27.8	18.7	31.6	42.1	10.5	34.5	26.2	25.0	37.2	30.6	18.2	36.1	28.2	19.6
	83.3			84.2			85.7			86.0			83.9		
7	33.8	29.8	20.7	36.8	26.3	21.1	33.4	34.5	19.0	37.2	34.7	16.5	32.9	32.5	21.4
	84.3			84.2			86.9			88.4			86.8		
8	37.5	27.4	17.7	31.6	31.6	15.8	33.4	26.2	23.8	40.5	28.1	16.5	35.4	30.4	17.9
	82.6			79.0			83.4			85.1			83.7		

Tabla 52: log(SI)

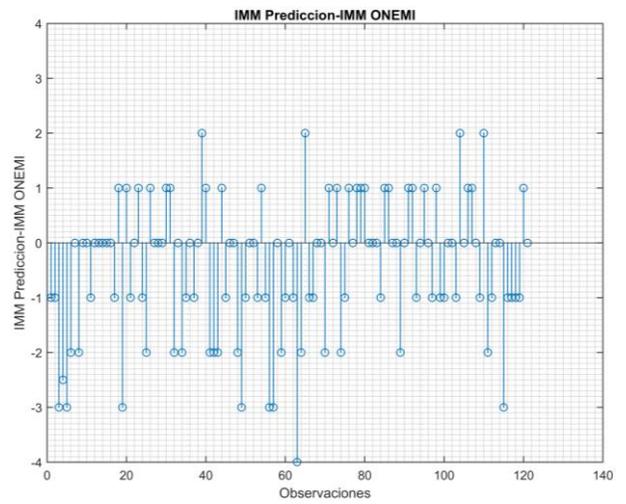
	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
3	24.1	24.1	19.1	21.1	36.8	5.3	23.8	6.2	5.0	22.3	32.2	24.0	27.1	22.9	22.9
	67.3			63.2			35.5			78.5			72.9		
4	35.8	27.8	19.7	42.1	21.1	15.8	38.1	27.4	19.0	42.1	29.8	14.0	36.8	26.4	21.4
	83.3			79.0			84.5			85.9			84.6		
5	37.1	28.8	15.7	36.8	31.6	10.5	34.5	31.0	17.9	40.5	30.6	14.9	37.5	26.4	20.0
	81.6			78.9			83.4			86.0			83.9		
8	37.1	28.8	15.7	36.8	31.6	10.5	34.5	31.0	17.9	40.5	30.6	14.9	37.5	26.4	20.0
	81.6			78.9			83.4			86.0			83.9		

Tabla 53: IJMA

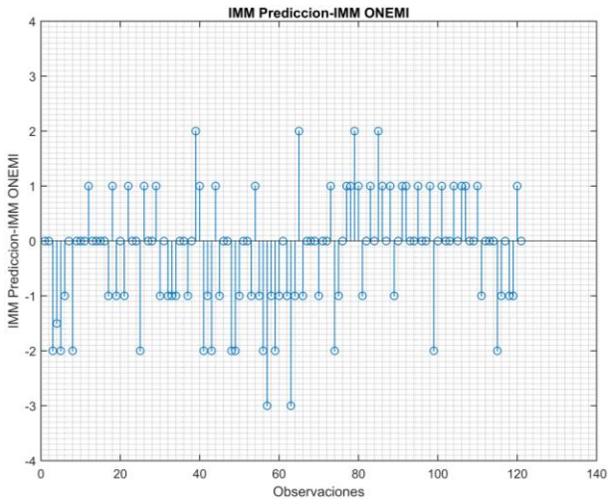
	Caso 0			Caso 1			Caso 2			Caso 3			Caso 4		
	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]	Pos1 [%]	Pos2 [%]	Pos3 [%]
3	22.1	24.4	24.4	21.1	31.6	21.1	20.2	31.0	26.2	26.4	30.6	19.0	28.2	20.0	21.4
	70.9			73.8			77.4			76.0			69.6		
4	34.8	29.8	18.7	36.8	31.6	10.5	38.1	29.8	17.9	38.0	34.7	14.9	32.1	31.1	21.8
	83.3			78.9			85.8			87.6			85.0		
5	38.1	27.1	16.4	36.8	31.6	10.5	33.4	32.1	16.7	38.0	33.1	14.9	37.5	27.1	19.6
	81.6			78.9			82.2			86.0			84.2		
8	38.1	27.1	16.4	36.8	31.6	10.5	33.4	32.1	16.7	38.0	33.1	14.9	37.5	27.1	19.6
	81.6			78.9			82.2			86.0			84.2		



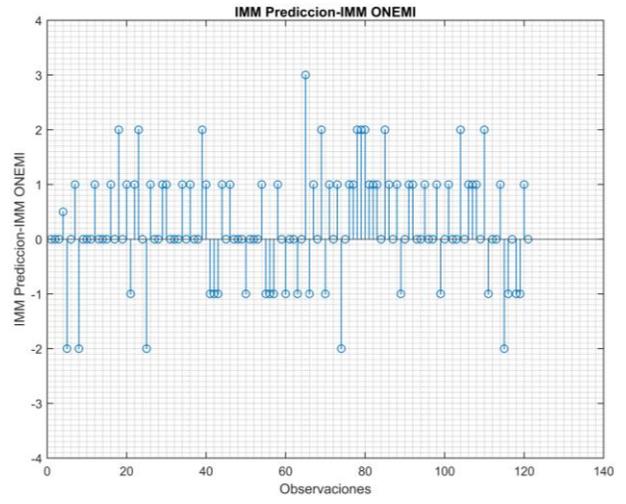
(a)



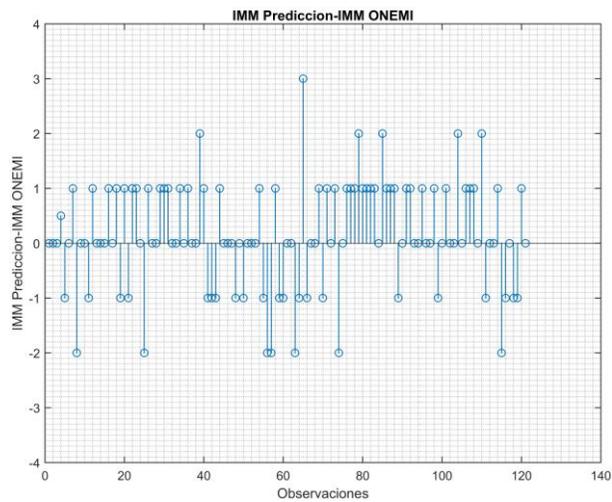
(b)



(c)

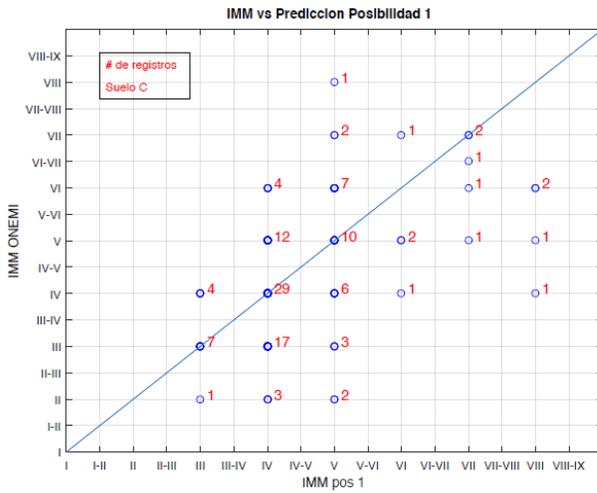


(d)

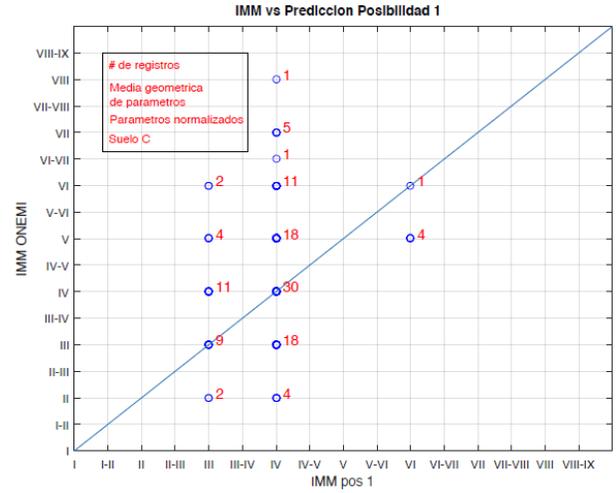


(e)

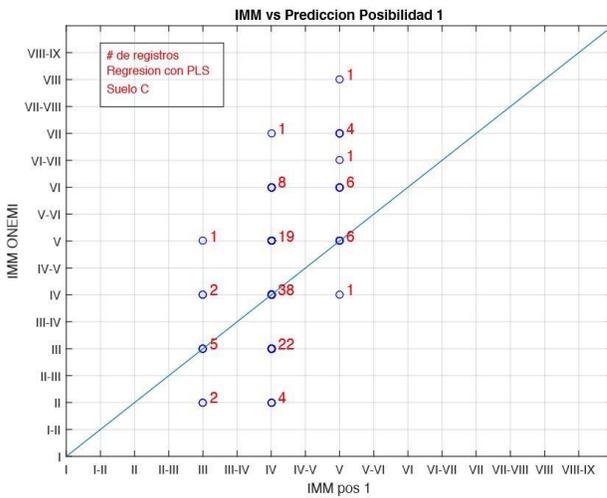
Figura 73: Diferencia entre IMM predicho e IMM informado por la ONEMI. (a) $\log(PGA)$, (b) $\log(PGV)$, (c) $\log(Ia)$, (d) $\log(SI)$, (e) IJMA. Utilizando RLM.



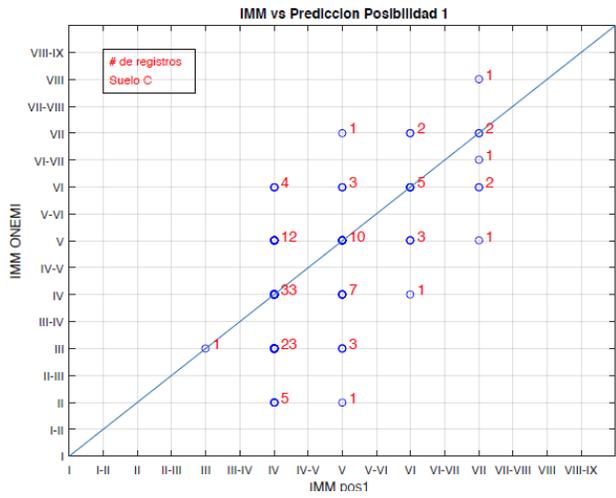
(a)



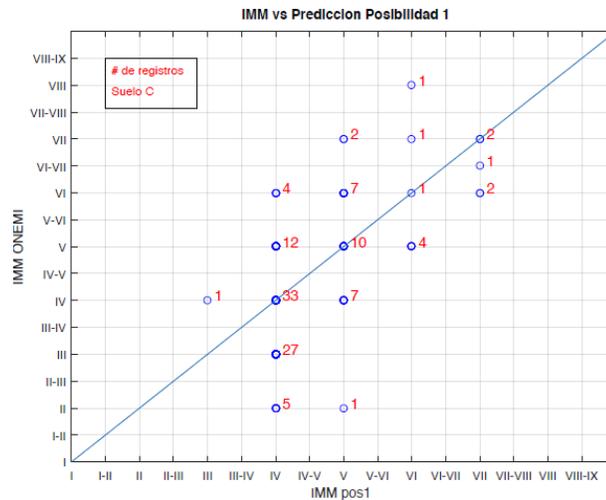
(b)



(c)



(d)



(e)

Figura 74: Predicción de IMM vs IMM ONEMI. RLM por parámetro (a) log(PGA), (b) log(PGV), (c) log(Ia), (d) log(Si), (e) IJMA. Utilizando RLM.

Tabla 54: Porcentaje de registros clasificados correctamente y/o con un valor mayor

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
log(PGA)	--	-----	8/12	-----	49/65	-----	21/31	-----	3/4	-----	5/5	-----	4/4	-----
	--	-----	66.7	-----	75.4	-----	67.7	-----	75.0	-----	100.0	-----	100.0	-----
log(PGV)	--	-----	11/28	-----	52/88	-----	-----	-----	5/5	-----	-----	-----	-----	-----
	--	-----	39.3	-----	59.1	-----	-----	-----	100.0	-----	-----	-----	-----	-----
log(Ia)	--	-----	7/10	-----	64/92	-----	7/19	-----	-----	-----	-----	-----	-----	-----
	--	-----	70.0	-----	69.6	-----	36.8	-----	-----	-----	-----	-----	-----	-----
log(SI)	--	-----	1/1	-----	61/77	-----	21/25	-----	9/11	-----	6/7	-----	-----	-----
	--	-----	100.0	-----	79.2	-----	84.0	-----	81.8	-----	85.7	-----	-----	-----
IJMA	--	-----	0/1	-----	65/81	-----	18/27	-----	5/7	-----	5/5	-----	-----	-----
	--	-----	0.0	-----	80.2	-----	66.7	-----	71.4	-----	100.0	-----	-----	-----

Tabla 55: Porcentaje de registros clasificados correctamente o máximo 1 grado por sobre el valor informado por la ONEMI

Caso	II	II-III	III	III-IV	IV	IV-V	V	V-VI	VI	VI-VII	VII	VII-VIII	VIII	VIII-IX
log(PGA)	--	-----	8/12	-----	46/65	-----	16/31	-----	2/4	-----	4/5	-----	0/4	-----
	--	-----	66.7	-----	70.8	-----	51.6	-----	50.0	-----	80.0	-----	0.0	-----
log(PGV)	--	-----	11/28	-----	48/88	-----	-----	-----	5/5	-----	-----	-----	-----	-----
	--	-----	39.3	-----	54.5	-----	-----	-----	100.0	-----	-----	-----	-----	-----
log(Ia)	--	-----	7/10	-----	60/92	-----	7/19	-----	-----	-----	-----	-----	-----	-----
	--	-----	70.0	-----	65.2	-----	36.8	-----	-----	-----	-----	-----	-----	-----
log(SI)	--	-----	1/1	-----	56/77	-----	17/25	-----	8/11	-----	5/7	-----	-----	-----
	--	-----	100.0	-----	72.7	-----	68.0	-----	72.7	-----	71.4	-----	-----	-----
IJMA	--	-----	0/1	-----	60/81	-----	17/27	-----	5/7	-----	5/5	-----	-----	-----
	--	-----	0.0	-----	74.1	-----	63.0	-----	71.4	-----	100.0	-----	-----	-----

6.3 Resumen y Análisis de Resultados

De los resultados mostrados en la Sección 6.1 (Redes Neuronales) y la Sección 6.2 (Regresión Logística Multinomial), se generan tablas de resumen para hacer más fácil el análisis de cada método, la determinación del desempeño, y la comparación entre ambos métodos utilizados.

De la Tabla 56 y Tabla 57 se puede observar que el hecho de hacer una distinción del tipo de suelo asociado al registro, en el caso de RNA no implica un aumento significativo en el porcentaje de clasificación, y por el lado de RLM se observa que los porcentajes mayores se obtienen al utilizar los datos considerando todos los suelos (Caso 0: 44.4%) o, todos los suelos menos roca dura (Caso 4: 43.9%). De la comparación de estas dos tablas, se puede concluir que en general Regresión Logística Multinomial presenta mejores resultados.

Por otro lado, de la Tabla 56 se puede decir que el porcentaje de clasificación correcta del Caso Extra (24.2%), es decir solo considerar aquellos parámetros que mayor información aportan, según el *loading plot* realizado mediante PLS, es similar a los porcentajes de los modelos en que se consideran todos los parámetros e incluso levemente inferior. A diferencia de lo observado en la Tabla 57 en que el porcentaje (39.5%) asociado a este caso es el segundo mayor de todos los modelos generados mediante Regresión Logística Multinomial (17 clases) aunque la diferencia respecto a los modelos con menor porcentaje no es muy grande.

Tabla 56: Resumen porcentajes de clasificación de registros (RNA 16 parámetros)

Caso Según Tipo de Suelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
0	25.5	80.5	49.7
2	31.0	81.0	54.8
3	26.7	75.0	43.4
4	30.7	84.3	52.1
Caso Extra	24.2	80.5	49.0

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

Tabla 57: Resumen porcentajes de clasificación de registros RLM 17 clases

Caso Según Tipo de Suelo	% registros clasificados correctamente (posibilidad 1)	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
0	44.4	84.6	63.2
2	38.1	81.0	58.4
3	33.9	73.6	48.8
4	43.9	86.4	64.2
Caso Extra	39.5	85.6	63.9

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

De la Tabla 58 se observa que en los modelos generados por RNA no hay un parámetro que destaque sobre otro si se considera solo el porcentaje de registros clasificados correctamente, pero si se considera el porcentaje de registros clasificados en el rango [0,1], el modelo que utiliza log(PGA) y el modelo que utiliza log(PGV) tienen mejores resultados.

De la Tabla 59 se tiene que si bien existen algunas diferencias entre los porcentajes de clasificación de cada uno de los modelos, estas no son muy grandes. Y aquel que presenta el mayor porcentaje tanto en los registros clasificados correctamente y registros clasificados en el rango [0,1] es el generado considerando log(PGV).

Por lo tanto, del análisis de ambas tablas se puede decir que aquel parámetro que arroja mejores resultados es log(PGV).

Tabla 58: Resumen porcentajes de clasificación de registros (RNA por parámetro)

Parámetro utilizado en el modelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
log(PGA) (Caso 0)	29.5	80.5	59.7
log(PGV) (Caso 0)	26.2	78.5	57.7
log(Ia) (Caso 3)	28.3	80.0	48.4
log(SI) (Caso 3)	28.4	80.0	48.4
IJMA (Caso 0)	28.2	80.5	53.7

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Tabla 59: Resumen porcentajes de clasificación de registros (RL por parámetro)

Parámetro utilizado en el modelo	% registros clasificados correctamente (posibilidad 1)	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
log(PGA) (Caso 3)	39.7	82.6	62.8
log(PGV) (Caso 3)	45.5	91.7	79.3
log(Ia) (Caso 3)	40.5	83.5	61.2
log(SI) (Caso 3)	42.1	86.8	71.9
IJMA (Caso 3)	38.0	89.3	71.9

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Del análisis de la Tabla 56, Tabla 57, Tabla 58 y Tabla 59 se concluye que para ambos métodos (RNA y RL) se obtienen mejores resultados si se consideran los parámetros por separado, en particular log(PGV). Además, queda claro que no existe un mejoramiento al ocupar los parámetros que se ocupan por separado (log(PGA), log(PGV), log(Ia), log(SI) e IJMA) todos juntos en un solo modelo (Caso Extra). Esto ocurre por lo que se puede observar en el loading plot, las cinco variables mencionadas están muy correlacionadas entre sí, por lo que al ocupar todas a la vez, por su alta correlación es como si se estuviera considerando solo una.

Cabe agregar, que de los modelos elegidos por ser los que obtienen un mayor porcentaje para los modelos mostrados en la Tabla 56, Tabla 57, Tabla 58 y Tabla 59, en su mayoría son los que consideran la media geométrica de las variables. Y en Regresión Logística, de la totalidad de los modelos elegidos (4), dos utilizan PLS para la determinación de la regresión lineal utilizada en este método.

En la Tabla 60 se muestran los resultados obtenidos mediante Regresión Logística Multinomial al considerar dos clases: $IMM \leq V$ e $IMM > V$. Se hace esta distinción para separar aquellos registros asociados a IMM en que el sismo no provoca daño ($IMM \leq V$) y aquellos en que sí ($IMM > V$). En general se obtienen buenos resultados. Para todos los casos (según el tipo de suelo) el porcentaje es mayor al 80%.

Además, al igual que lo observado en las tablas anteriores, el dato del tipo de suelo (casos) no aporta información relevante. Es decir, que no es un parámetro importante al momento de realizar la Regresión Logística Multinomial.

Tabla 60: Resumen resultados RLM considerando 2 clases

	% Clasificación correcta	% (Pred – ONEMI) < 0 (total registros set de prueba)	% mal clasificado clase $\leq V$	% mal clasificado clase $> V$
Caso 0	86.0	11.0	15.7	19.1
Caso 2	81.0	11.8	17.8	34.8
Caso 3	87.6	9.9	12.4	33.4
Caso 4	86.1	9.6	13.7	27.3

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Por último, analizando los modelos en que se considera solo un parámetro a la vez, se tiene que para Regresión Logística Multinomial (Tabla 61) independiente del tipo de suelo considerado (Casos) el modelo que utiliza el parámetro $\log(PGV)$ es aquel que presenta un mayor porcentaje de clasificación. En el caso de los modelos realizados mediante Redes Neuronales (Tabla 62) cada caso tiene un parámetro que mejor se ajusta según el tipo de suelo. Por lo anterior se podría decir que en caso de querer realizar una “predicción” para un nuevo evento sísmico se recomienda usar el método de Regresión Logística y utilizando solo $\log(PGV)$.

Tabla 61: Resumen porcentajes de clasificación de registros (RLM por parámetro)

Parámetro utilizado en el modelo	Caso 0		Caso 2		Caso 3		Caso 4	
	% pos1	% total						
$\log(PGA)$	36.8	82.7	36.9	79.8	39.7	80.2	36.1	82.2
$\log(PGV)$	39.1	83.3	39.3	84.5	45.5	86.8	38.9	84.2
$\log(Ia)$	37.5	82.6	34.5	76.1	40.5	75.1	36.1	83.9
$\log(SI)$	37.1	81.6	38.1	84.5	42.1	85.9	37.5	83.9
IJMA	38.1	81.6	38.1	85.8	38.0	87.6	37.5	84.2

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

Tabla 62: Resumen porcentajes de clasificación de registros (RNA por parámetro)

Parámetro utilizado en el modelo	Caso 0	Caso 2	Caso 3	Caso 4
$\log(PGA)$	29.5	19.0	16.7	24.3
$\log(PGV)$	26.2	23.8	25.5	22.9
$\log(Ia)$	26.8	19.0	29.3	26.4
$\log(SI)$	20.1	16.7	28.4	20.7
IJMA	28.2	14.3	13.7	27.1

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

6.3 Nuevos Resultados

Del análisis de los resultados mostrados en el Capítulo 6, Sección 6.2 se decide: generar un nuevo modelo utilizando ambos métodos; y realizar un análisis de los gráficos donde se muestra la diferencia entre valor IMM salido del modelo e IMM informado por la ONEMI (error), para lograr identificar si existe algo en común según el valor del error. En particular, se analiza si se puede asociar el valor de $\log(\text{PGV})$ y $\log(\text{PGA})$ al valor del error.

6.3.1 Nuevo Modelo

Se genera un nuevo modelo tanto para Redes Neuronales Artificiales como para Regresión Logística Multinomial. Este modelo consiste en considerar solo algunos parámetros instrumentales, la selección de estos parámetros se hace de acuerdo a lo observado en el loading plot (Figura 75). Se escoge una variable de cada uno de los “grupos” visibles, ya que en teoría, si se escoge más de un parámetro por “grupo”, se está aportando información redundante al modelo. Estos grupos corresponden a aquellas variables que están correlacionadas entre sí (Anexo C).

Para RLM se realiza el modelo considerando 17 clases y 2 clases.

Además, de acuerdo a lo concluido de los resultados anteriores, estos nuevos modelos solo se realizan para el Caso 4 según el tipo de suelo (Todos los suelos menos roca dura), considerando la media geométrica de los parámetros escogidos, variables no normalizadas y, en el caso de RLM sin utilizar PLS para el cálculo de la regresión lineal. Ya que con estos criterios se obtuvo un mejor desempeño de los modelos.

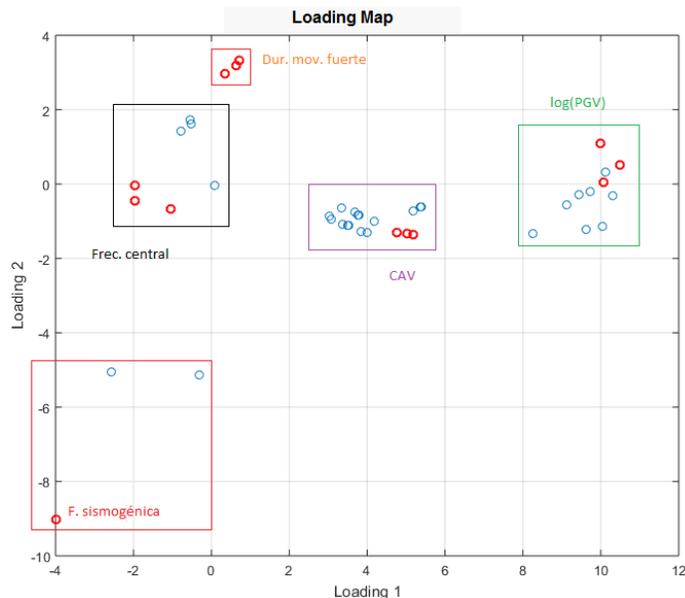


Figura 75: Loading plot donde se muestra qué variable se considera de cada uno de los "grupos" visibles.

Cabe destacar que la elección de qué variable escoger de cada grupo es totalmente arbitraria, a excepción del grupo encerrado en el grupo verde en que se escoge $\log(\text{PGV})$ ya que es el parámetro que, en los anteriores resultados, muestra un mejor desempeño.

En la Tabla 67 se resumen los resultados obtenidos de estos nuevos modelos.

Tabla 63: Resumen porcentajes de clasificación nuevos modelos

Método	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
RNA	26.4	79.3	44.3
RLM 17 clases	41.7	88.9	64.6
RLM 2 clases	85.4	% mal clasificado clase $\leq V$	% mal clasificado clase $\leq V$
		11.8	25.0

De la

Tabla 63 se observa que el modelo generado mediante RLM tiene mejor desempeño que el de RNA.

Para poder comparar estos resultados con los obtenidos anteriormente en la Tabla 64, Tabla 65 y Tabla 66, se muestran todos los resultados para RNA, RLM 16 clases y RLM 2 clases, respectivamente.

Tabla 64: Resumen porcentajes de clasificación de registros RNA

Caso Según Tipo de Suelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
RNA 16 parámetros			
0	25.5	80.5	49.7
2	31.0	81.0	54.8
3	26.7	75.0	43.4
4	30.7	84.3	52.1
Caso Extra	24.2	80.5	49.0
RNA por parámetro			
log(PGA)	29.5	80.5	59.7
log(PGV)	26.2	78.5	57.7
log(Ia)	28.3	80.0	48.4
log(SI)	28.4	80.0	48.4
IJMA	28.2	80.5	53.7
RNA 5 nuevos parámetros			
5 nuevos parámetros	26.4	79.3	44.3

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

**5 nuevos parámetros: $\log(\text{PGV})$, $\log(\text{CAV})$, Frec. Central, Fuente Sismogénica y Duración Movimiento Fuerte.

De la Tabla 64 se observa que este nuevo modelo no presenta un mejor desempeño que los otros realizados en este trabajo. Incluso se puede decir que para el porcentaje de registros en el rango [0,1] es el segundo más bajo.

Tabla 65: Resumen porcentajes de clasificación RLM 17 clases, por parámetro y 5 nuevos parámetros

Caso Según Tipo de Suelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
	RLM 17 clases		
0	44.4	84.6	63.2
2	38.1	81.0	58.4
3	33.9	73.6	48.8
4	43.9	86.4	64.2
Caso Extra	39.5	85.6	63.9
Parámetro	RLM por parámetro		
log(PGA)	39.7	82.6	62.8
log(PGV)	45.5	91.7	79.3
log(Ia)	40.5	83.5	61.2
log(SI)	42.1	86.8	71.9
IJMA	38.0	89.3	71.9
RLM 5 nuevos parámetros			
5 nuevos parámetros	41.7	88.9	64.6

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

**5 nuevos parámetros: log(PGV), log(CAV), Frec. Central, Fuente Sismogénica y Duración Movimiento Fuerte.

De la Tabla 65 se observa que el nuevo modelo generado está entre los 3 primeros porcentajes de clasificación más altos, siendo el primero el que utiliza solo log(PGV). Con respecto al porcentaje que se encuentra en el rango [0,1] tiene un buen desempeño, pero no destaca por sobre los otros modelos.

Por último, de la Tabla 66, en que se muestran los resultados para los modelos generados mediante RLM 2 clases, se puede ver que el nuevo modelo generado arroja un porcentaje de clasificación correcta similar al de los otros modelos.

Tabla 66: Resumen resultados RLM considerando 2 clases

Caso Según Tipo de Suelo	% Clasificación correcta	% mal clasificado clase $\leq V$	% mal clasificado clase $> V$
	RLM 16 parámetros		
Caso 0	86.0	15.7	19.1
Caso 2	81.0	17.8	34.8
Caso 3	87.6	12.4	33.4
Caso 4	86.1	13.7	27.3
RLM 5 nuevos parámetros			
5 nuevos parámetros	85.4	11.8	25.0

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura.

**5 nuevos parámetros: log(PGV), log(CAV), Frec. Central, Fuente Sismogénica y Duración Movimiento Fuerte.

Como conclusión de la realización de este nuevo modelo, se puede decir que en general los porcentajes de clasificación correcta no son mayores. Aunque en el caso de RLM 17

clases está entre los tres mayores porcentajes, sigue teniendo un mejor desempeño el que considera solo $\log(\text{PGV})$.

6.3.2 Análisis error entre IMM modelo e IMM ONEMI

En esta sección se analiza si existe alguna relación entre el error asociado al modelo, medido como IMM salida modelo – IMM ONEMI, y el valor de $\log(\text{PGA})$ y $\log(\text{PGV})$, por separado. Esto se realiza mostrando en un mismo gráfico lo siguiente: en el eje X cada observación del set de datos de prueba; en el eje Y el error; y, con una escala de colores (*colormap*), el valor de $\log(\text{PGA})$ y $\log(\text{PGV})$.

Se realiza un análisis para aquellos modelos que arrojaron mayor porcentaje de clasificación para cada uno de los métodos utilizados: RNA considerando 16 parámetros, RNA utilizando un parámetro a la vez, RLM 17 clases, RLM 2 clases y RLM considerando un parámetro. Es decir se muestran y analizan cinco figuras.

En la Figura 76, Figura 77, Figura 78, Figura 79 y Figura 80 se observa que no se puede concluir que exista relación entre estos parámetros instrumentales y el error que arroja el modelo. Esto ya que al analizar los colores, que representan el valor de la variable en cuestión, se encuentra una distribución aleatoria para cada valor de error. Dicho de otra forma, para un mismo valor del error existe una distribución alta de valores de $\log(\text{PGA})$ o $\log(\text{PGV})$ según sea el caso.

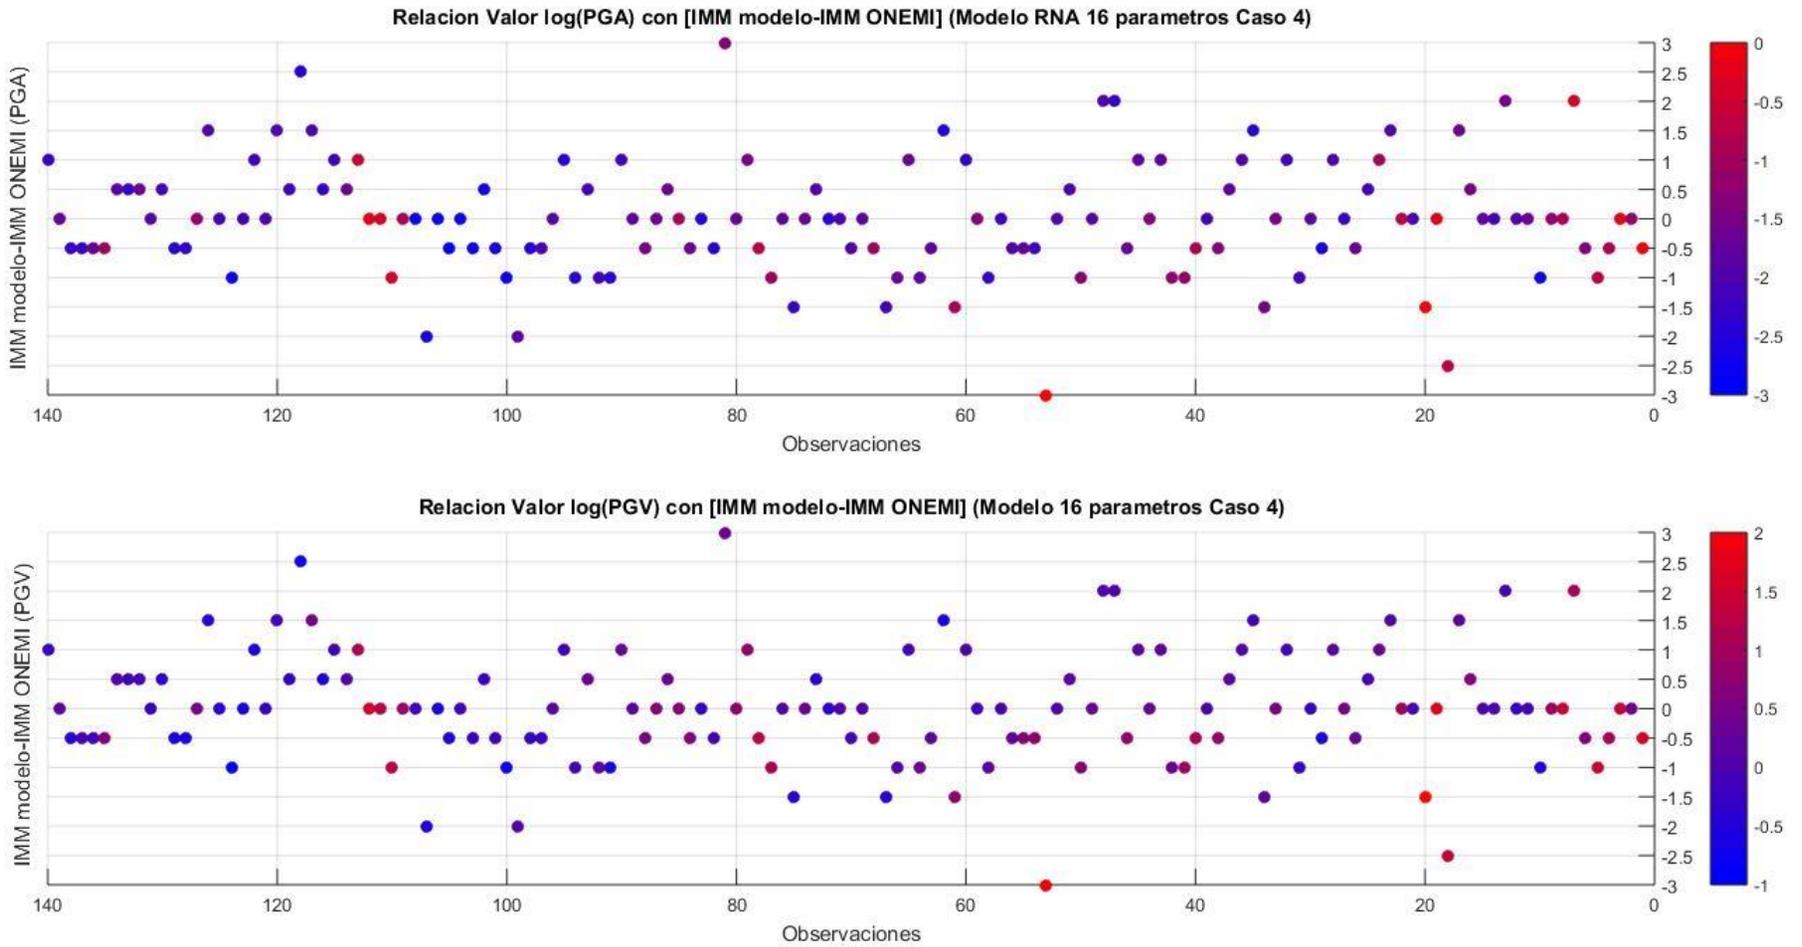


Figura 76: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). Modelo de RNA que considera 16 variables predictoras.

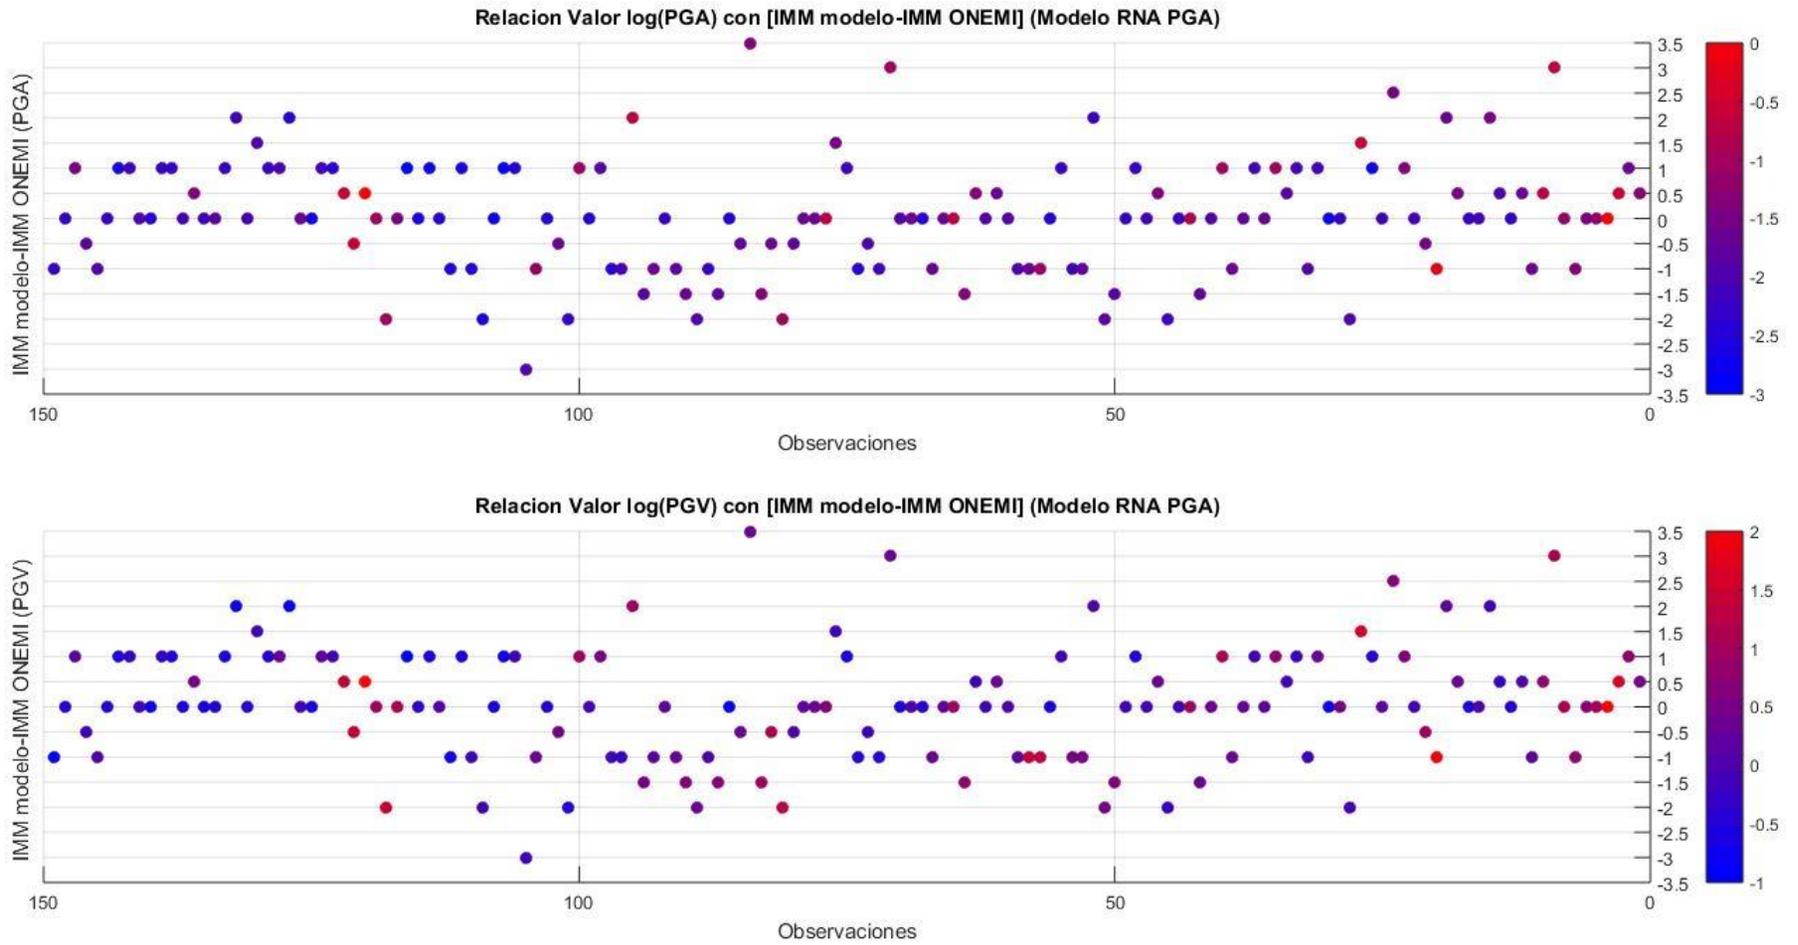


Figura 77: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). RNA considerando log(PGA) como variable predictora.

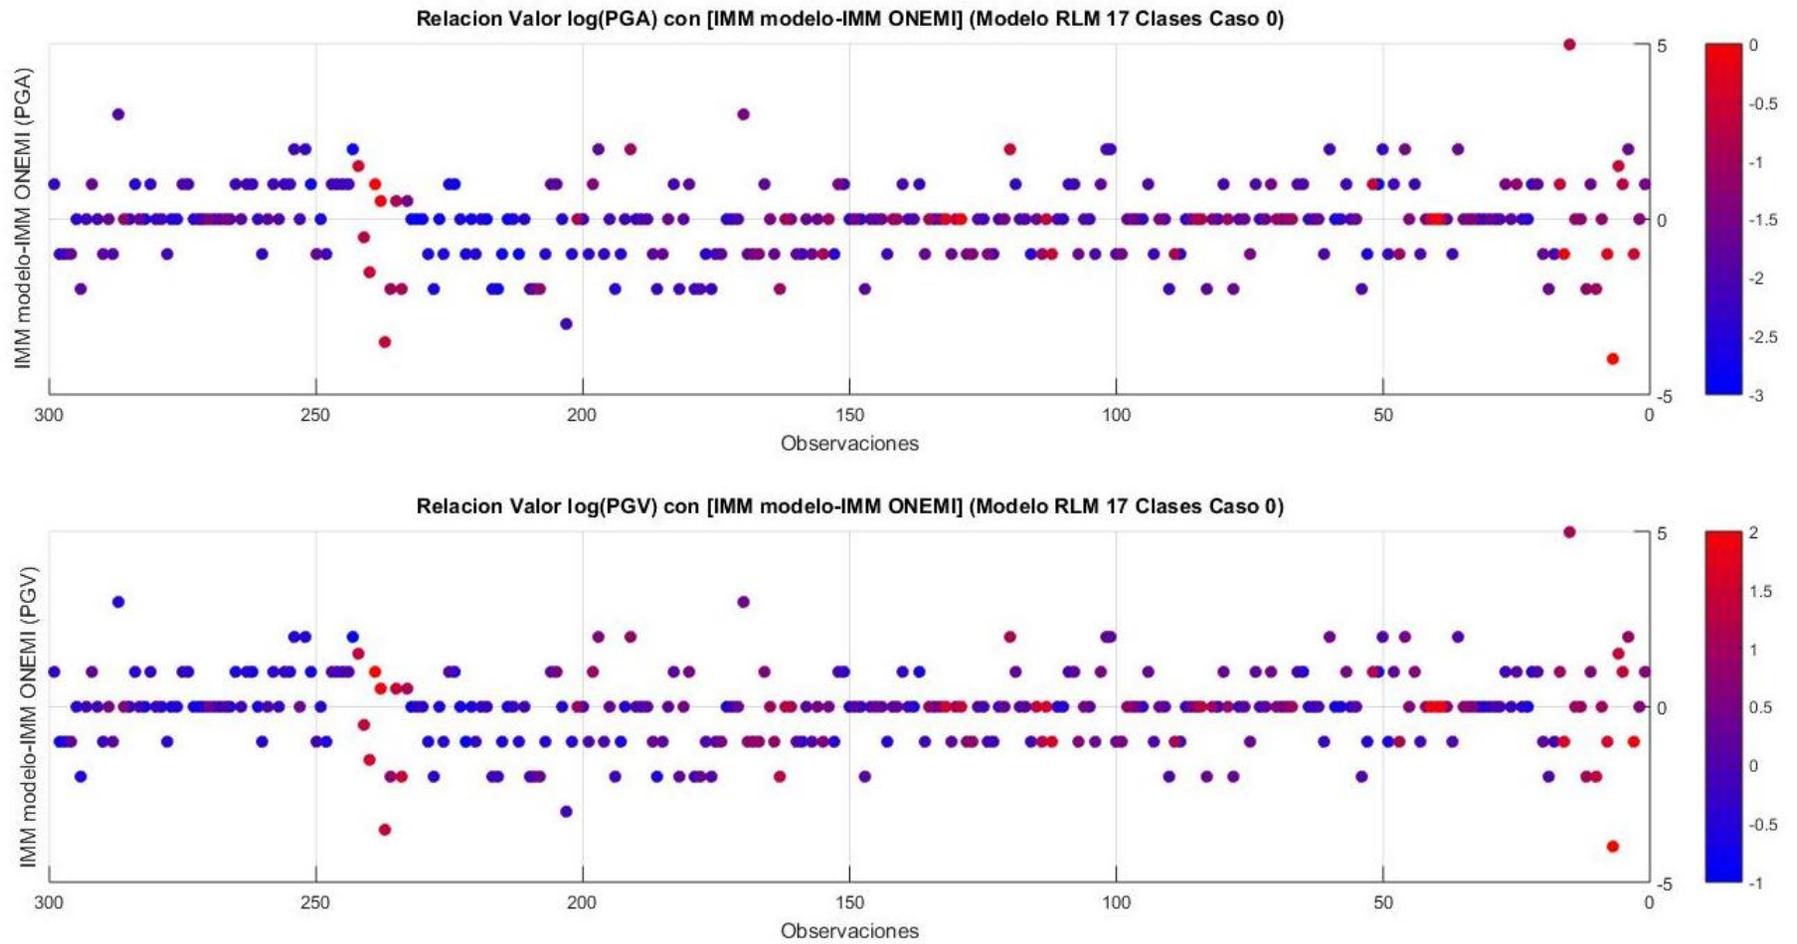


Figura 78: Gráfico que muestra relación entre $\log(\text{PGA})$ y error del modelo (arriba), y $\log(\text{PGV})$ y error del modelo (abajo). Modelo RLM 17 Clases.

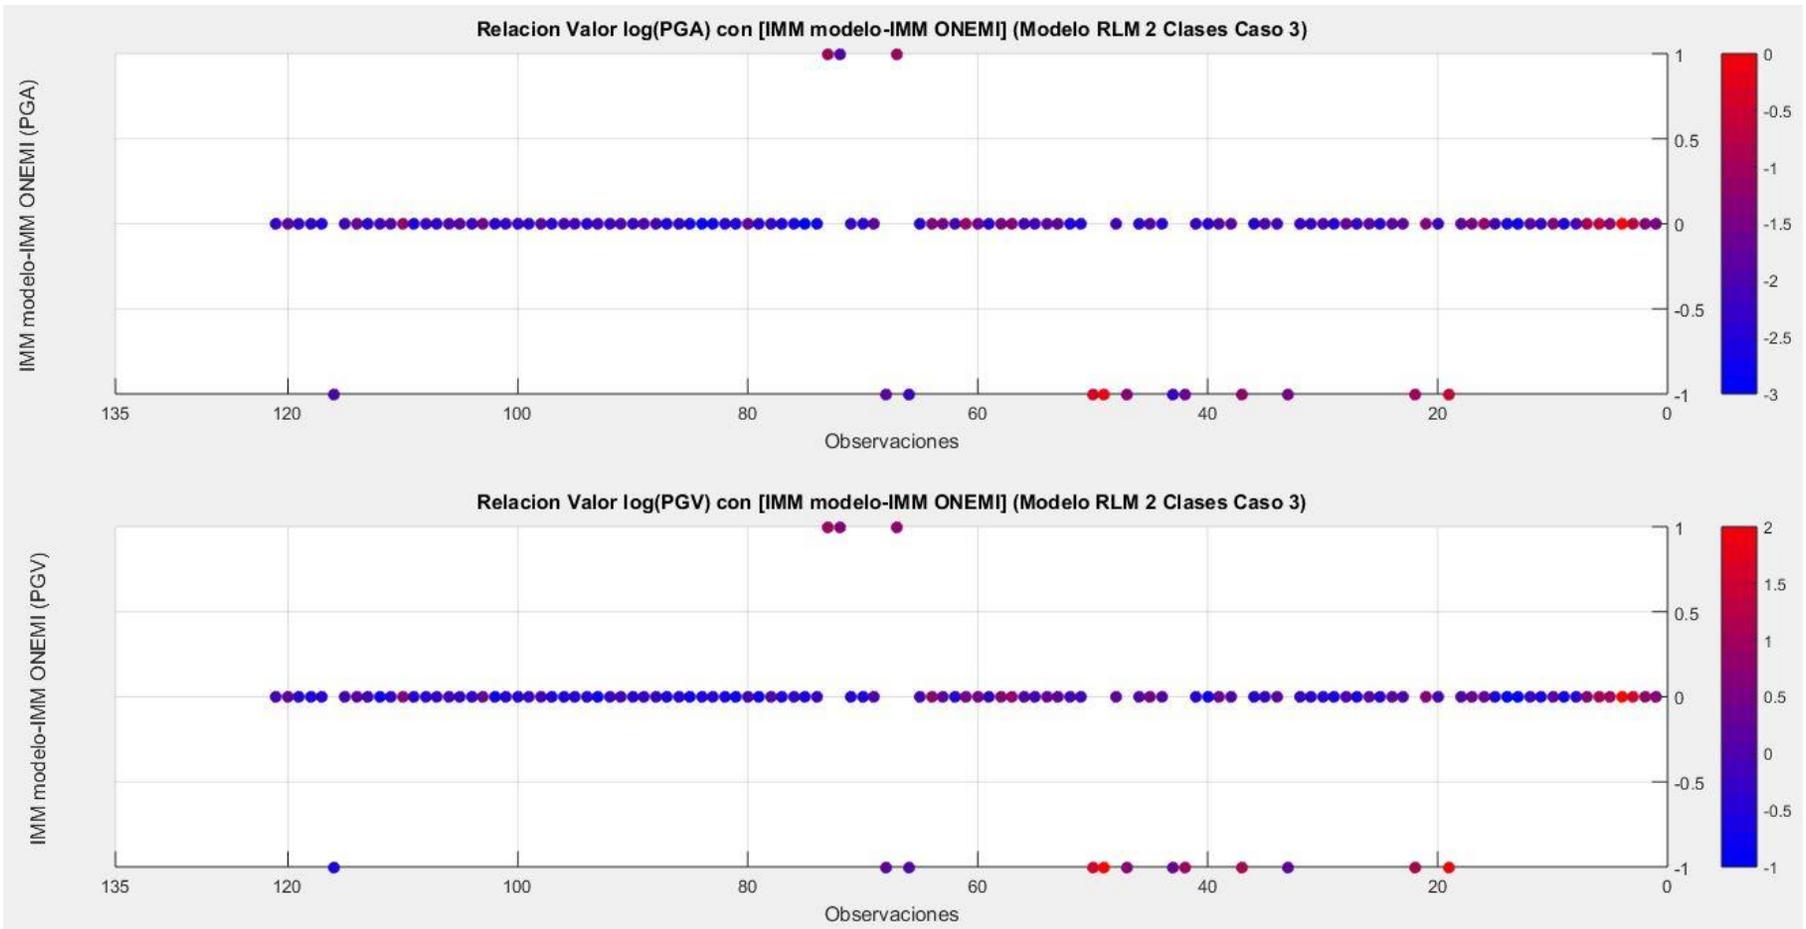


Figura 79: Gráfico que muestra relación entre log(PGA) y error del modelo (arriba), y log(PGV) y error del modelo (abajo). Modelo RLM 2 clases.

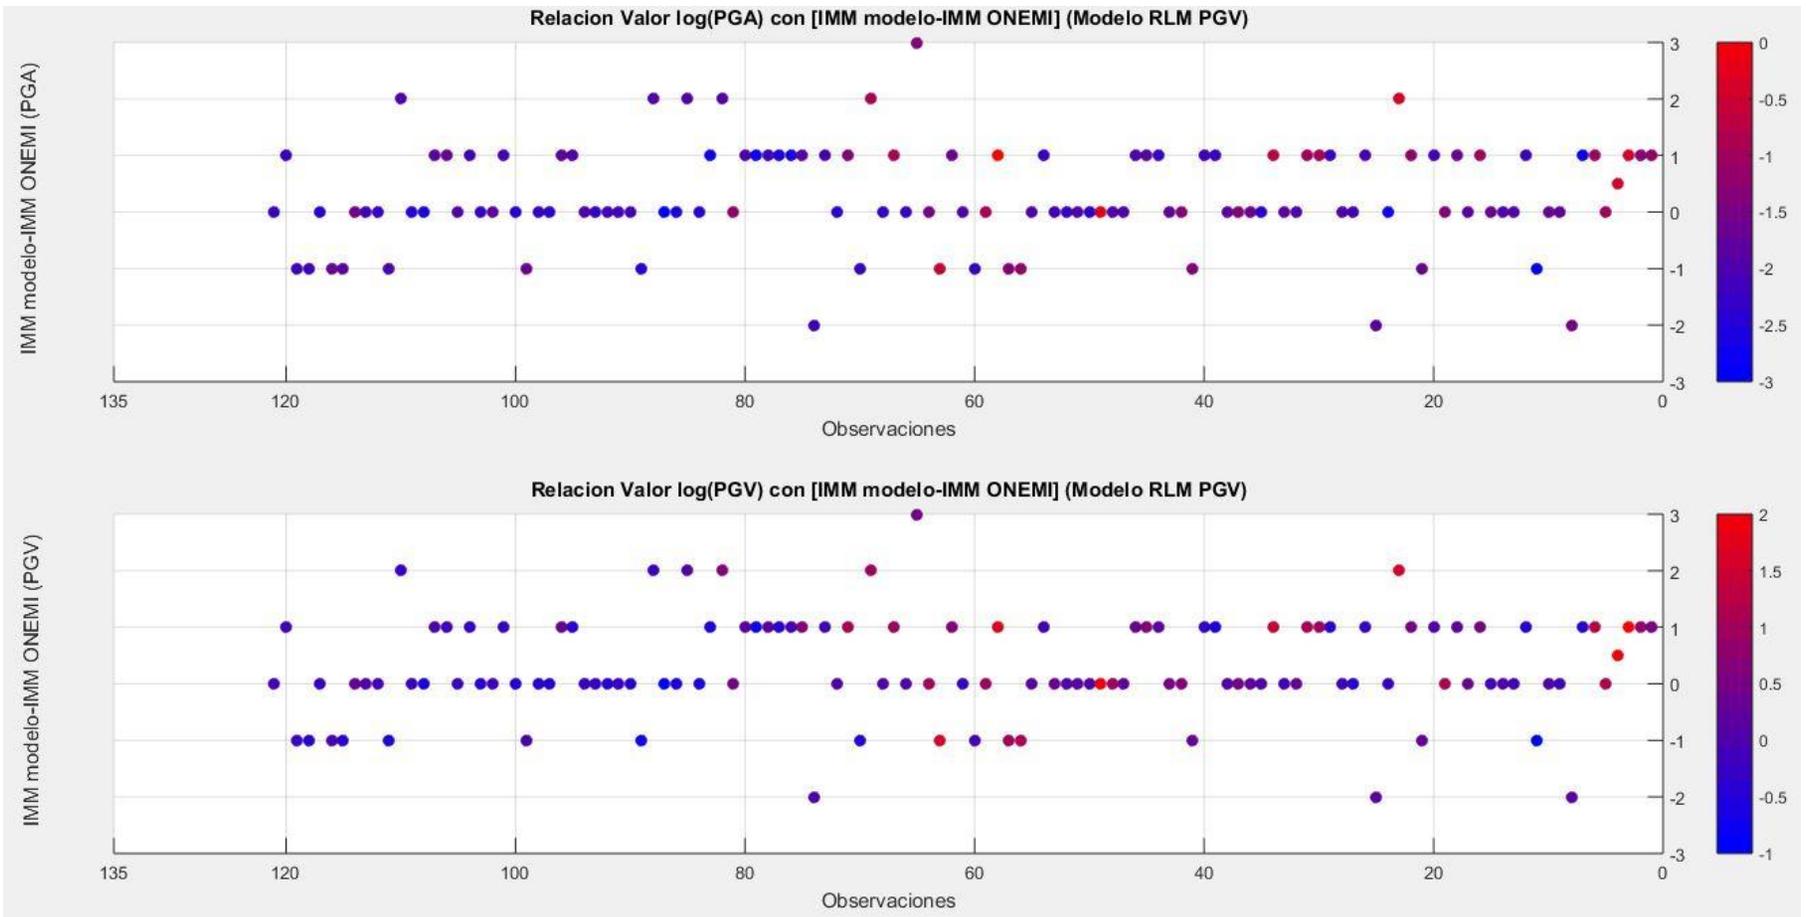


Figura 80: Gráfico que muestra relación entre $\log(\text{PGA})$ y error del modelo (arriba), y $\log(\text{PGV})$ y error del modelo (abajo). Modelo RLM con $\log(\text{PGV})$ como variable predictora.

CAPÍTULO 7: COMENTARIOS Y CONCLUSIONES

El presente trabajo tiene como objetivo principal objetivar la Intensidad de Mercalli Modificada (IMM) mediante el uso de parámetros instrumentales. Esto se realiza mediante el uso de dos métodos estadísticos distintos: Redes Neuronales Artificiales (RNA) y Regresión Logística Multinomial (RLM), ambos pertenecientes a la rama de Inteligencia Artificial conocida como Aprendizaje Automático (AA). Por otro lado, se utiliza el método estadístico Mínimos Cuadrados Parciales (PLS) para resolver uno de los objetivos específicos de este trabajo, que es identificar los parámetros más influyentes en el valor de la escala de la IMM asignado luego de la ocurrencia de un sismo; y como una alternativa para el cálculo de la regresión lineal que utiliza el método RLM.

Los parámetros considerados son: PGA, PGV, I_a , SI, IJMA, CAV, cruces por cero, frecuencia central, tipo de suelo, fuente sismogénica, duración de fase fuerte, distancia al hipocentro, profundidad hipocentro y espectro de desplazamiento, velocidad y aceleración para los periodos $T=0.2$ [s] y $T=1$ [s].

Como conclusiones principales, respondiendo a los objetivos de este trabajo, se tiene que el método de RLM tiene un mejor desempeño que RNA, obteniendo un mayor porcentaje de clasificación correcta y/o considerando un margen de error de 1 grado hacia el lado conservador (salidas del modelo mayor al valor informado por la ONEMI).

Con respecto a determinar qué variables son las más influyentes en el valor de IMM, con la ayuda de la realización de un *loading plot* mediante PLS, se obtiene que $\log(\text{PGV})$, $\log(\text{PGA})$, $\log(I_a)$, $\log(\text{SI})$ e IJMA son los parámetros que mayor información aportan al momento de explicar la varianza del set de datos utilizados. Además, se realizan modelos en que solo se utiliza cada una de estas variables a la vez, con el fin de identificar si existe entre las cinco una que sobresalga. Como resultado de estos modelos se determina que $\log(\text{PGV})$ tiene un desempeño levemente mejor que el resto.

A continuación se enumeran conclusiones más específicas del trabajo desarrollado y el posterior análisis de los resultados obtenidos:

1. Dentro de los 16 parámetros utilizados $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(I_a)$, $\log(\text{SI})$ e IJMA son los que presentan alguna relación con el valor de la escala de la Intensidad de Mercalli Modificada (Gráficos Anexo A), los demás parámetros no presentan relación o tendencia clara con la IMM. Esta relación se traduce en un mayor aporte de información a los modelos, cuestión que se refleja en *loading plot* realizado mediante Mínimos Cuadrados Parciales (PLS).
2. Debido a que no existe relación de la mayoría de los parámetros con IMM y además, aquellos que sí la presentan están muy correlacionados entre sí, para los modelos es difícil encontrar una regresión lineal que pueda relacionar las variables independientes (parámetros) con la variable dependiente (IMM). Y en este trabajo los 2 métodos utilizados se basan en el cálculo de una regresión lineal para realizar la posterior clasificación.

3. Como se menciona en el punto 2, los parámetros que tienen más relación con la escala de Mercalli Modificada, a su vez son los que más correlación presentan entre ellos. Por esto se decidió usar PLS como una opción para el cálculo de la regresión lineal en RLM, ya que este método tiene un buen comportamiento cuando las variables están muy correlacionadas entre sí. El uso de PLS en RLM arroja buenos resultados, ya que de las cuatro formas de utilización de RLM* en dos de ellas el modelo seleccionado por tener mayor porcentaje de clasificación lo utiliza.
 1. Considerando 17 clases
 2. Considerando 5 clases
 3. Considerando 2 clases
 4. Considerando solo un parámetro a la vez (log(PGA), log(PGV), log(Ia), log(SI) e IJMA).
4. Para algunos de los parámetros utilizados es mejor utilizar el valor del logaritmo en base 10 de ellos, al usar el logaritmo de las variables existe una relación más evidente entre estos y la Intensidad de Mercalli Modificada. En particular, las variables para las cuales es conveniente usar el logaritmo de su valor son: PGA, PGV, SI, Ia y CAV.
5. Existen algunos parámetros que se pensaba tendrían mayor relevancia al momento de encontrar una relación con la IMM, pero que en la práctica no se observa, como la distancia al hipocentro, fuente sismogénica y duración de la fase fuerte.
6. De los modelos generados mediante Redes Neuronales Artificiales considerando 16 parámetros se tiene que los porcentajes de clasificación correcta están entre un 25-30% y entre un 49-55% los registros clasificados dentro del rango [0,1] (Tabla 67).

Tabla 67: Resumen porcentajes de clasificación de registros (RNA 16 parámetros)

Caso Según Tipo de Suelo	% registros clasificados correctamente	% registros clasificados en el rango [-1,1]	% registros clasificados en el rango [0,1]
0	25.5	80.5	49.7
2	31.0	81.0	54.8
3	26.7	75.0	43.4
4	30.7	84.3	52.1
Caso Extra	24.2	80.5	49.0

*Caso 0: todos los suelos, Caso 2: Solo suelo B, Caso 3: Solo suelo C, Caso 4: Todos los suelos menos roca dura, Caso Extra: 5 parámetros y todos los suelos.

7. En todos los modelos generados por RNA considerando 16 parámetros (Caso 0, Caso 2, Caso 3, Caso 4 y Caso Extra) se observa un mal comportamiento en las predicciones para aquellos valores informados por la ONEMI que indican que la intensidad está entre dos valores de la escala de IMM (Ej: II-III, IV-V, etc.). Lo más probable es que esto ocurra debido a que en el conjunto de pruebas son muy pocos los registros que tienen un valor informado asociado de este estilo, sin embargo el modelo predice para varios registros este tipo de valores como salida.

A qué corresponde cada caso se menciona a continuación:

Caso 0: Todos los tipos de suelo

Caso 2: Solo suelo tipo B

Caso 3: Solo suelo tipo C

Caso 4: Todos los tipos de suelo excluyendo roca dura (suelo tipo A)

Caso Extra: Todos los tipos de suelo pero considerando los 5 parámetros que aportan más información de acuerdo al *loading plot*: $\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{SI})$, $\log(I_a)$ e IJMA.

8. Las regresiones generadas por el método de RNA, para todos los modelos, tienen un comportamiento conservador para valores de la escala de IMM cercanos a III, y no conservador para valores cercanos a V.
9. De los modelos generados mediante Regresión Logística Multinomial considerando 17 clases, en el cual cada clase corresponde a un solo valor de la Intensidad de Mercalli Modificada (Clase 1=I, Clase 2=I-II, Clase 3=II,..., Clase 17=IX), se tiene que si bien los porcentajes de clasificación están entre un 16-35% (considerando solo la salida asociada a la mayor posibilidad), presentan mejores porcentajes si se considera el rango de clasificación [0,1]:
 1. Caso 0: 53.5%
 2. Caso 2: 40.5%
 3. Caso 3: 41.3%
 4. Caso 4: 57.5%
 5. Caso Extra: 63.9%

Los casos corresponden a los mismos descritos en la conclusión nº7

El Caso Extra tiene un desempeño mayor claro respecto a los otros casos.

10. Todos los modelos obtenidos mediante Regresión Logística Multinomial considerando 17 clases realizan pocas predicciones en valores que no existen en el conjunto de datos de prueba, en particular aquellos valores que se encuentran entre dos intensidades de IMM.
11. Para los modelos generados mediante RLM considerando 5 clases, en el cual cada clase se define como sigue:
 - Clase 1: I, I-II, II, II-III, III y III-IV
 - Clase 2: IV, IV-V, V, V-VI
 - Clase 3: VI
 - Clase 4: VI-VII
 - Clase 5: \geq VII

En general no se obtienen buenos resultados:

1. Diferencia de hasta 4 clases, es decir que si la predicción clasifica un registro como Clase 1 el registro podría corresponder a la Clase 5 según el valor informado por la ONEMI.
2. En cada uno de los modelos seleccionados por su mayor porcentaje de clasificación para cada uno de los 5 casos distintos (*) al menos las 2 primeras clases (Clase 1 y Clase 2) se comportan de forma no conservadora
3. En algunos modelos existe gran dispersión en la predicción de la Clase 5, los registros predichos como Clase 5, en el peor de los casos, pertenecen a registros asociados a cuatro clases distintas.
4. Los registros que deberían haber sido predichos como Clase 5, los modelos arrojan salidas en todas las clases.

(*) Los casos corresponden a los mismos descritos en la conclusión n°7

12. Para ambos métodos utilizados (RNA y RLM) la mayor parte de los modelos que presentan un mayor porcentaje de clasificación son aquellos en que o bien se calcula la media geométrica de los parámetros o son eliminadas las variables de acuerdo al *loading plot*.
13. Para ambos métodos (RNA y RLM) se obtienen mejores resultados si se consideran los parámetros por separado, en particular $\log(\text{PGV})$. Además, queda claro que no existe un mejor desempeño al ocupar los parámetros que se ocupan por separado ($\log(\text{PGA})$, $\log(\text{PGV})$, $\log(\text{Ia})$, $\log(\text{SI})$ e IJMA) todos juntos en un solo modelo (Caso Extra).
14. Para los modelos realizados mediante RLM en que se consideran dos clases: $\text{IMM} \leq V$ e $\text{IMM} > V$ (distinción hecha para separar aquellos registros asociados a $\text{IMM} \leq V$ en que el sismo no provoca daño y aquellos en que sí) en general se obtienen buenos resultados. Para todos los casos (según el tipo de suelo) el porcentaje es mayor al 80%.
15. El hecho de hacer una distinción del tipo de suelo asociado al registro, para ninguno de los dos métodos (RNA y RLM) implica un aumento en el porcentaje de clasificación. En particular en el caso de RL se observa que los porcentajes mayores se obtienen al utilizar los datos considerando todos los suelos o todos los suelos menos roca dura (Caso 0 y Caso 4 respectivamente, descritos en la conclusión n°7).
16. Analizando los modelos en que se considera solo un parámetro a la vez, se tiene que para Regresión Logística, independiente del tipo de suelo considerado (Casos), el modelo que utiliza el parámetro $\log(\text{PGV})$ es aquel que presenta un mayor porcentaje de clasificación. En el caso de los modelos realizados mediante Redes Neuronales Artificiales cada caso tiene un parámetro que mejor se ajusta según el tipo de suelo.

Con respecto al tipo de datos con los que se trabaja:

17. Dentro de los registros de aceleraciones con los que se trabaja hay algunos que pertenecen a distintos lugares dentro de una misma ciudad, por lo que las aceleraciones, y en consecuencia, los parámetros calculados a partir de este registro varían dependiendo del lugar. Mientras que los valores informados por la ONEMI son un valor por ciudad. En este trabajo se asocian estos valores entregados por ciudad a los registros, independiente del lugar ubicado dentro de la misma. Esto implica un error al querer generar una relación entre diversos parámetros e IMM.
18. Se busca encontrar una relación entre los parámetros instrumentales y el valor de la IMM. Esto se hace entrenando los métodos con los valores ya informados por la ONEMI, por lo que si bien se busca objetivar la escala de IMM, los resultados obtenidos están basados en datos subjetivos.

Nuevos Resultados

19. Con respecto al nuevo modelo generado, en el cual se considera una variable de cada "grupo" observable en el *loading plot*, las cuales son: $\log(\text{PGV})$, $\log(\text{CAV})$, fuente sismogénica, duración fase fuerte y frecuencia central; se tiene que para el caso de RNA y RLM 2 clases el modelo no destaca por sobre los realizados anteriormente. En cuanto a RLM 17 clases, el modelo muestra un mejor desempeño que la mayoría de los otros modelos (tercer porcentaje mayor correcto de clasificación). El hecho que no muestre mejores resultados, o levemente mejores, puede desprenderse del mismo *loading plot*, ya que se ocupan variables, que se concluye anteriormente, tienen un bajo aporte a la varianza del conjunto de datos con el que se trabaja.
20. No es posible, con las herramientas que se tienen en este trabajo, encontrar una relación entre el error de cada uno de los modelos (diferencia entre el valor de IMM salido del modelo e IMM informado por la ONEMI) y los parámetros instrumentales $\log(\text{PGA})$ y $\log(\text{PGV})$.

CAPÍTULO 8: RECOMENDACIONES Y FUTURO TRABAJO

Recomendaciones

1. Aumentar el conjunto de datos, si bien en este trabajo se utilizan registros de eventos ocurridos entre los años 2007 al 2015 y los registros de eventos importantes de los años 1985, 1995, 1997, 1999, 2001 y 2005, existen más registros dentro de este periodo de tiempo que no han sido procesados. Por lo que es factible aumentar el set de datos.

Como se puede ver en la Figura 81, el número de datos que se tiene para intensidades altas $\geq VII$ es significativamente menor que para las intensidades $< VII$, por lo que para generar un modelo que sea “confiable” en todos los valores de la escala de IMM, se debería poder aumentar los registros asociados a intensidades mayores.

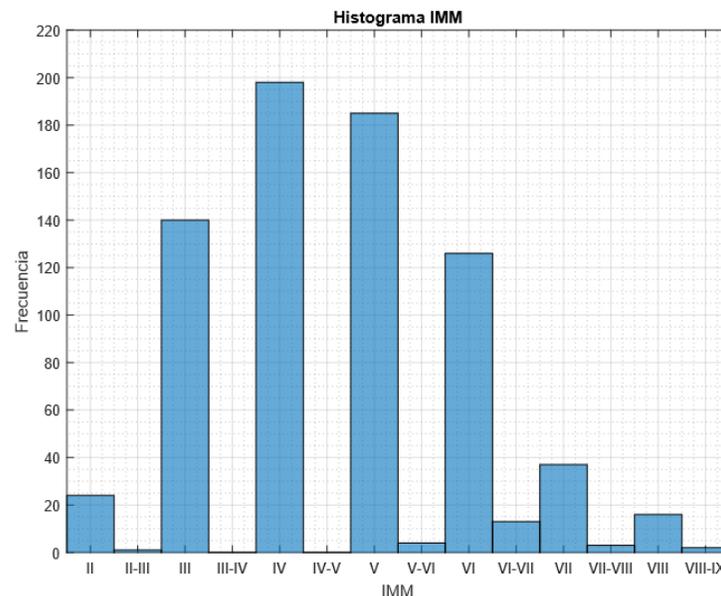


Figura 81: Histograma Intensidad de Mercalli Modificada

2. Utilizar el método de Mínimos Cuadrados Parciales como un método de predicción. Además de utilizarlo para encontrar las variables que más información aportan a la generación de un modelo, también se puede ocupar para generar un modelo predictivo.

A través de este método se encuentra una relación (combinación lineal) entre las variables independientes y la variable dependiente, en este trabajo esta última corresponde a IMM. De esta forma, se generaría una relación de la forma:

$$IMM = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (8.1)$$

donde:

IMM : Intensidad de Mercalli Modificada (variable dependiente)

X_i : Variables independientes o predictoras, con $i = 1, 2, \dots, n$

b_0 : Intercepto de la regresión

b_i : Coeficientes de regresión para las variables independientes, con $i = 1, 2, \dots, n$

Al igual que en otros métodos, se debe dividir el conjunto de datos total en un set de entrenamiento y un set de prueba. Mediante el algoritmo NIPALS, que es el que usa PLS, y utilizando el set de datos de entrenamiento se obtienen los coeficientes b_0 y b_i de la combinación lineal mostrada en la Ecuación 8.1. Luego, para determinar el desempeño, se generan salidas del modelo (valor IMM, lado izquierdo Ecuación 8.1) utilizando las variables independientes (X_i) del set de prueba y estos valores se comparan con el valor de IMM informado por la ONEMI (set de prueba variable dependiente).

Futuro trabajo

3. Poder determinar si existe alguna relación entre los valores de PGA y PGV dependiendo del valor de la Intensidad de Mercalli Modificada. Es decir, encontrar si por ejemplo, para las escalas menores existe mayor relación con uno de estos dos parámetros, y para las escalas mayores con el otro, como se ha establecido en otros trabajos [39].

Para esto se recomienda utilizar test de hipótesis estadísticos, como por ejemplo el Test de Scheffé. Este test, a grandes rasgos, consiste en un método de comparación múltiple: se compara la media de distintos grupos con el fin de encontrar atributos en común de ellos.

Otra opción que se recomienda es utilizar lógica difusa, la cual se puede utilizar como un método individual o aplicarla como complemento a las Redes Neuronales Artificiales. La lógica difusa (fuzzy logic) es una extensión de la lógica tradicional (booleana) donde la pertenencia a un grupo no es determinada por una condición estricta, es decir que existen “matices”. Por esto se podría ocupar para resolver este punto, ya que quizá la relación entre PGA-valores bajos de IMM y PGV-valores altos de IMM no es estricta, puede ser que para determinar IMM se pondere cada parámetro (PGA y PGV) por un coeficiente, y que estos coeficientes varíen de acuerdo a que tan baja o alta es la escala de IMM.

Bibliografía

- [1]. Alvarado, D., Valdebenito, G.: Microzonificación Sísmica en Zonas de Geología compleja. Evaluación del Peligro Sísmico Local en Valdivia, Chile, XI Congreso Chileno de Sismología e Ingeniería Sísmica ACHISINA, 2015.
- [2]. Alvarez, D. A., Hurtado, J. E., Bedoya-Ruiz, D. A.: Prediction of modified Mercalli intensity from PGA, PGV, moment magnitude, and epicentral distance using several nonlinear statistical algorithms, *J Seismol*, 2012.
- [3]. Arias, A. 1970. A measure of earthquake intensity. HANSEN, R. (Editor). *Seismic Design for Nuclear Power Plant*. Cambridge, MA, The M.I.T. Press. pp. 438 – 483.
- [4]. Atkinson, G. M. and Kaka, S. I.: Relationship between felt intensity and instrumental ground motion in the central United States and California, *B. Seismol. Soc. Am.*, 2007.
- [5]. Cabañas, L., Benito, B., Herraiz, M.: An approach to the measurement of the Potential Structural Damage of Earthquake Ground Motions, *Earthquake Engineering and Structural Dynamics*, 1997.
- [6]. Carrasco Durán, Felipe Aroldo. Efecto de la duración de los terremotos en la respuesta inelástica de estructuras. Título de Ingeniero Civil. Concepción, Chile. Universidad Católica de la Santísima Concepción, Facultad de Ingeniería Civil, 2009.
- [7]. Davenport, P.: Neural network analysis of seismic intensity from instrumental records. In: *Proceedings of the 13th world conference on earthquake engineering*, paper no. 692. Vancouver, Canada, 2004.
- [8]. Directorio creado por Warren S. Sarle, Mar 7, 2002. [En línea]. <ftp://ftp.sas.com/pub/neural/FAQ3.html#A_over>.
- [9]. EcuRed. [En línea]. <https://www.ecured.cu/Aprendizaje_Autom%C3%A1tico>.
- [10]. EPRI. 1991. Standardization of the cumulative absolute velocity. EPRI T R-100082 (Tier 2). Electrical Power Research Inst., Palo Alto, USA.
- [11]. Escuela de Ingeniería de Antioquía. [En línea]. <http://fluidos.eia.edu.co/hidraulica/articulos/flujoentuberias/neuronal/neuronal_archivos/page0003.htm>.
- [12]. Gobierno Regional de Los Lagos, Plan Regional de Ordenamiento Territorial. [En línea]. <http://www.goreloslagos.gob.cl/resources/descargas/programas/pr_turismo/2015/PROT_MExp_18122013_VPreliminar.pdf>.
- [13]. Housner, G. W. 1952. Intensity of ground motions during strong earthquakes. Earthquake Research Laboratory. California Institute Of Technology. California, USA.

- [14]. Jorquera Valenzuela, Roberto Andrés. Catálogo de terremotos subductivos chilenos para la generación de curvas de fragilidad. Título de Ingeniero Civil. Santiago, Chile. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, 2014.
- [15]. Kaka, S., and G. Atkinson.: Relationships between instrumental intensity and ground motion parameters in eastern North America, *Bull. Seism. Soc. Am*, 2004.
- [16]. Karim, K. R. and R. Yamazaki, R.: Correlation of JMA instrumental seismic intensity with strong motion parameters, *Earthq. Eng. Struct, D.*, 2001.
- [17]. Karim, K. R. and R. Yamazaki, R.: Correlation of JMA instrumental seismic intensity with strong motion parameters, *Earthq. Eng. Struct, D.*, 2001. Leyton F., Ruiz S., Sepúlveda S. A.: Reevaluación del peligro sísmico probabilístico en Chile central. *Andean Geology*, 2010.
- [18]. Nature Clinical Practice Gastroenterology & Hepatology, link: http://www.nature.com/nrgastro/journal/v5/n6/fig_tab/ncpgasthep1125_F6.html
- [19]. Nigam, N. y Jennings, P.: Calculation of Response Spectra from strong-motion earthquake records. *Bulletin of the Seismological Society of America*, 1969.
- [20]. Ordenes Marinkovic, Jennyfer. Actualización de la base de datos para la generación de curvas de predicción de movimiento para sismos chilenos. Título de Ingeniera Civil. Santiago, Chile. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, 2017.
- [21]. Poblete Rojas, Jorge Diego. Determinación experimental de la intensidad de Mercalli Modificada para Chile. Título de Ingeniero Civil. Santiago, Chile. Universidad de Chile, Facultad de Ciencias Físicas y Matemáticas, 2008.
- [22]. Ruiz, S., Sepúlveda, S. A., Leyton, F.: Reevaluación del peligro sísmico probabilístico en Chile central. *Andean Geology*, 2010.
- [23]. Saragoni R.: Influencia de la aceleración máxima, duración y contenido de frecuencias en los daños producidos por los terremotos. *Boletín de Información de Carreteras y Geotecnia*, N°144, 1981.
- [24]. Saragoni R., Astroza M., Ruiz S.: Relación entre la alta frecuencia característica o cruces por cero de los terremotos chilenos y el daño observado. Conferencia: IX Congreso Chileno de Sismología e Ingeniería Antisísmica, 2005.
- [25]. Shabestari, K. T. and Yamazaki, F.: A Proposal of Instrumental Seismic Intensity Scale Compatible with MMI Evaluated from Three-Component Acceleration Records, *Earthquake Spectra*, 2001.
- [26]. Sokolov, Y. V.: Seismic Intensity and Fourier Acceleration Spectra: Revised Relationship, *Earthq. Spectra*, 2002.

- [27]. Trifunac, M. D. y Brady, A. G. 1975. On the correlation of seismic intensity scales with the peaks of recorded strong ground motion. BSSA, Vol. 65, pp. 139-162
- [28]. Tselentis G-A., Danciu, L.: Empirical relationships between Modified Mercalli Intensity and Engineering Ground-Motion Parameters in Greece, Bull. Seism. Soc. Am, 2008.
- [29]. Tselentis G-A., Vladutu L., Danciu, L.: A model for MMI-Attenuation Based on Artificial Neural Networks and Genetic Algorithms, 2010.
- [30]. Tselentis G-A., Vladutu L.: An attempt to model the relationship between MMI attenuation and engineering ground-motion parameters using artificial neural networks and genetic algorithms. Nat Hazards Earth Syst. Sci., 2010.
- [31]. Tong H., Yamazaki F.: A relationship between seismic ground motion severity and house damage ratio. Proceedings of the 4th US Conference on Lifeline Earthquake Engineering, ASCE, 1995.
- [32]. Tung A. T. Y., Wong F. S., Dong W.: A Neural Networks based MMI attenuation model, National Earthquake Conference, 1993.
- [33]. Universidad de Alcalá, El Blog de CIFF, tu Escuela de Negocios. ¿Qué es el Aprendizaje Automático o Machine Learning. [En línea]. <<http://www.ciff.net/blog/que-es-el-aprendizaje-automatiko-o-machine-learning.html>>.
- [34]. Universidad del País Vasco–Euskal Herriko Unibertsitatea, Departamento de Ciencias de la Computación e Inteligencia Artificial. [En línea]. <<http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>>
- [35]. Universidad de Valparaíso, Departamento de Computación. [En línea]. <https://www.inf.utfsm.cl/~rsalas/Pagina_Investigacion/docs/Apuntes/Redes%20Neuronales%20Artificiales.pdf>.
- [36]. Universidad de Buenos Aires, Facultad de Ciencias Exactas y Naturales. [En línea]. <<https://www.dc.uba.ar/materias/aa/2011/cuat2>>.
- [37]. Universidad de Buenos Aires, Facultad de Ingeniería. [En línea]. <<http://laboratorios.fi.uba.ar/lfi/bertona-tesisingenieriainformatica.pdf>>.
- [38]. Universidad de Sevilla, Departamento de Ciencias de la Computación e Inteligencia Artificial. [En línea]. <<http://www.cs.us.es/~fsancho/?e=75>>.
- [39]. Wald, D. J., Quitoriano, V., Heaton, T. H., and Kanamori, H.: Relationships between peak ground acceleration, peak ground velocity, and modified mercalli intensity in California, Earthq. Spectra, 1999.

- [40]. Wood H. O, Neumann F.: Modified Mercalli Intensity Scale of 1931. Bulletin of the Seismological Society of America, December 1931.
- [41]. Worden, C. B.; Gerstenberger, M. C.; Rhoades, D. A.; Wald, D. J.: Probabilistic Relationships between Ground-Motion Parameters and Modified Mercalli Intensity in California, Bull. Seism. Soc. Am, 2012.

**ANEXO A: HISTOGRAMA VARIABLE DEPENDIENTE Y DE
VARIABLES INDEPENDIENTES**

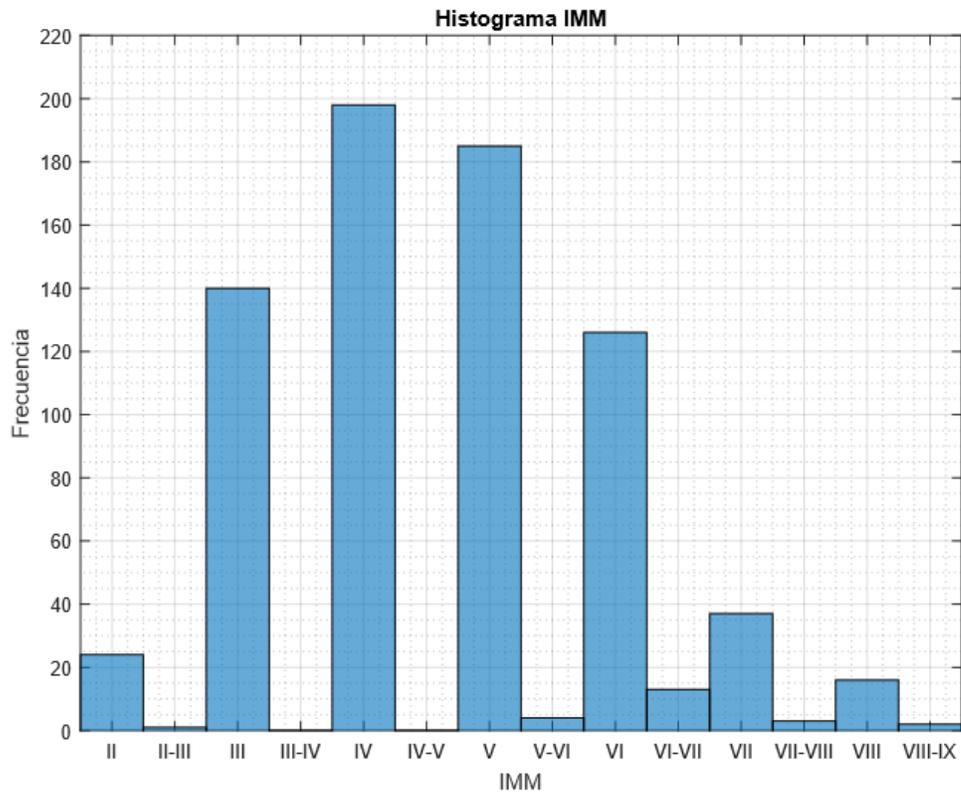


Figura A. 1: Histograma Intensidad de Mercalli Modificada

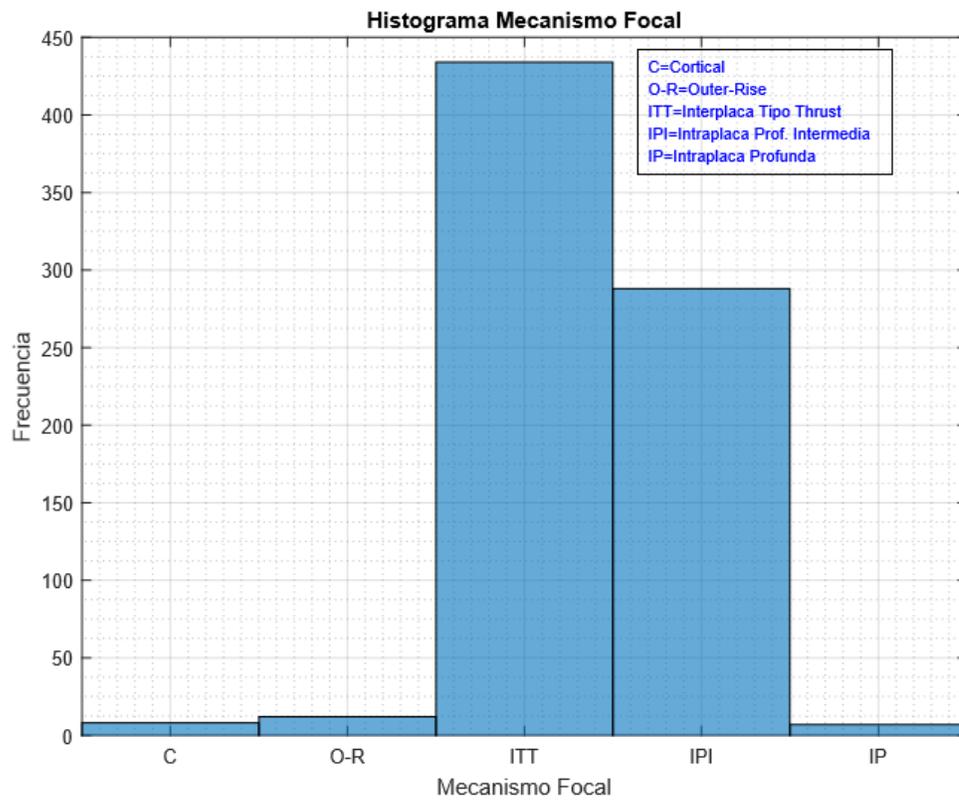


Figura A. 2: Histograma Mecanismo Focal

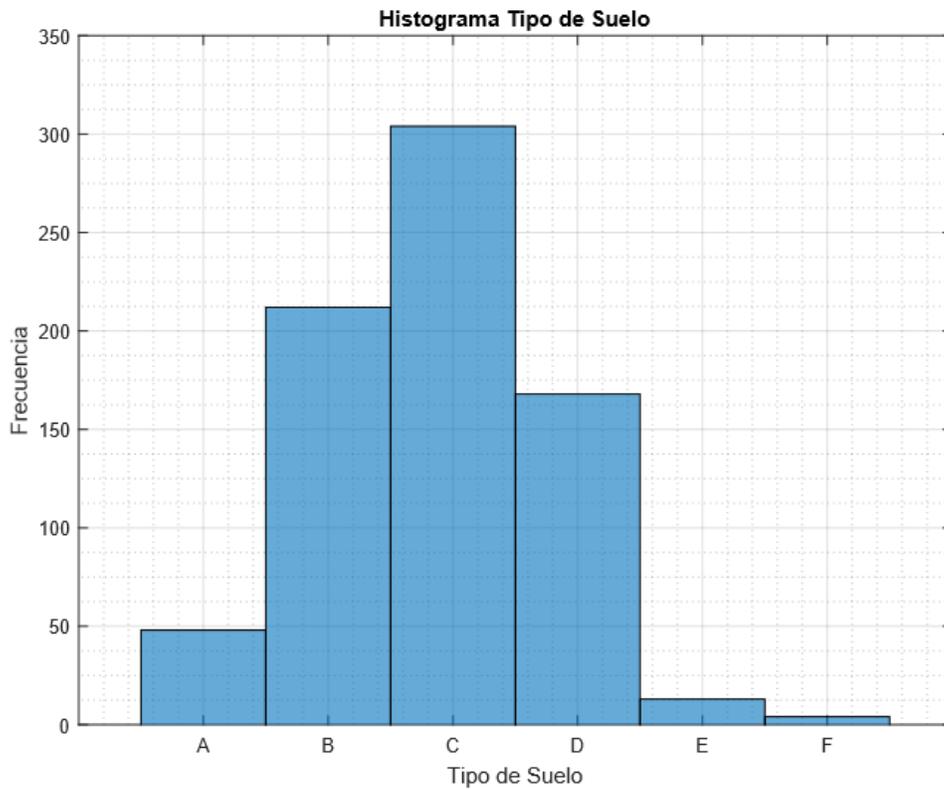


Figura A. 3: Histograma Tipo de Suelo

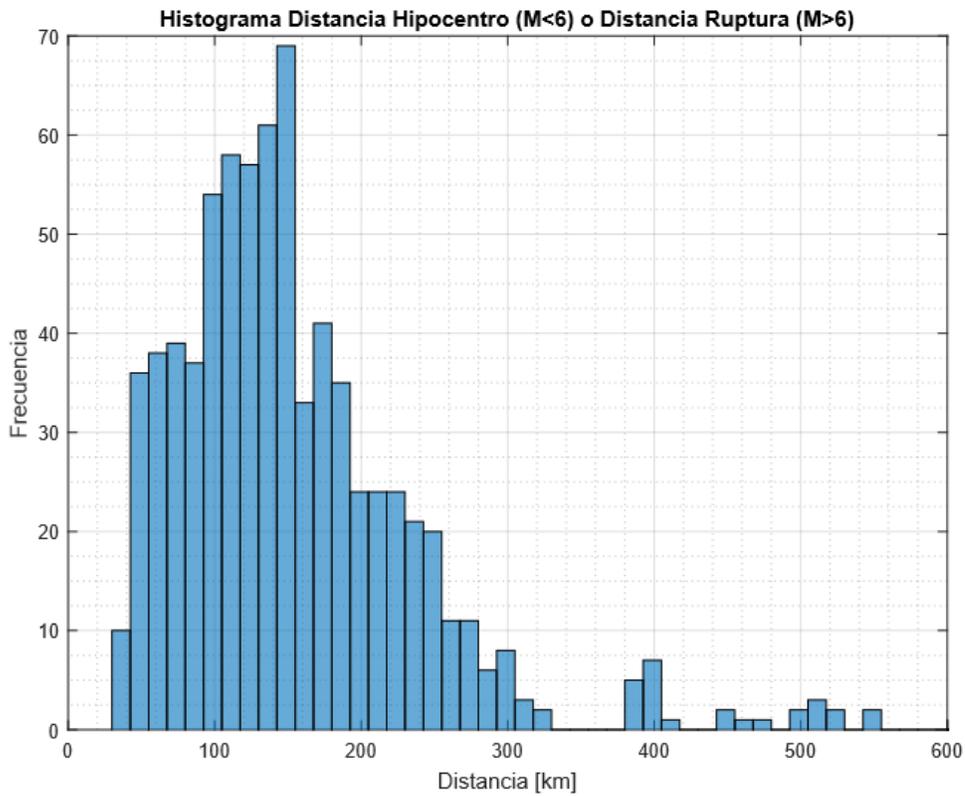


Figura A. 4: Histograma distancia al hipocentro para sismos menores a 6M y distancia de ruptura para sismos mayores a 6M

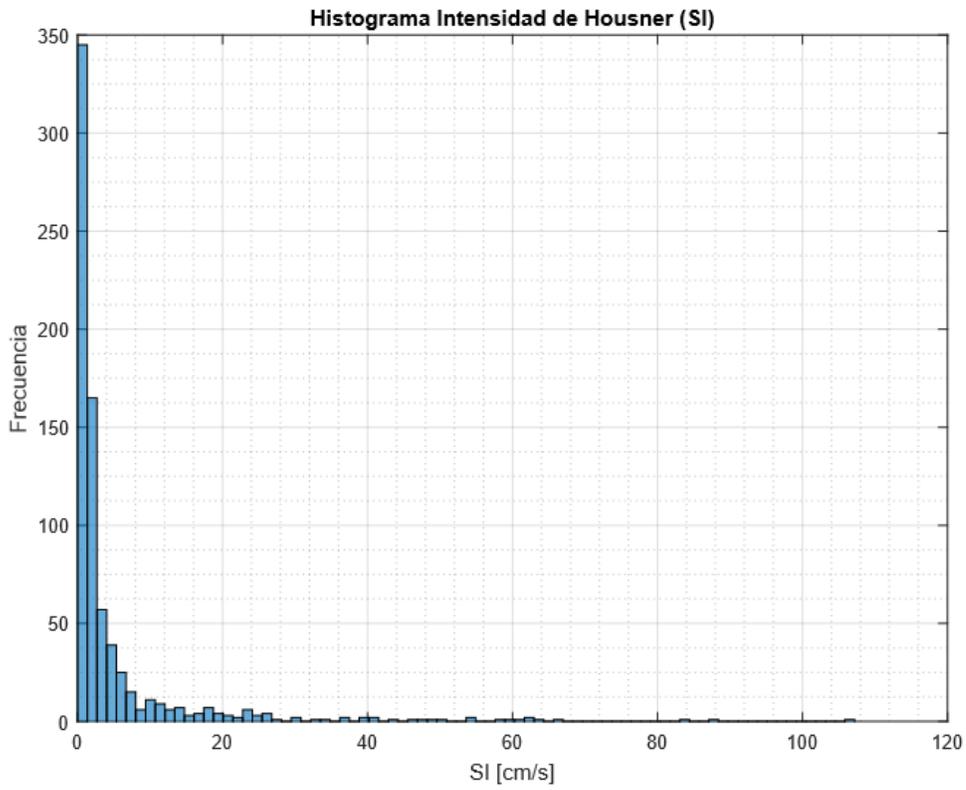


Figura A. 5: Histograma Intensidad de Housner

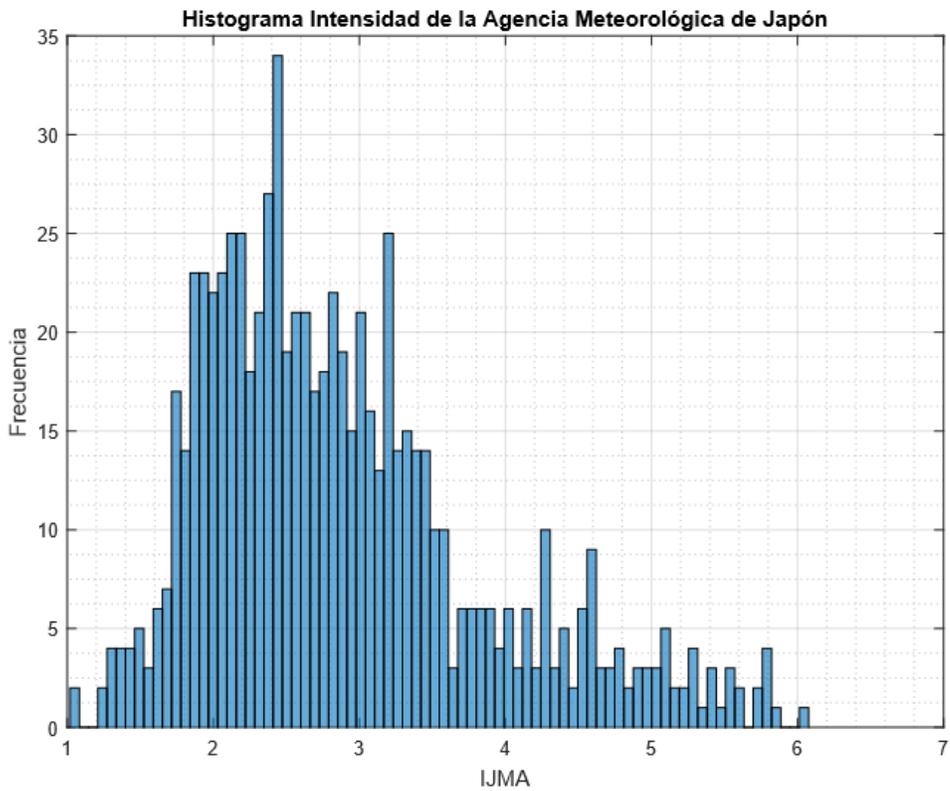


Figura A. 6: Histograma IJMA

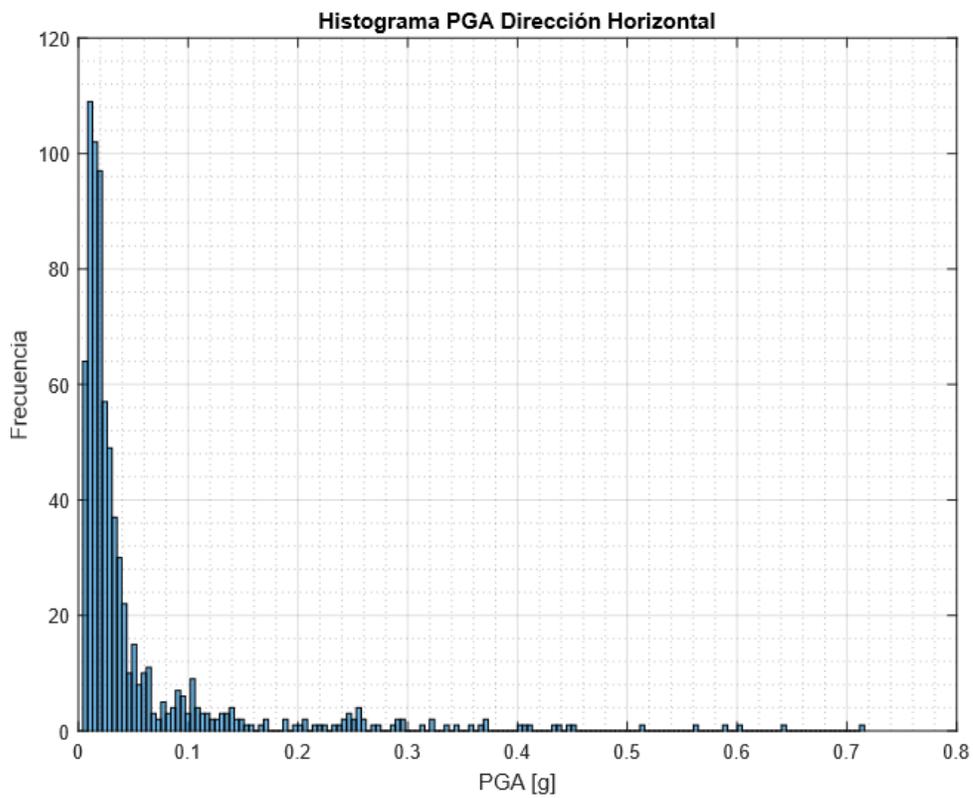


Figura A. 7: Histograma PGA Dirección Horizontal

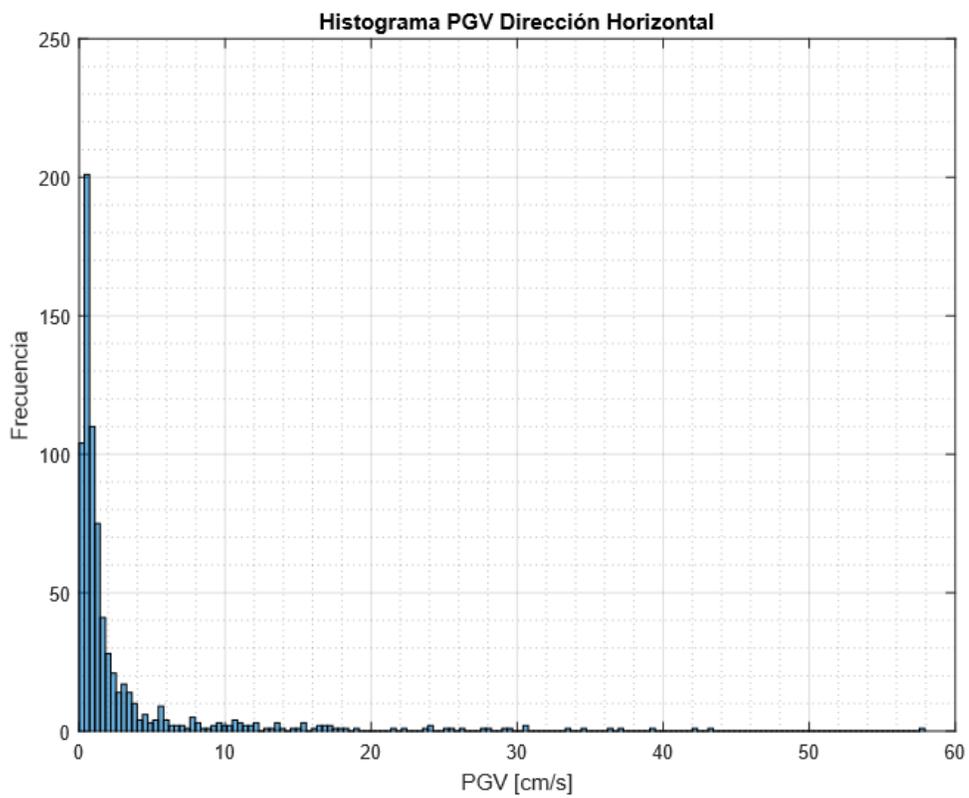


Figura A. 8: Histograma PGV Dirección Horizontal

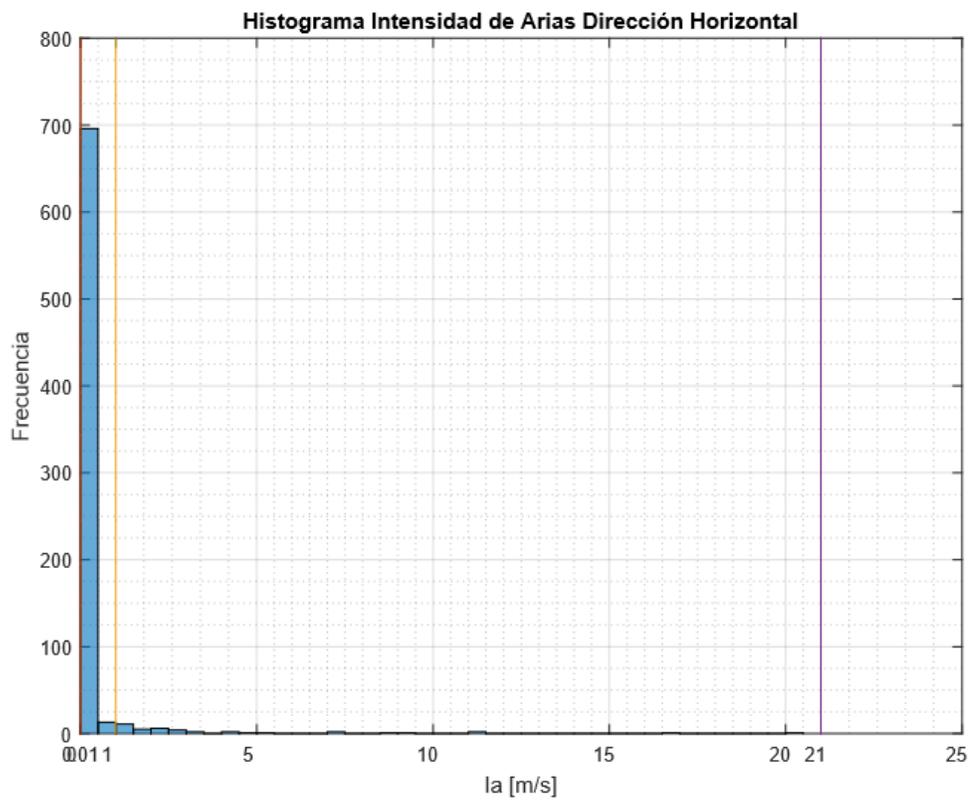


Figura A. 9: Histograma Intensidad de Arias Dirección Horizontal

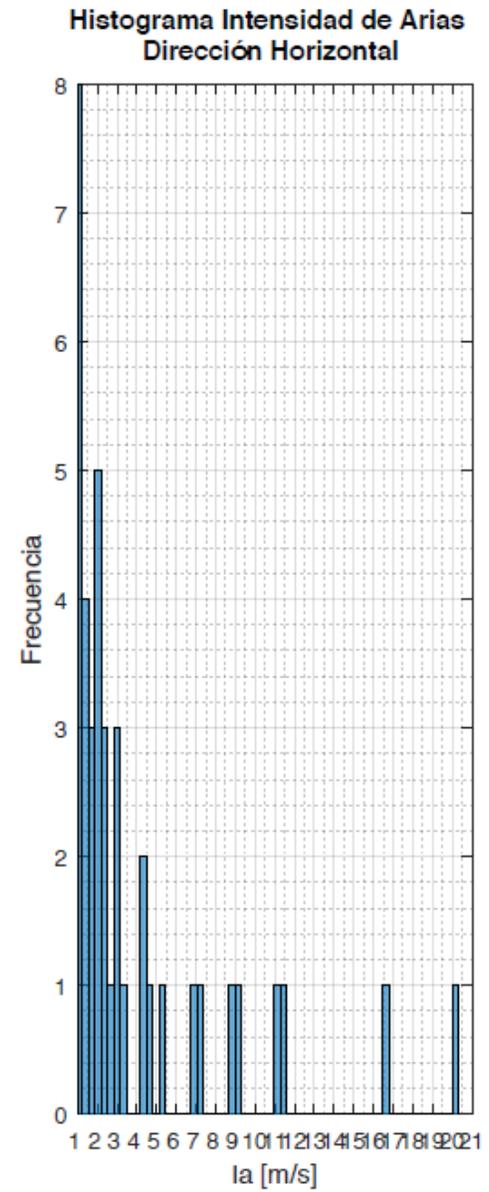
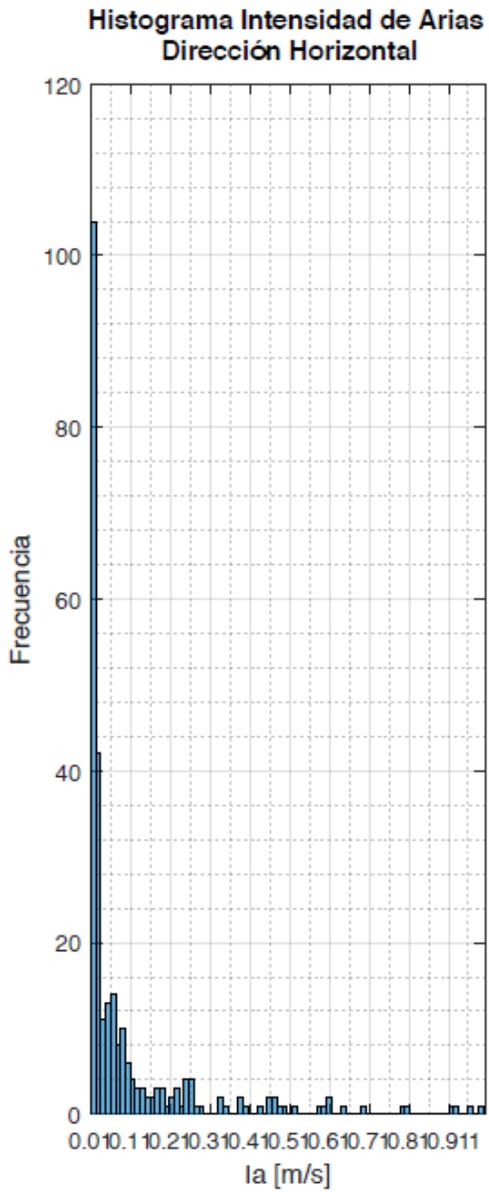
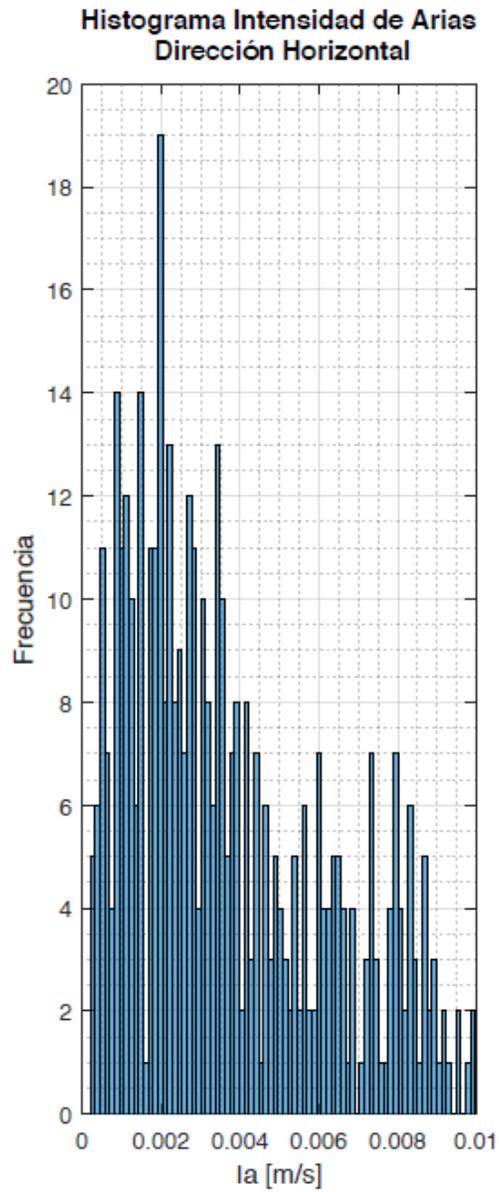


Figura A. 10: Histograma por partes Intensidad de Arias Dirección Horizontal

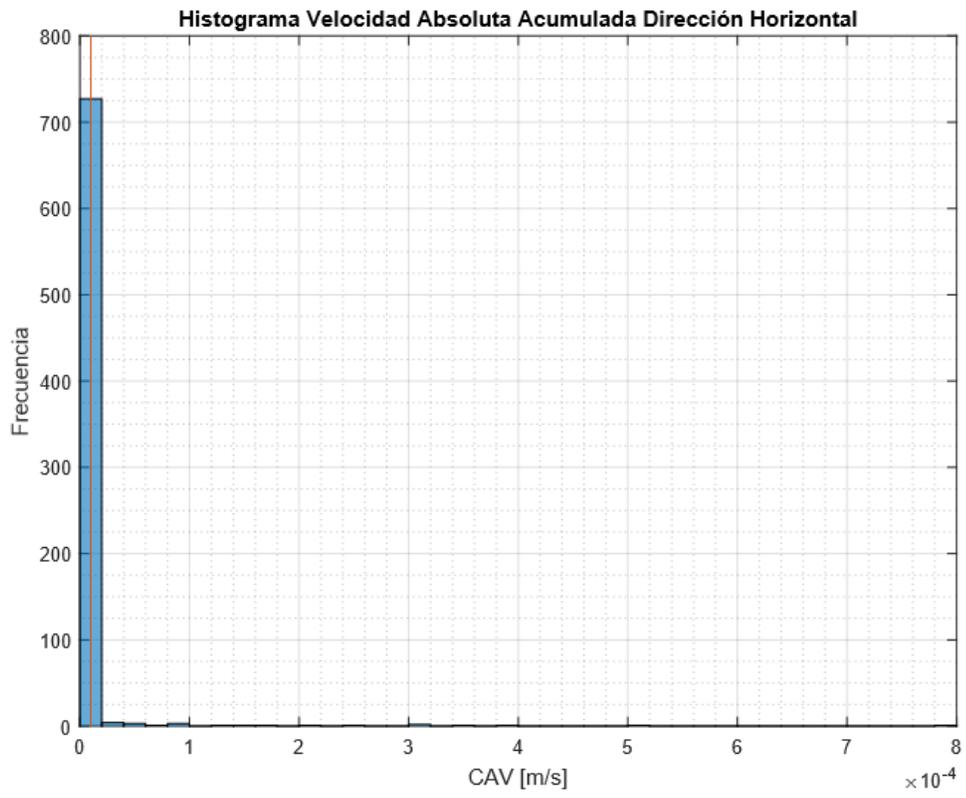


Figura A. 11: Histograma Velocidad Absoluta Acumulada Dirección Horizontal

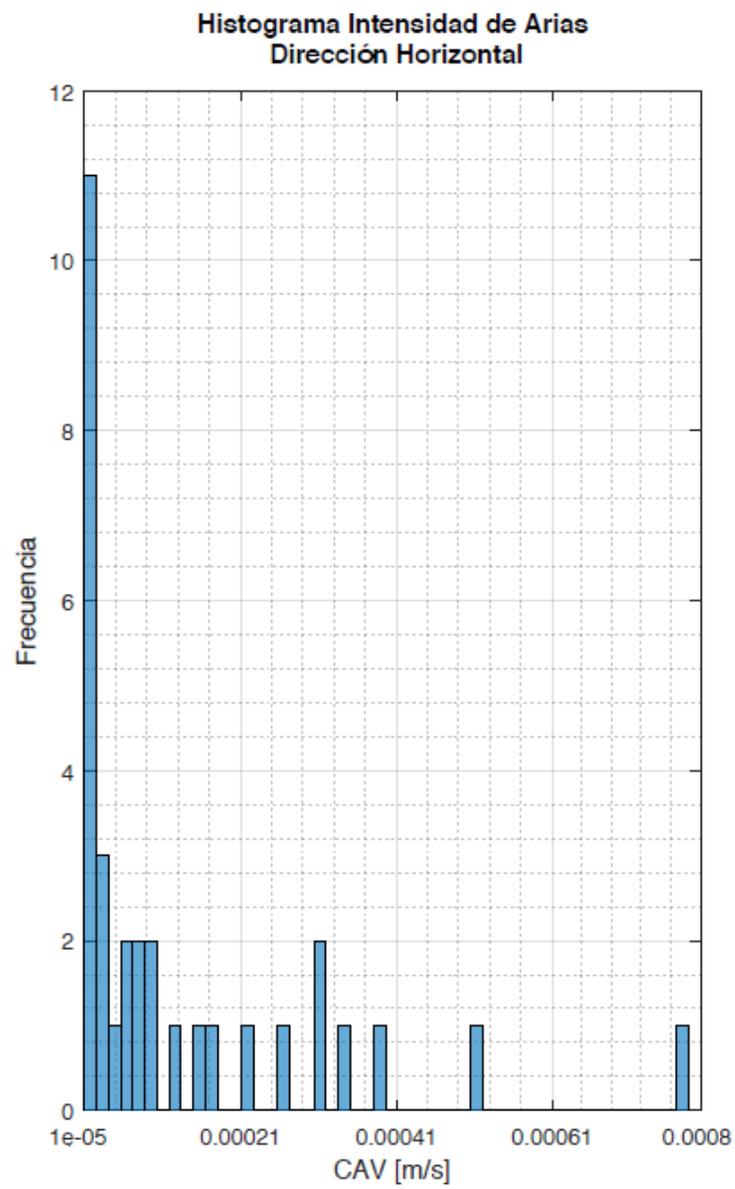
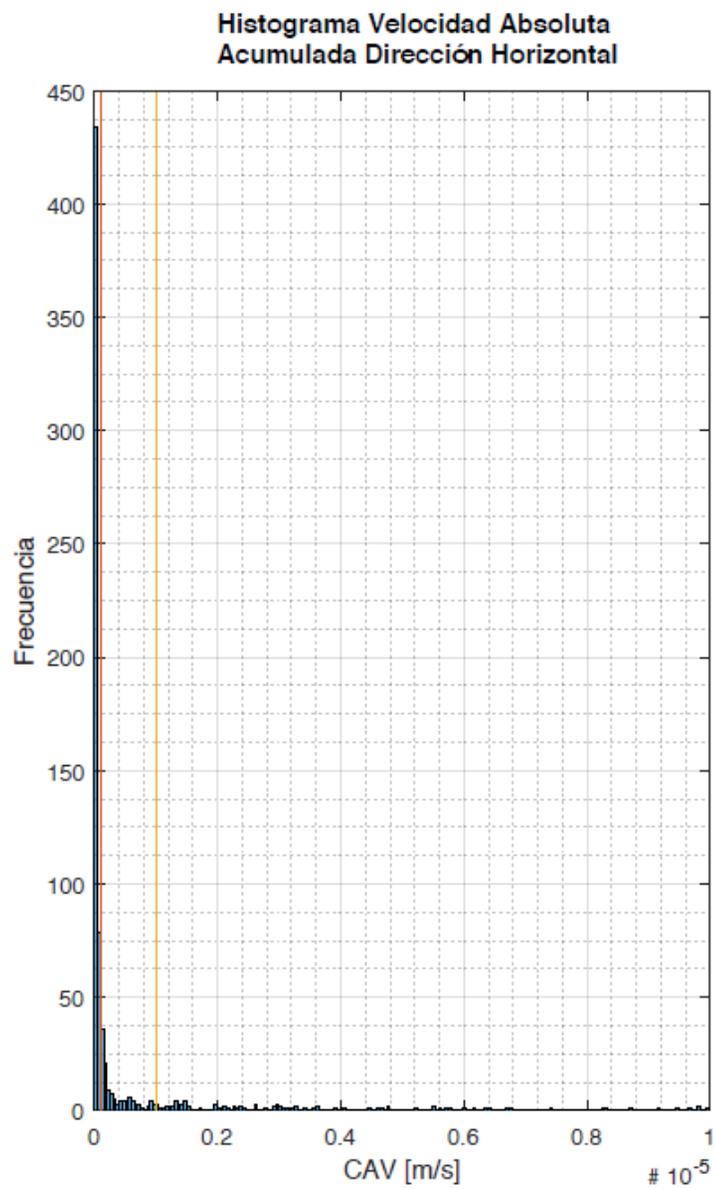
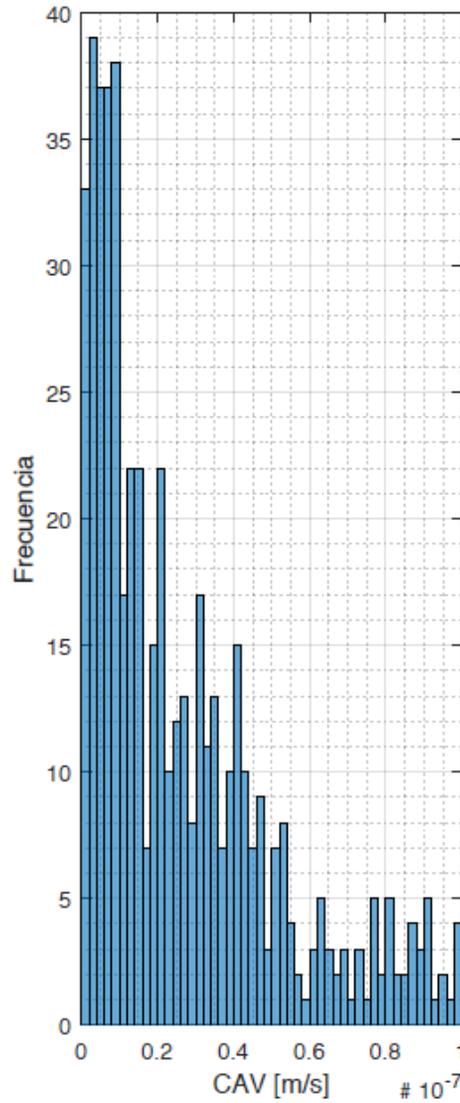
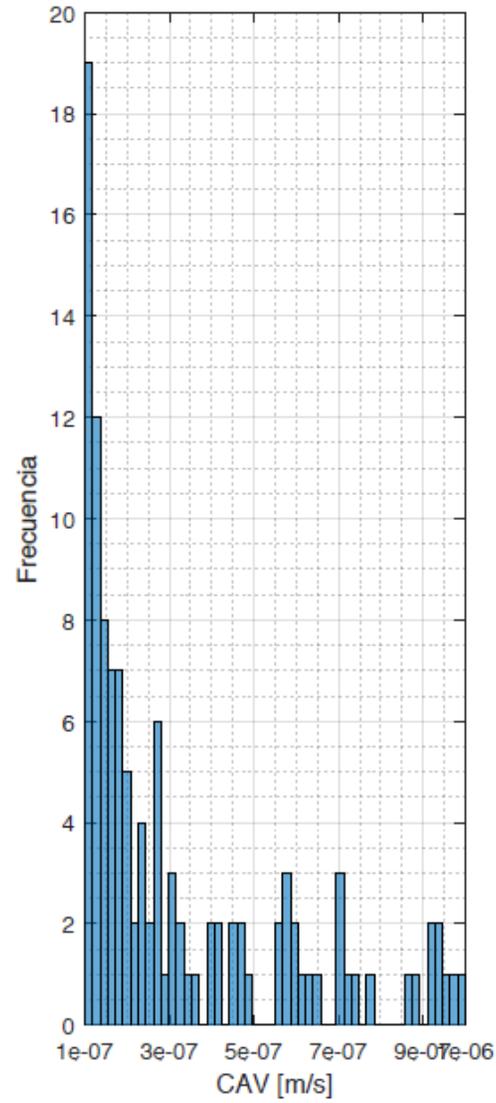


Figura A. 12: Histograma CAV Dirección Horizontal por partes

Histograma Velocidad Absoluta
Acumulada Dirección Horizontal



Histograma Velocidad Absoluta
Acumulada Dirección Horizontal



Histograma Velocidad Absoluta
Acumulada Dirección Horizontal

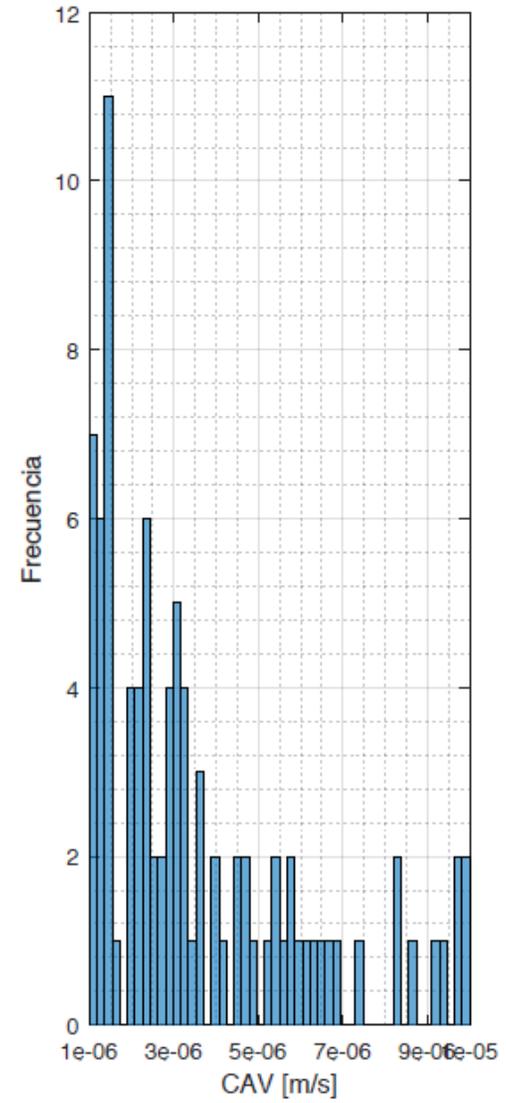


Figura A. 13: Histograma CAV Dirección Horizontal sub-partes

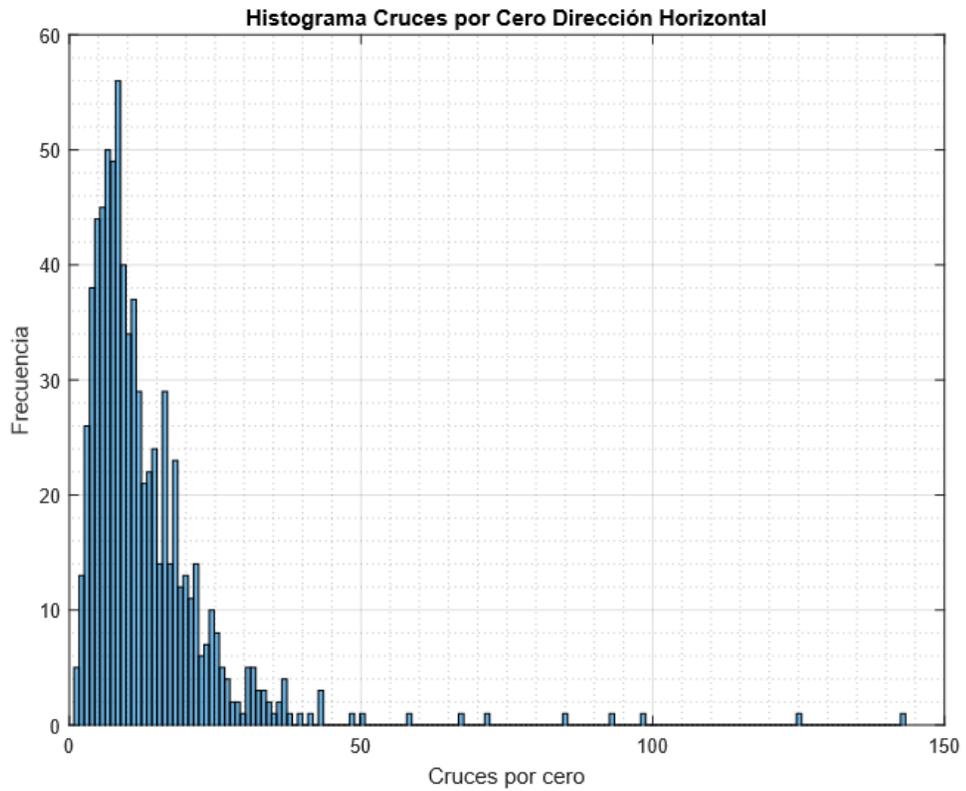


Figura A. 14: Histograma Cruces por Cero Dirección Horizontal

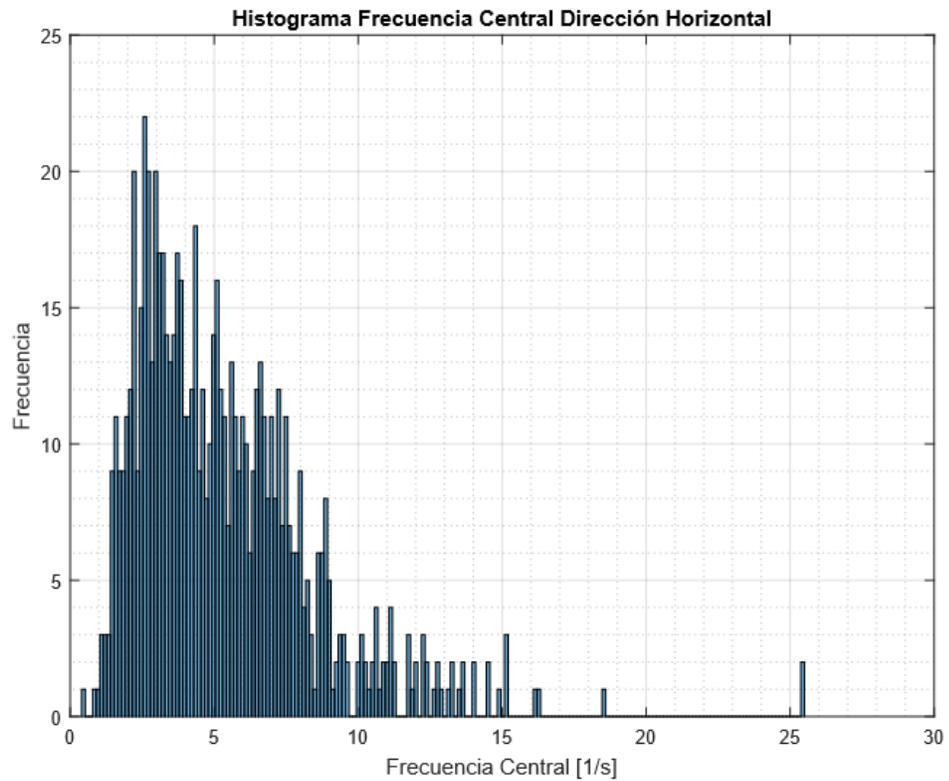


Figura A. 15: Histograma Frecuencia Central Dirección Horizontal

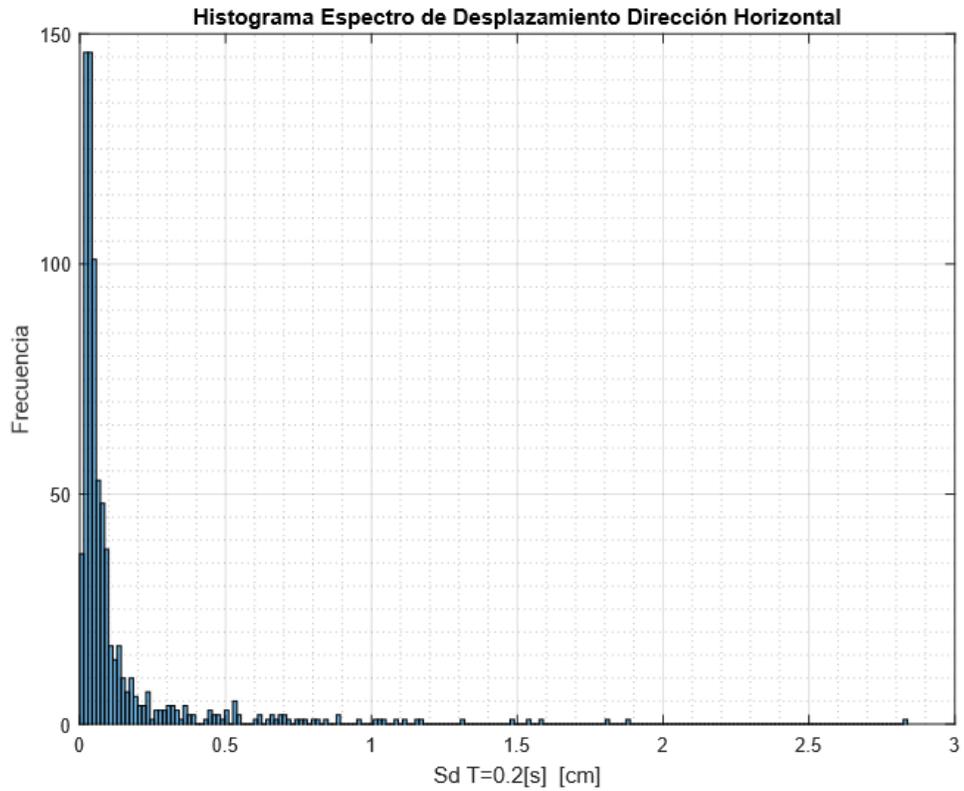


Figura A. 16: Histograma Espectro de Desplazamiento Dirección Horizontal. Periodo $T=0.2$ [s].

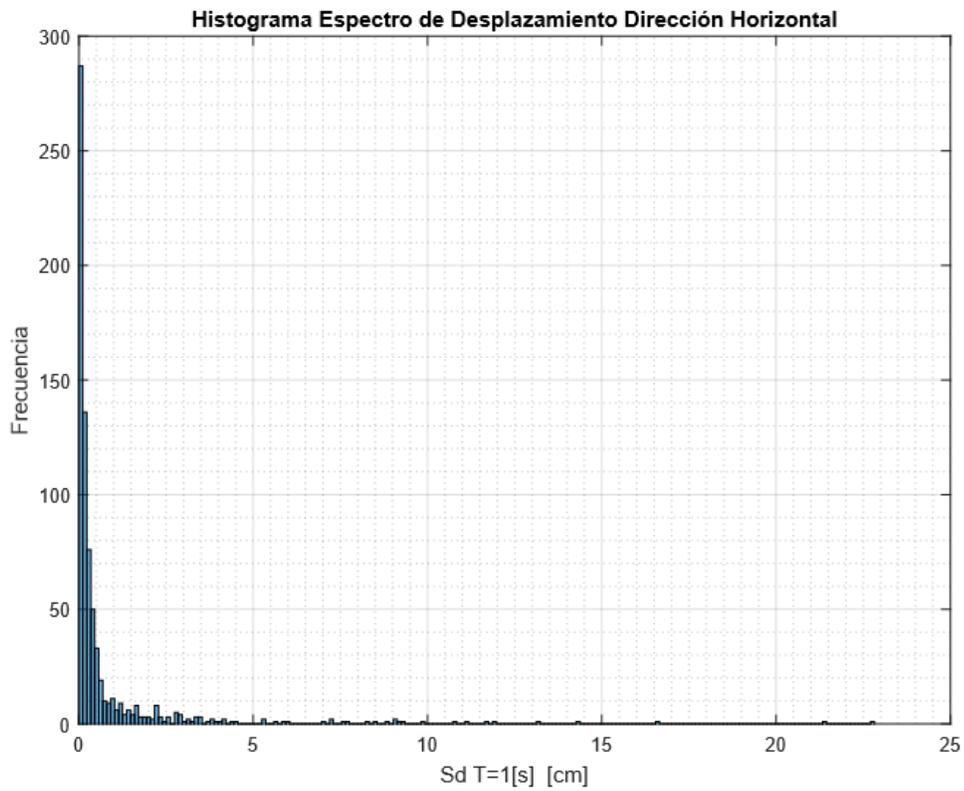


Figura A. 17: Histograma Espectro de Desplazamiento Dirección Horizontal. Periodo $T=1$ [s].

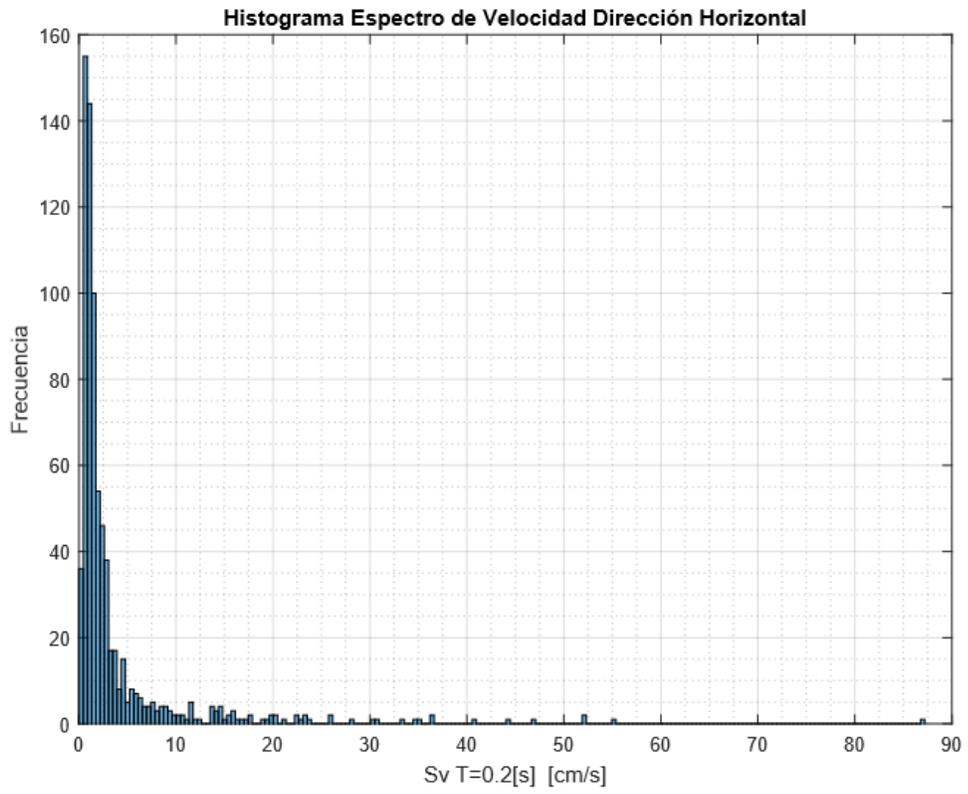


Figura A. 18: Histograma Espectro de Velocidad Dirección Horizontal. Periodo T=0.2 [s].

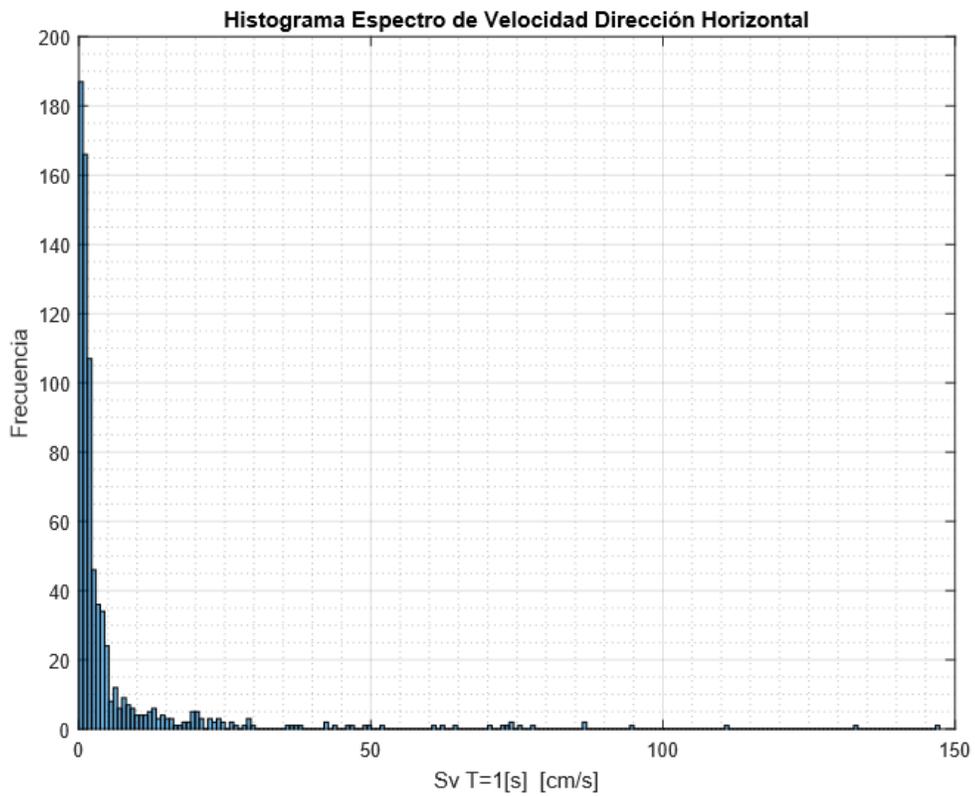


Figura A. 19: Histograma Espectro de Velocidad Dirección Horizontal. Periodo T=1 [s].

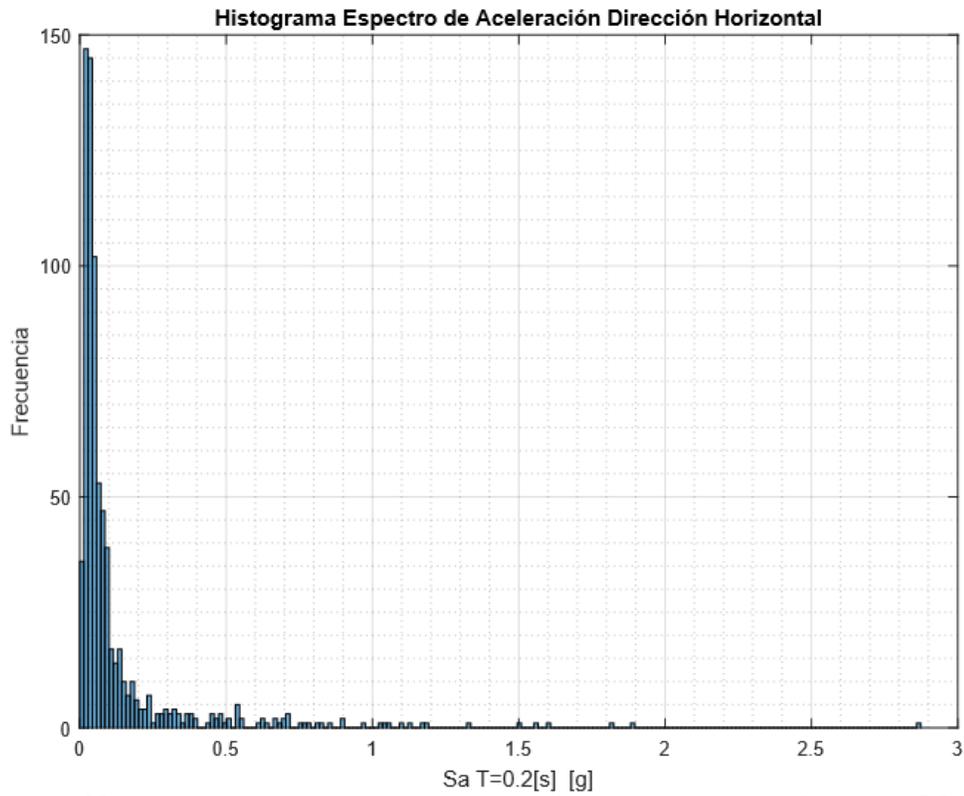


Figura A. 20: Histograma Espectro de Aceleración Dirección Horizontal. Periodo T=0.2 [s].

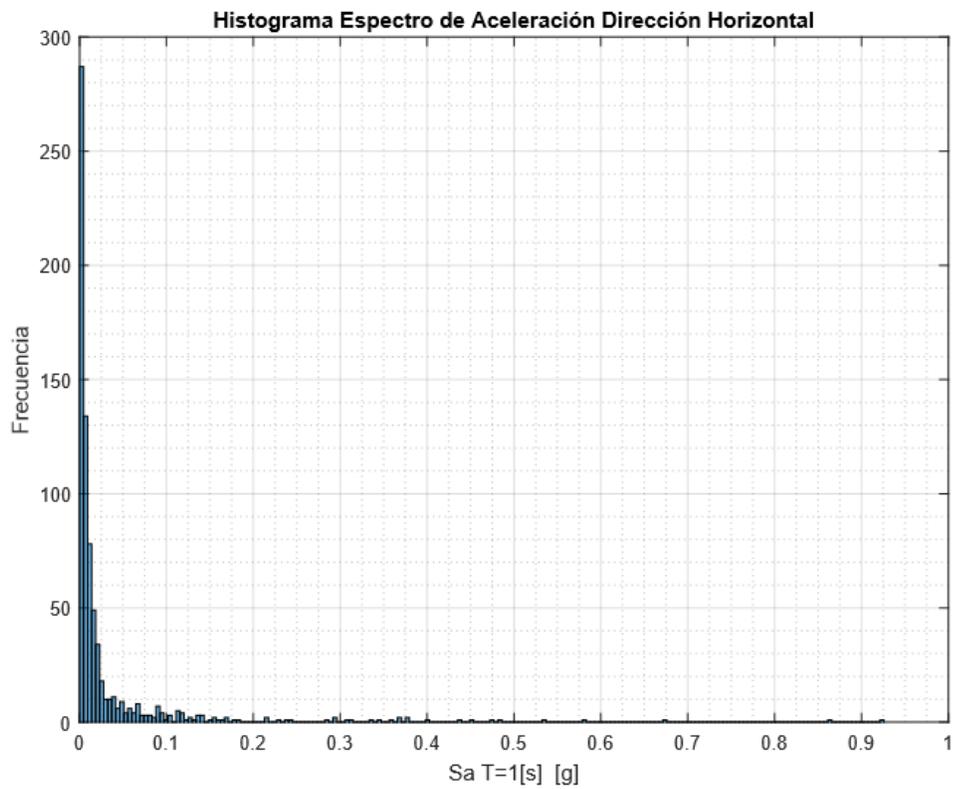


Figura A. 21: Histograma Espectro de Aceleración Dirección Horizontal. Periodo T=1 [s].

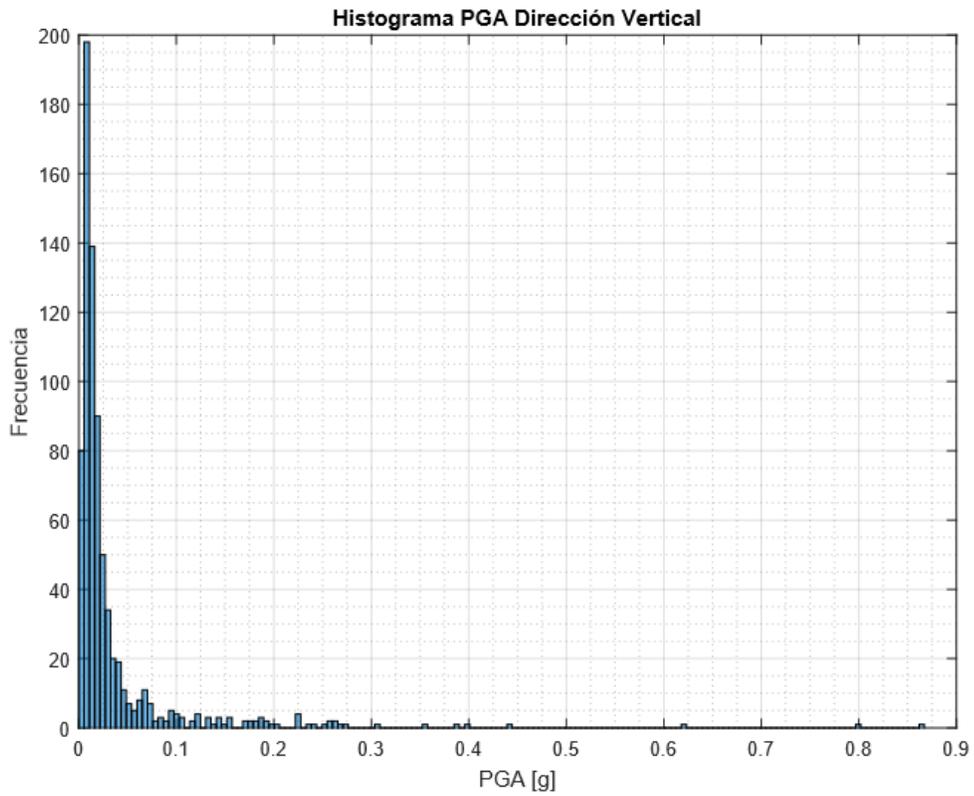


Figura A. 22: Histograma PGA Dirección Vertical

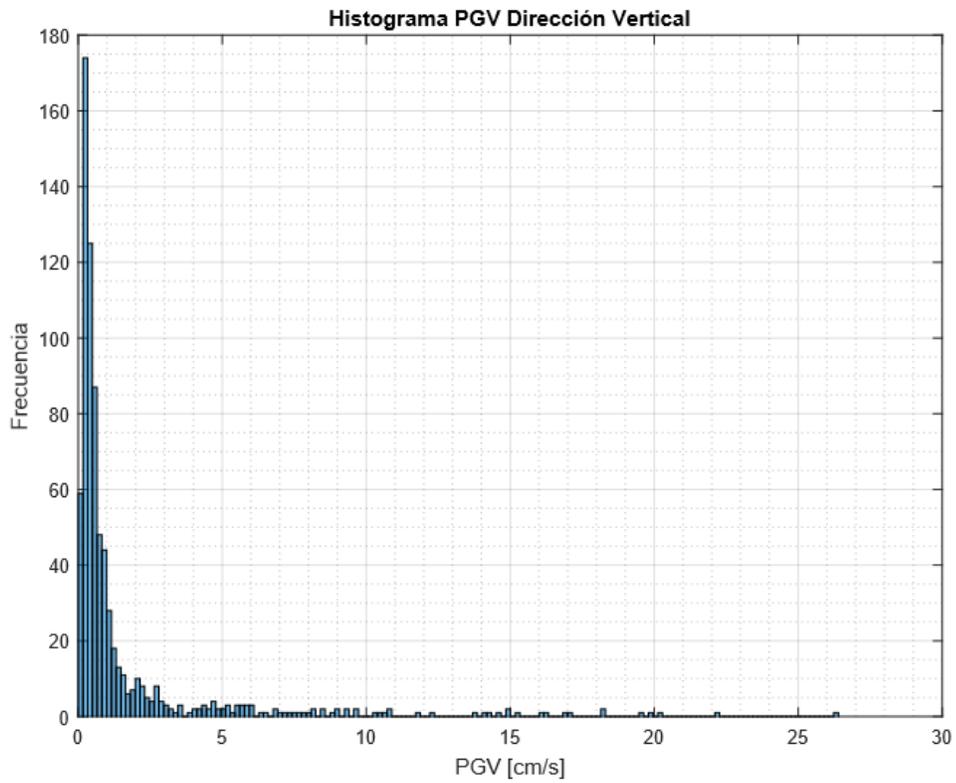


Figura A. 23: Histograma PGV Dirección Vertical

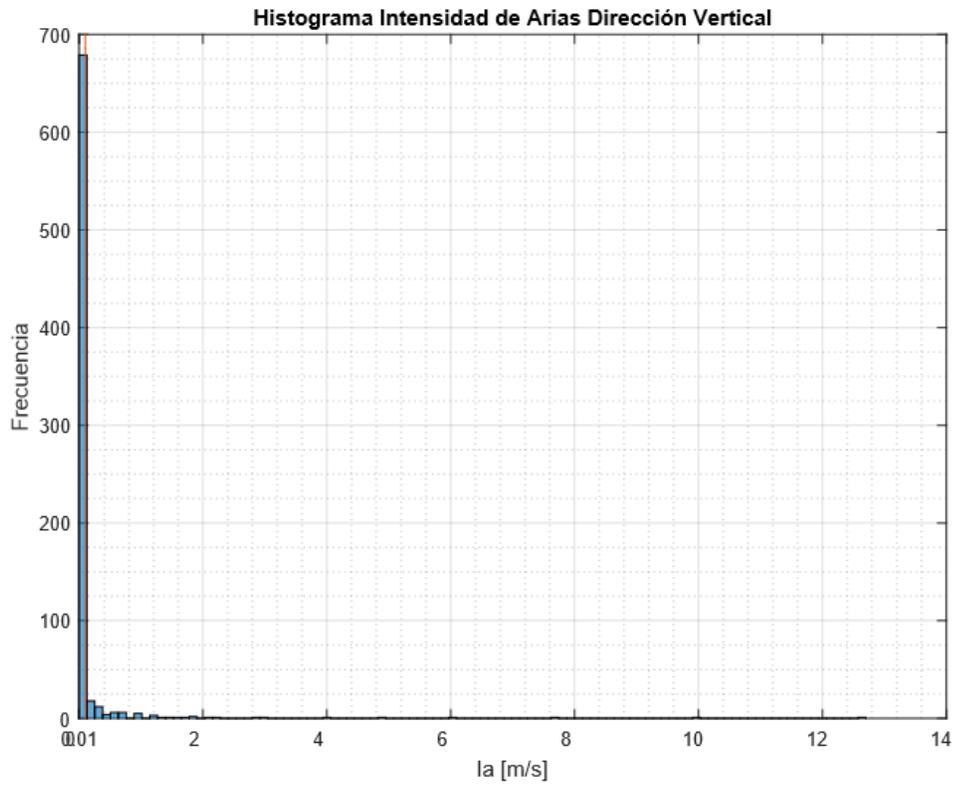


Figura A. 24: Histograma Intensidad de Arias Dirección Vertical

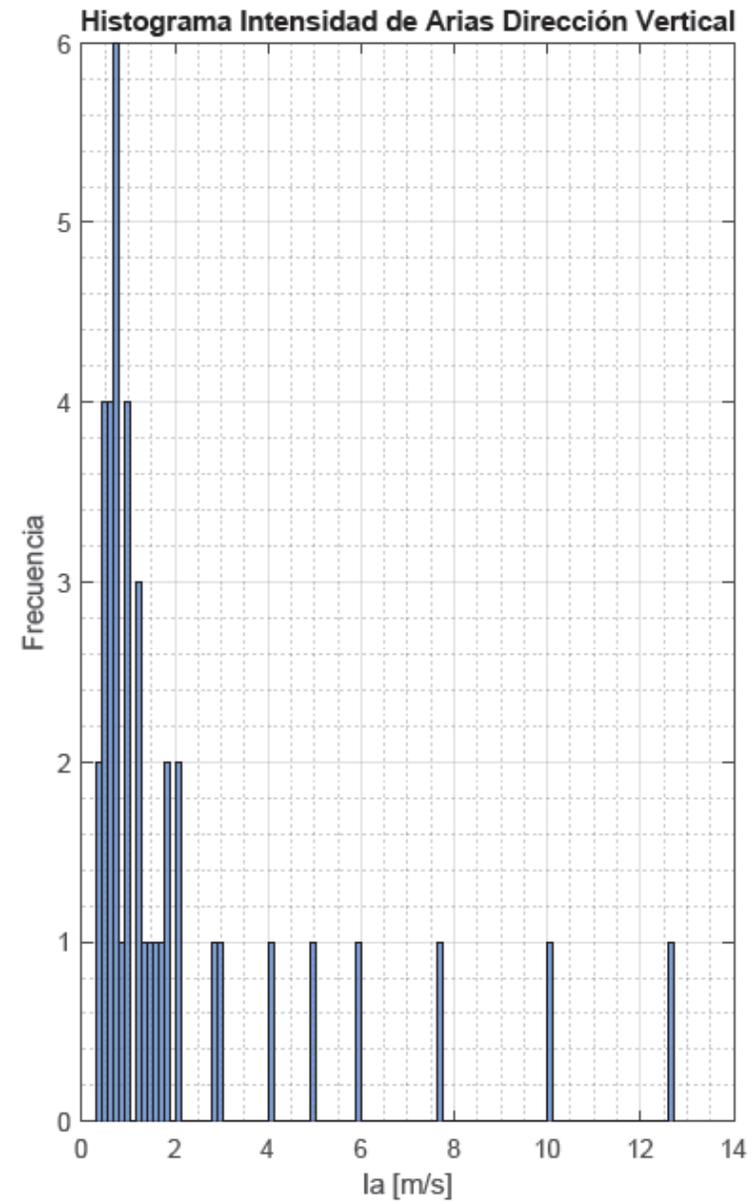
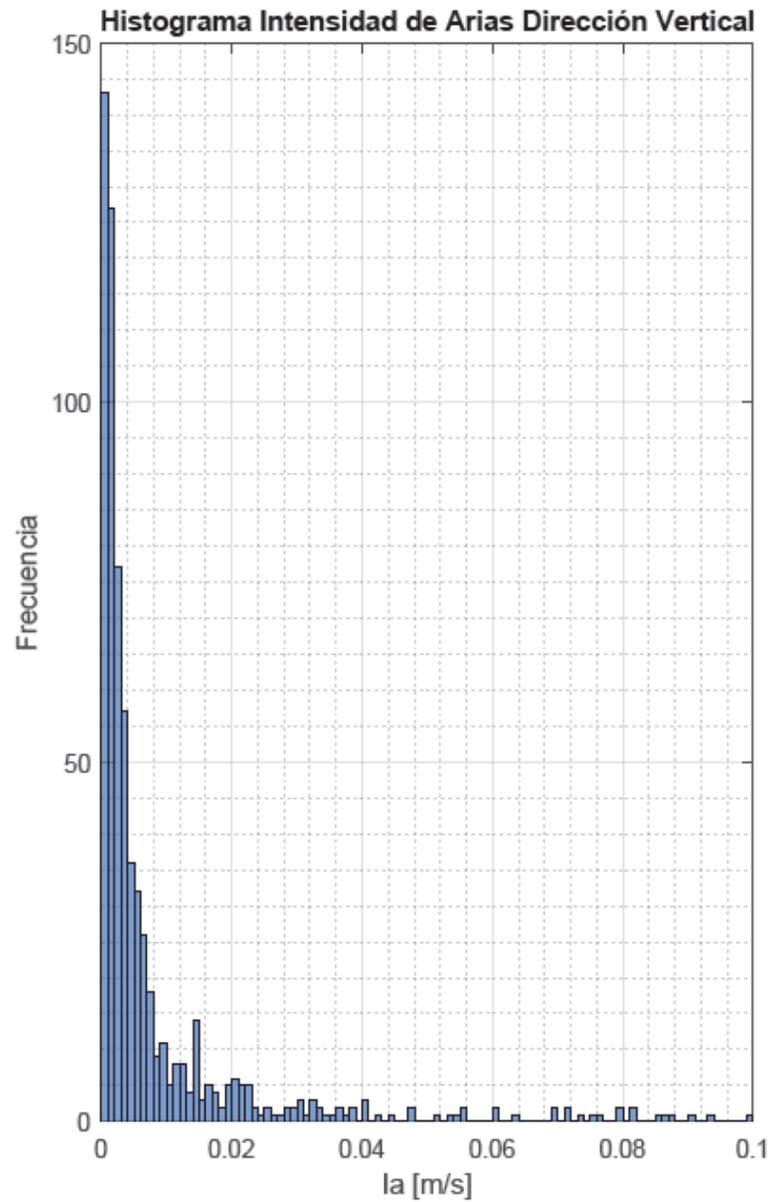


Figura A. 25: Histograma Intensidad de Arias Dirección Vertical por partes.

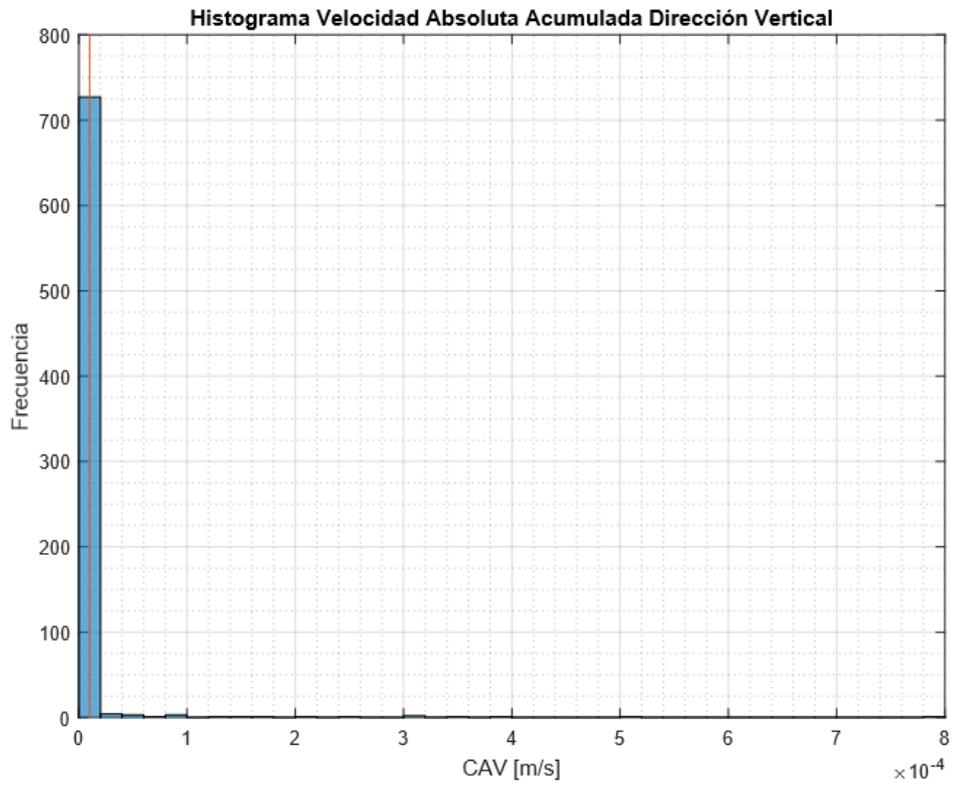


Figura A. 26: Histograma Velocidad Absoluta Acumulada Dirección Vertical

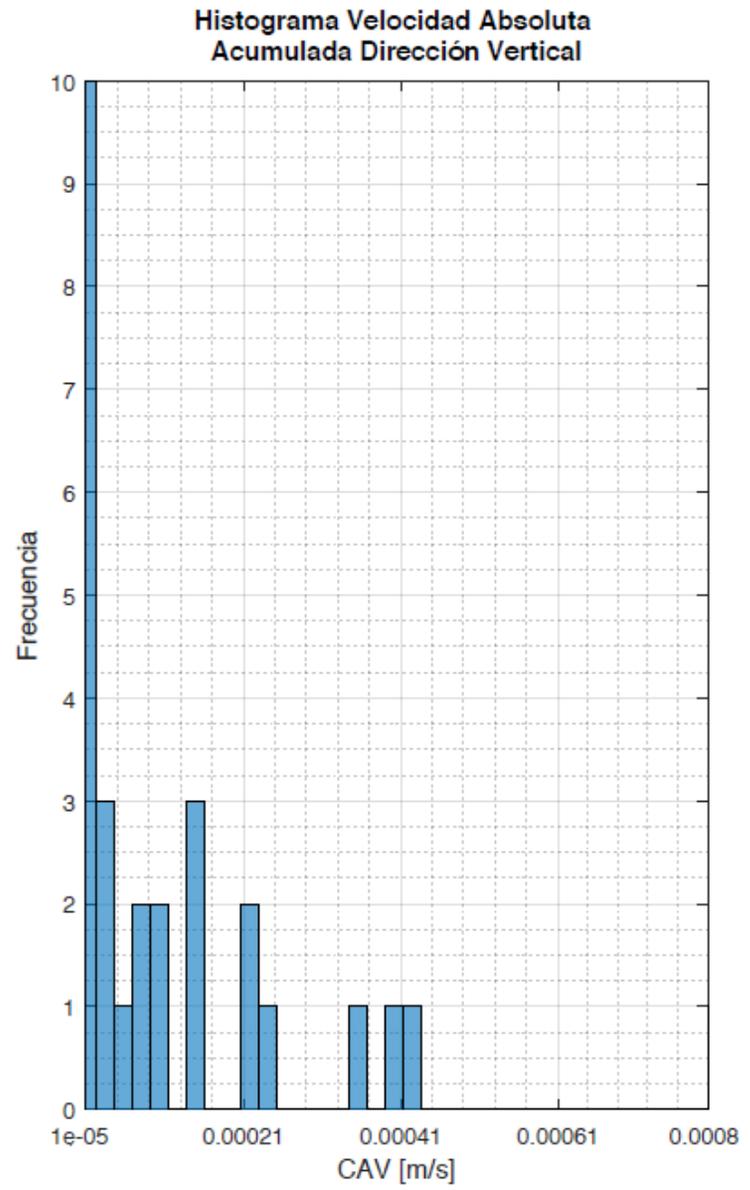
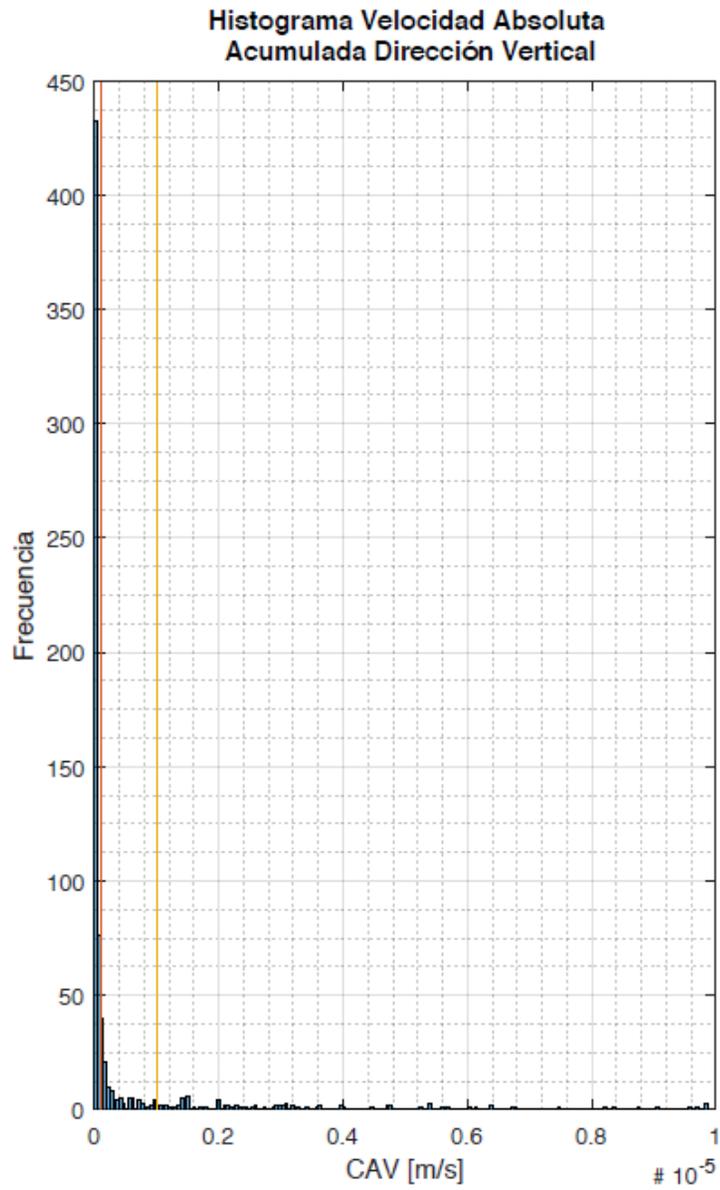


Figura A. 27: Histograma CAV Dirección Vertical por partes

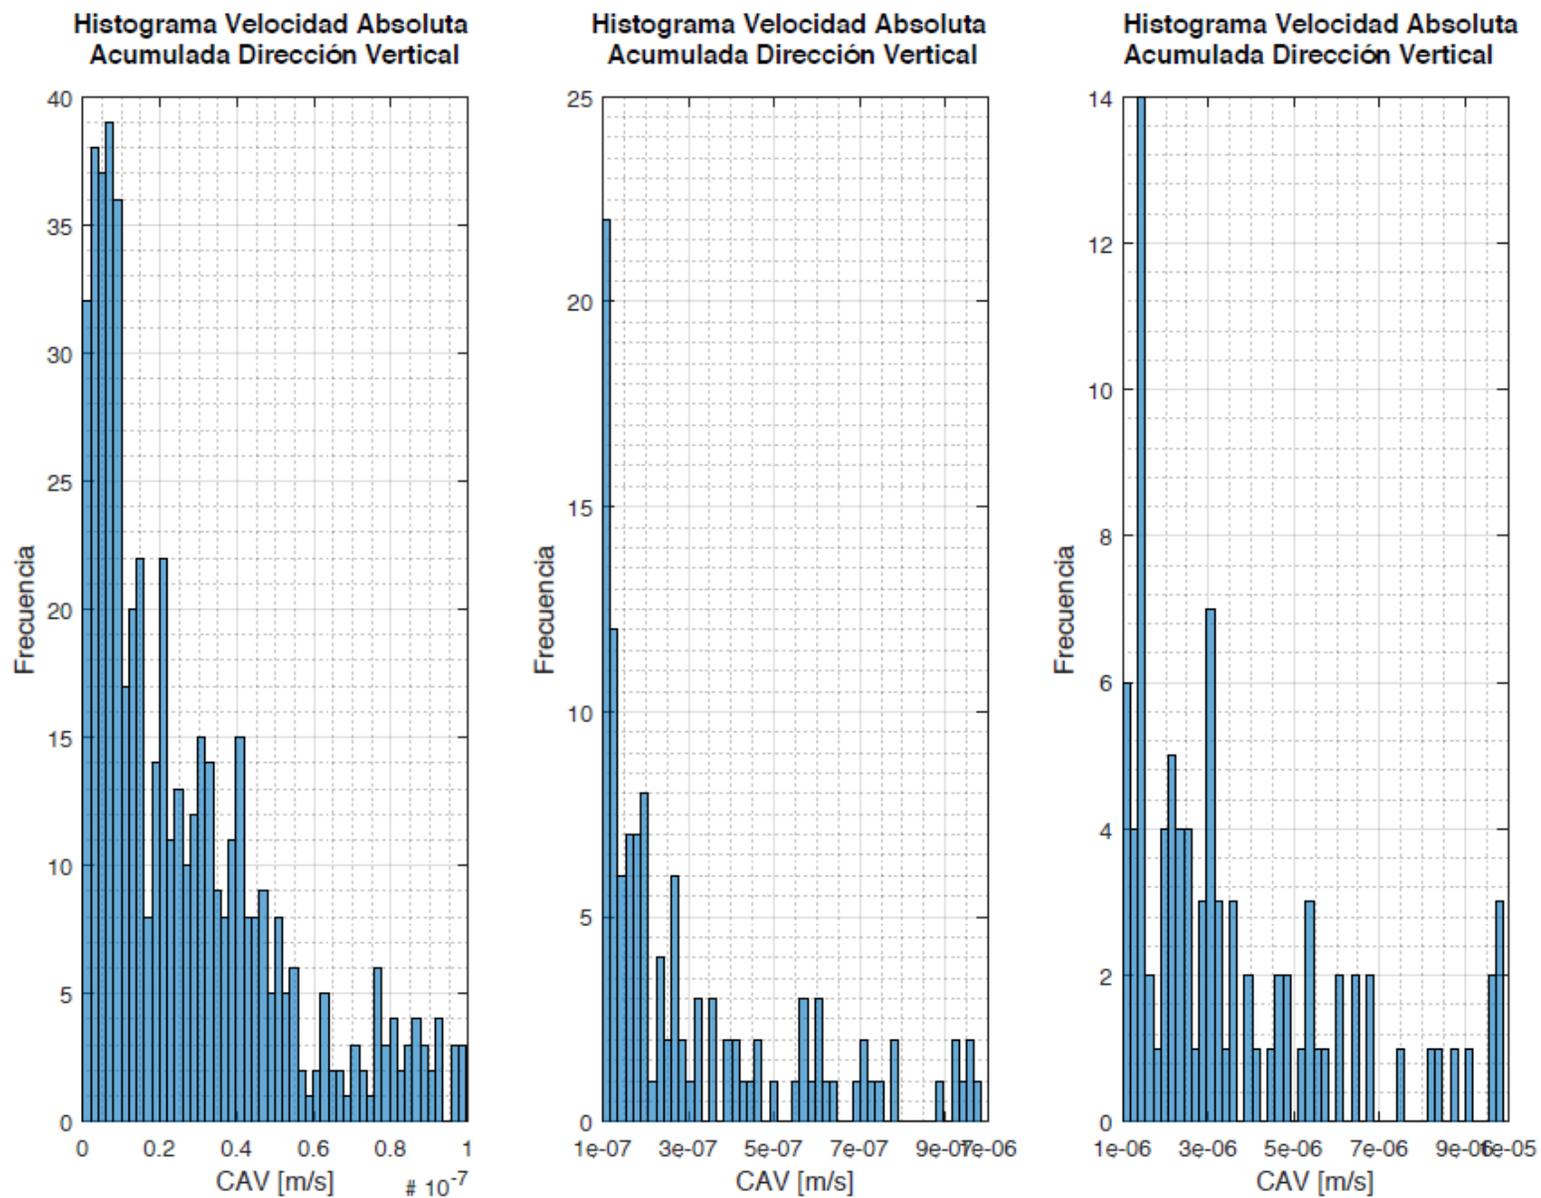


Figura A. 28: Histograma CAV Dirección Vertical sub-partes

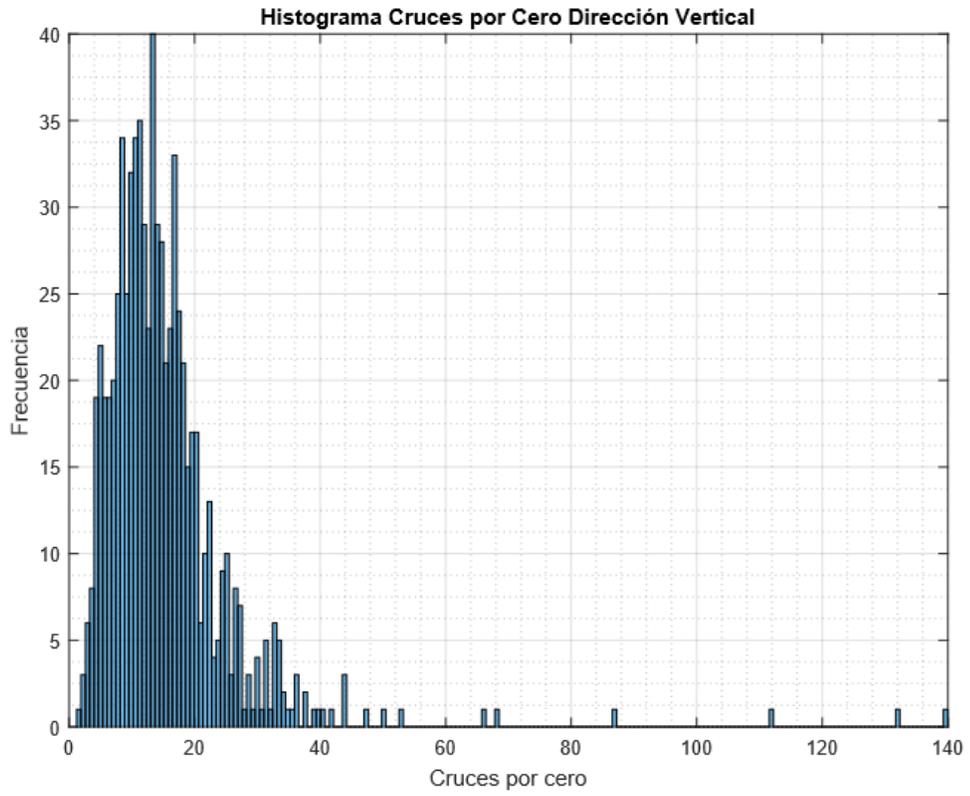


Figura A. 29: Histograma Cruces por Cero Dirección Vertical

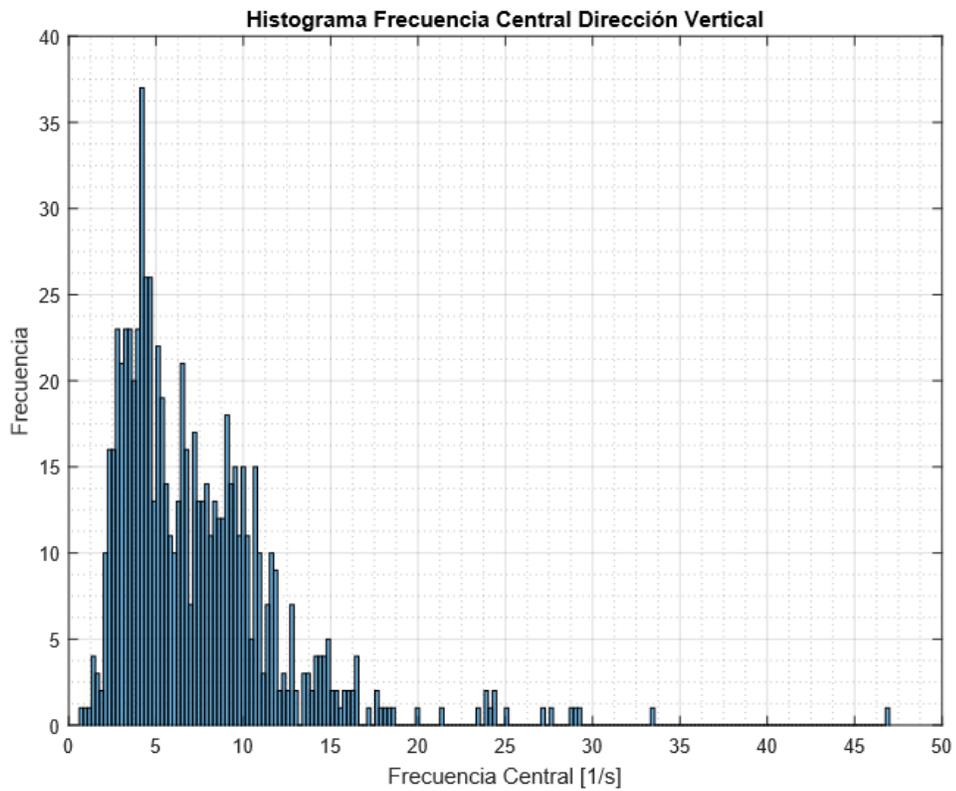


Figura A. 30: Histograma Frecuencia Central Dirección vertical

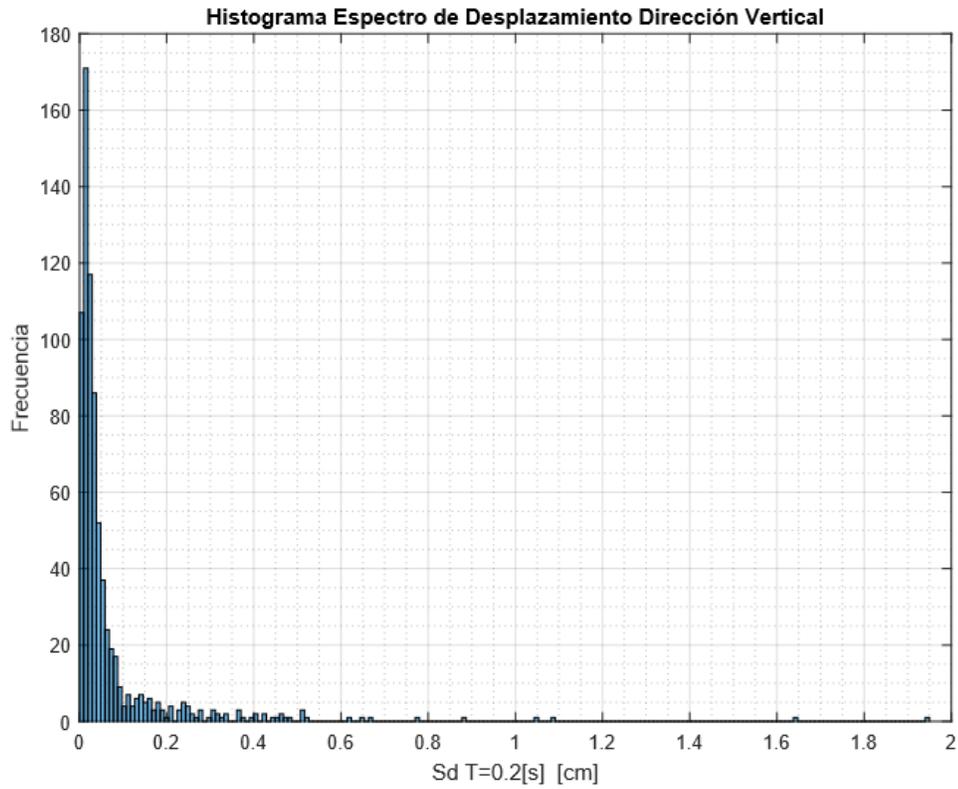


Figura A. 31: Histograma Espectro de Desplazamiento Dirección Vertical. Periodo T=0.2 [s].

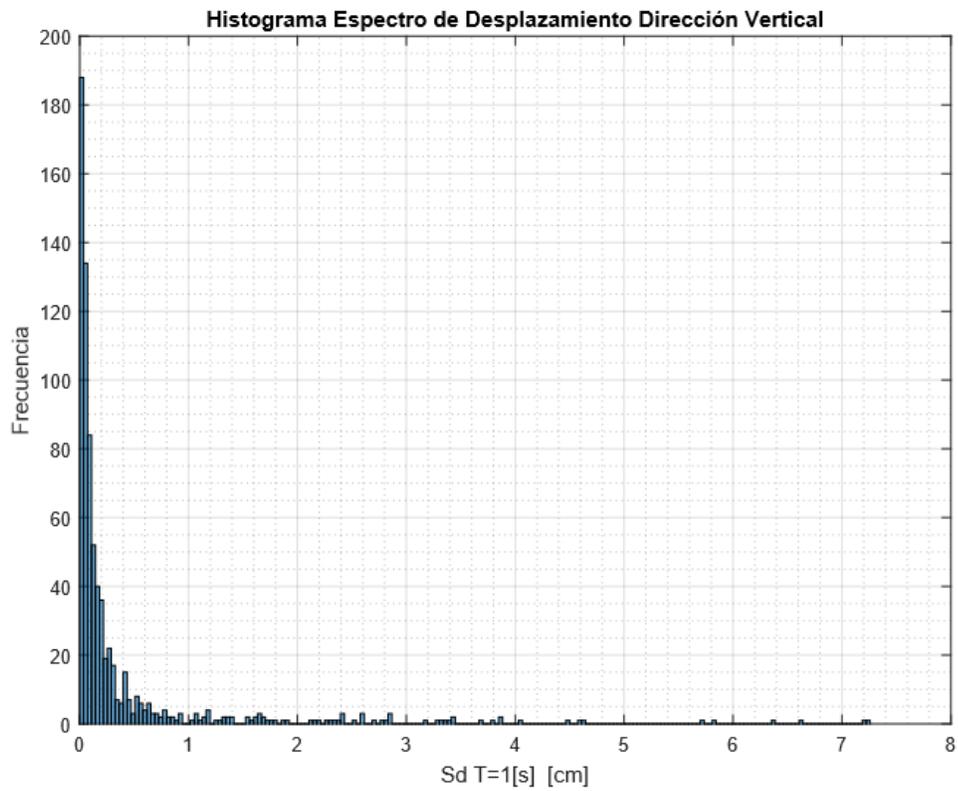


Figura A. 32: Histograma Espectro de Desplazamiento Dirección Vertical. Periodo T=1 [s].

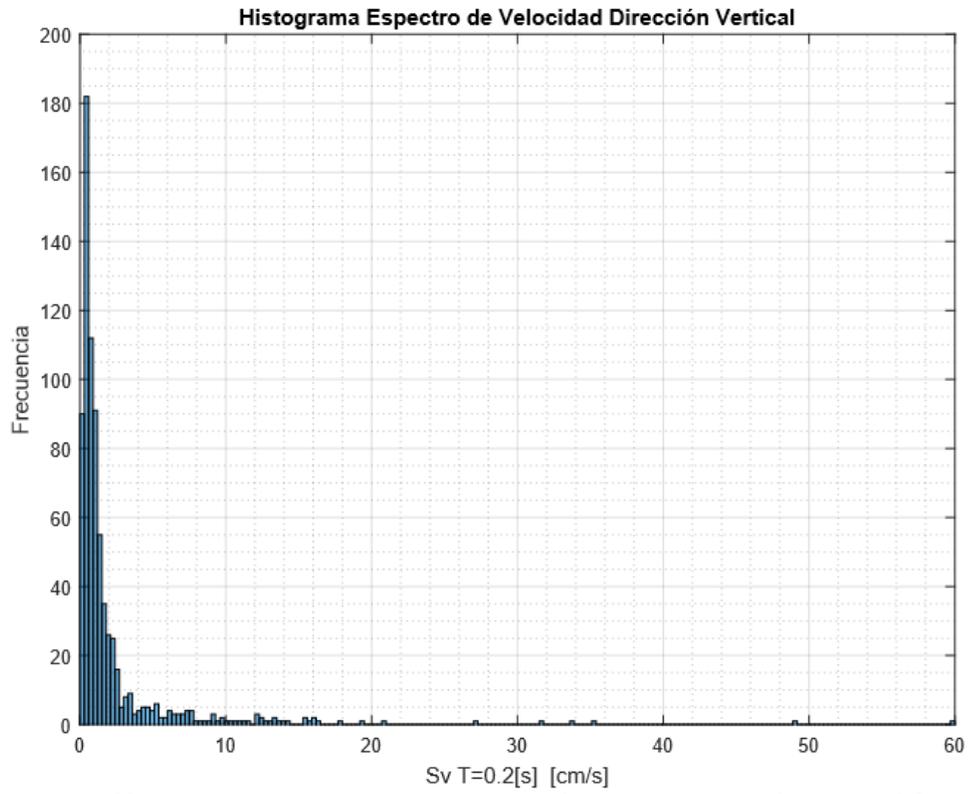


Figura A. 33: Histograma Espectro de Velocidad Dirección Vertical. Periodo $T=0.2$ [s].

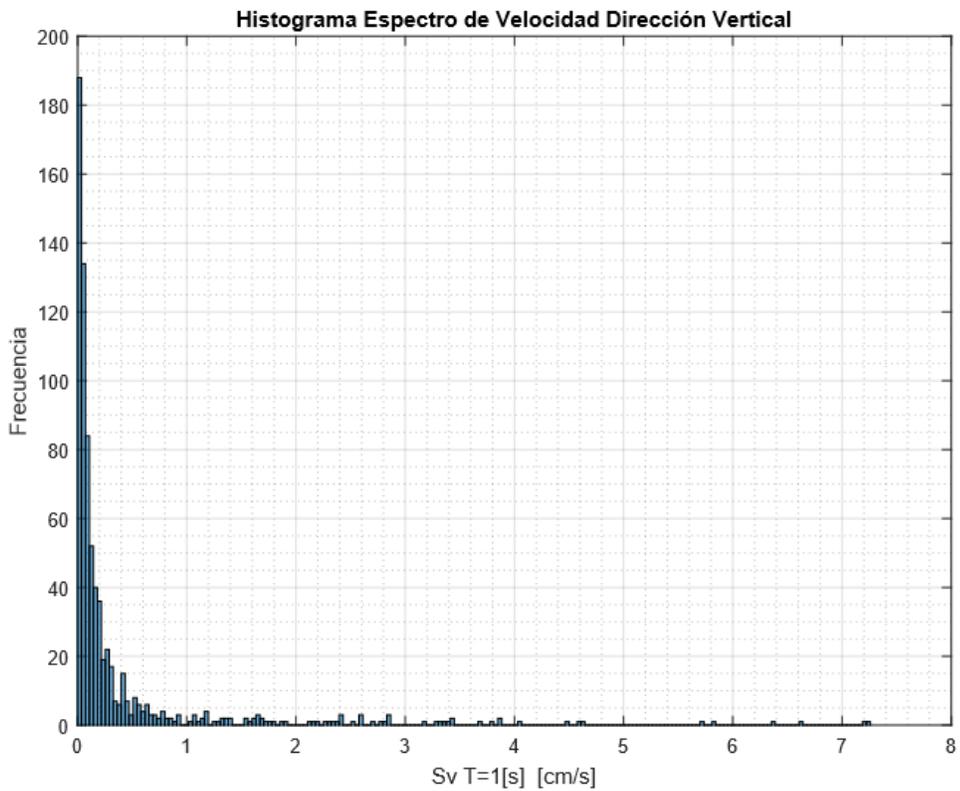


Figura A. 34: Histograma Espectro de Velocidad Dirección Vertical. Periodo $T=1$ [s].

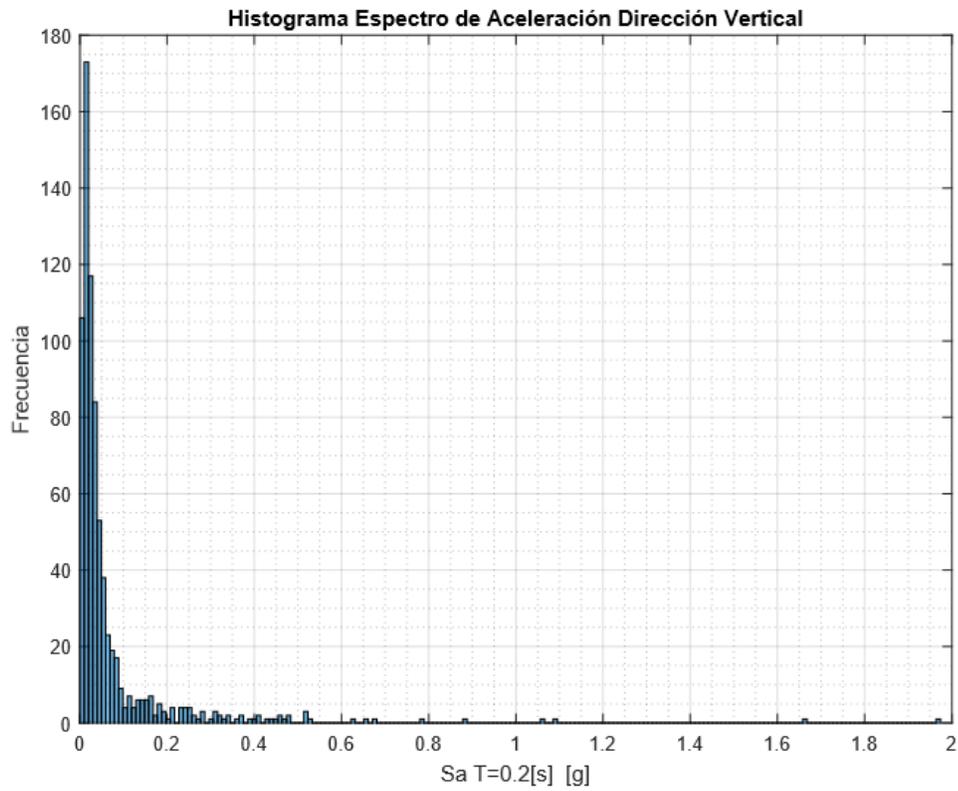


Figura A. 35: Histograma Espectro de Aceleración Dirección Vertical. Periodo T=0.2 [s].

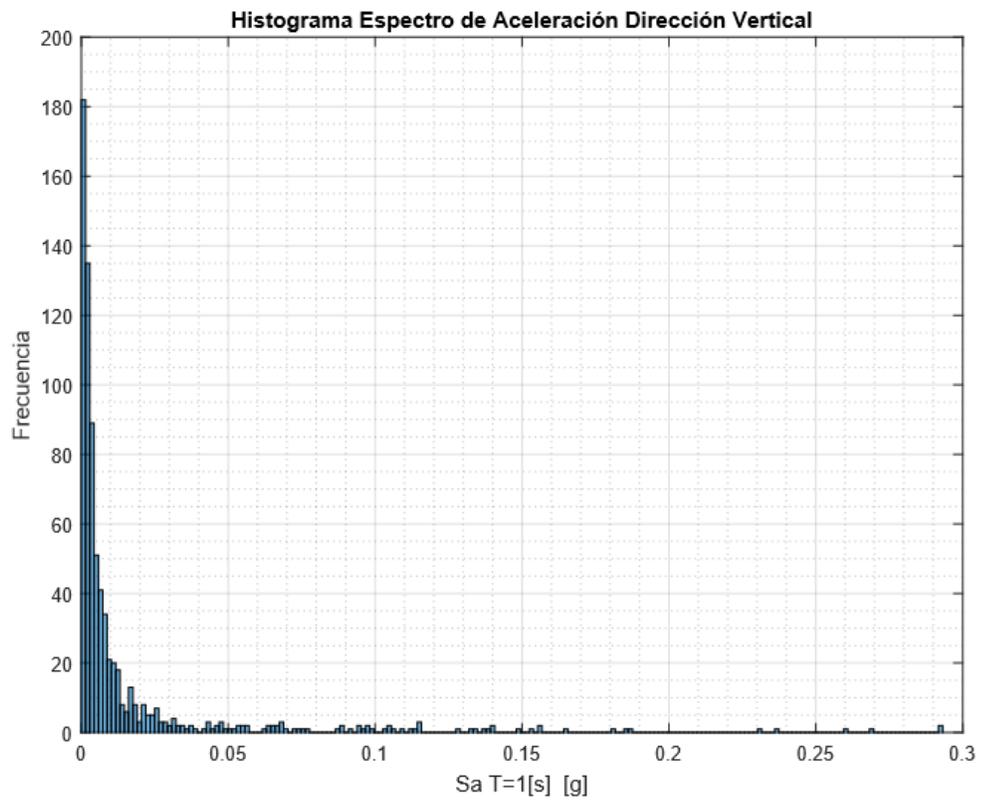


Figura A. 36: Histograma Espectro de Aceleración Dirección Vertical. Periodo T=1 [s].

**ANEXO B: RELACIÓN ENTRE INTENSIDAD DE MERCALLI
MODIFICADA Y CADA UNA DE LAS VARIABLES
INDEPENDIENTES**

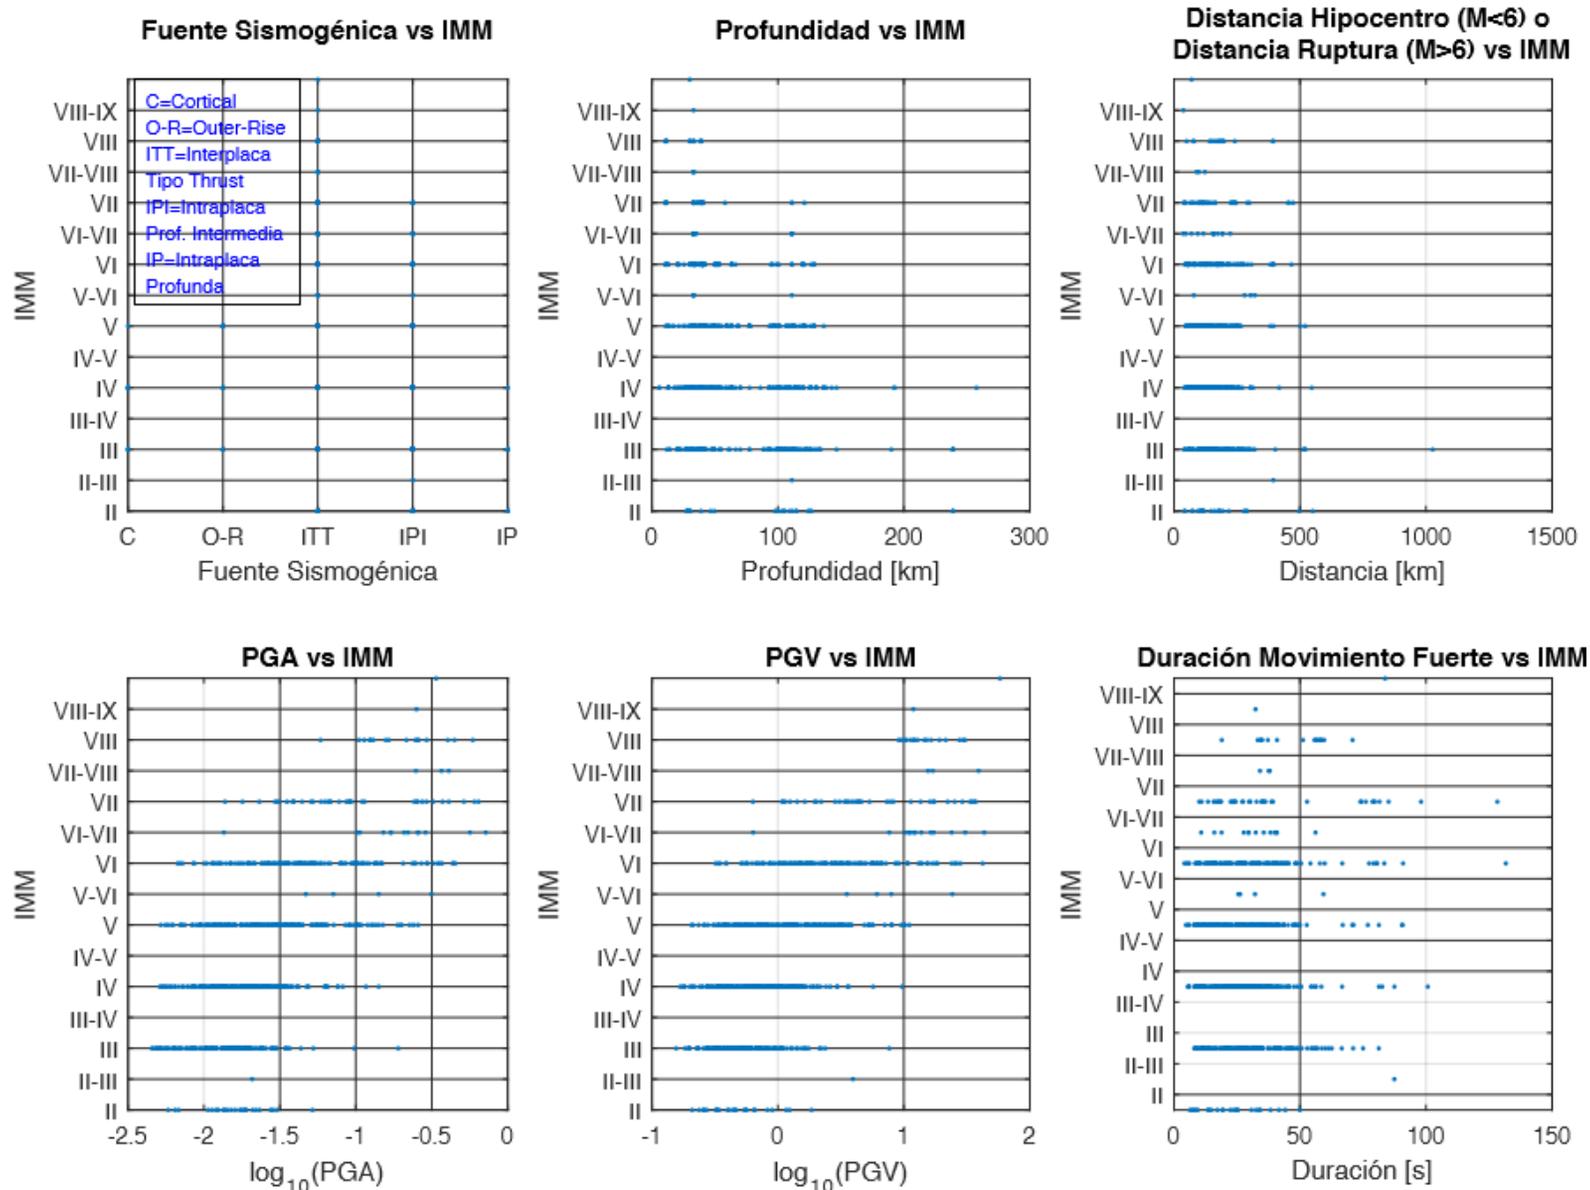


Figura B. 1: Relación entre IMM y (a) Fuente Sismogénica, (b) profundidad, (c) Distancia hipocentro, (d) $\log(\text{PGA})$, (e) $\log(\text{PGV})$, (f) Duración movimiento fuerte

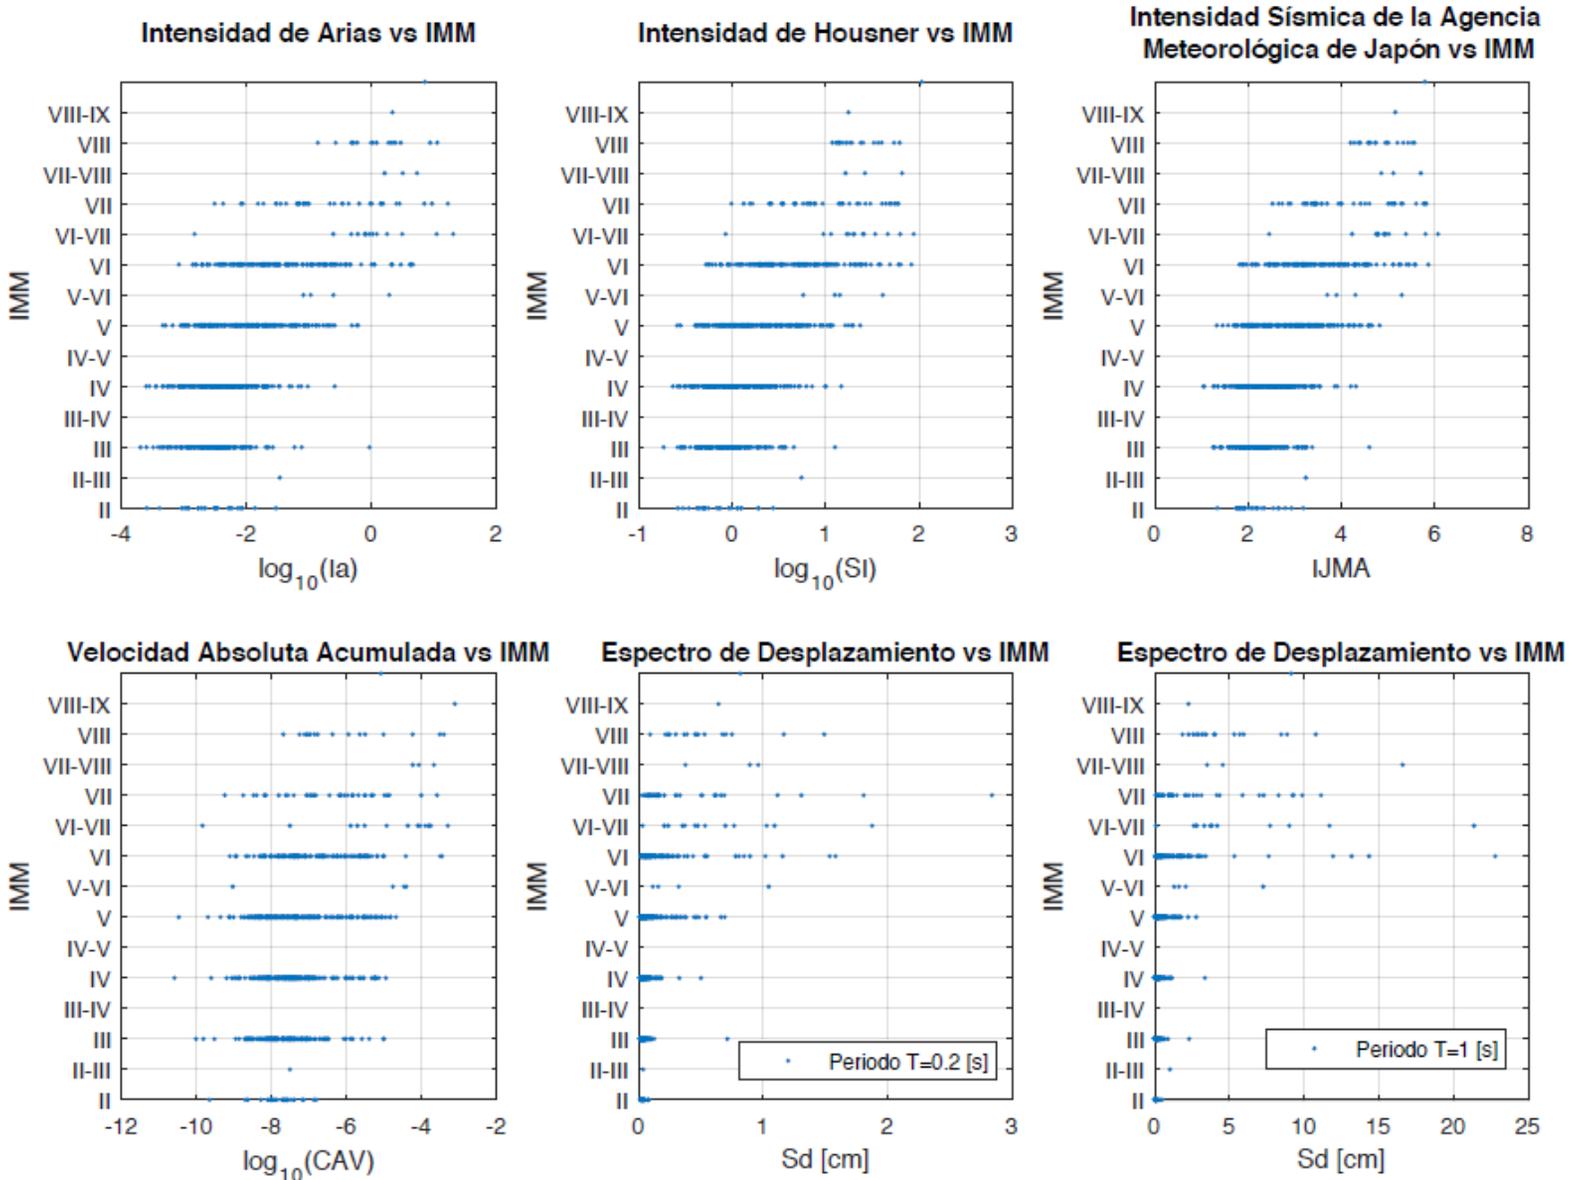


Figura B. 2: Relación entre IMM y (a) $\log(I_a)$, (b) $\log(S_I)$, (c) IJMA, (d) CAV, (e) Espectro de Desplazamiento $T=0.2$ [s], (f) Espectro de Desplazamiento $T=1$ [s]

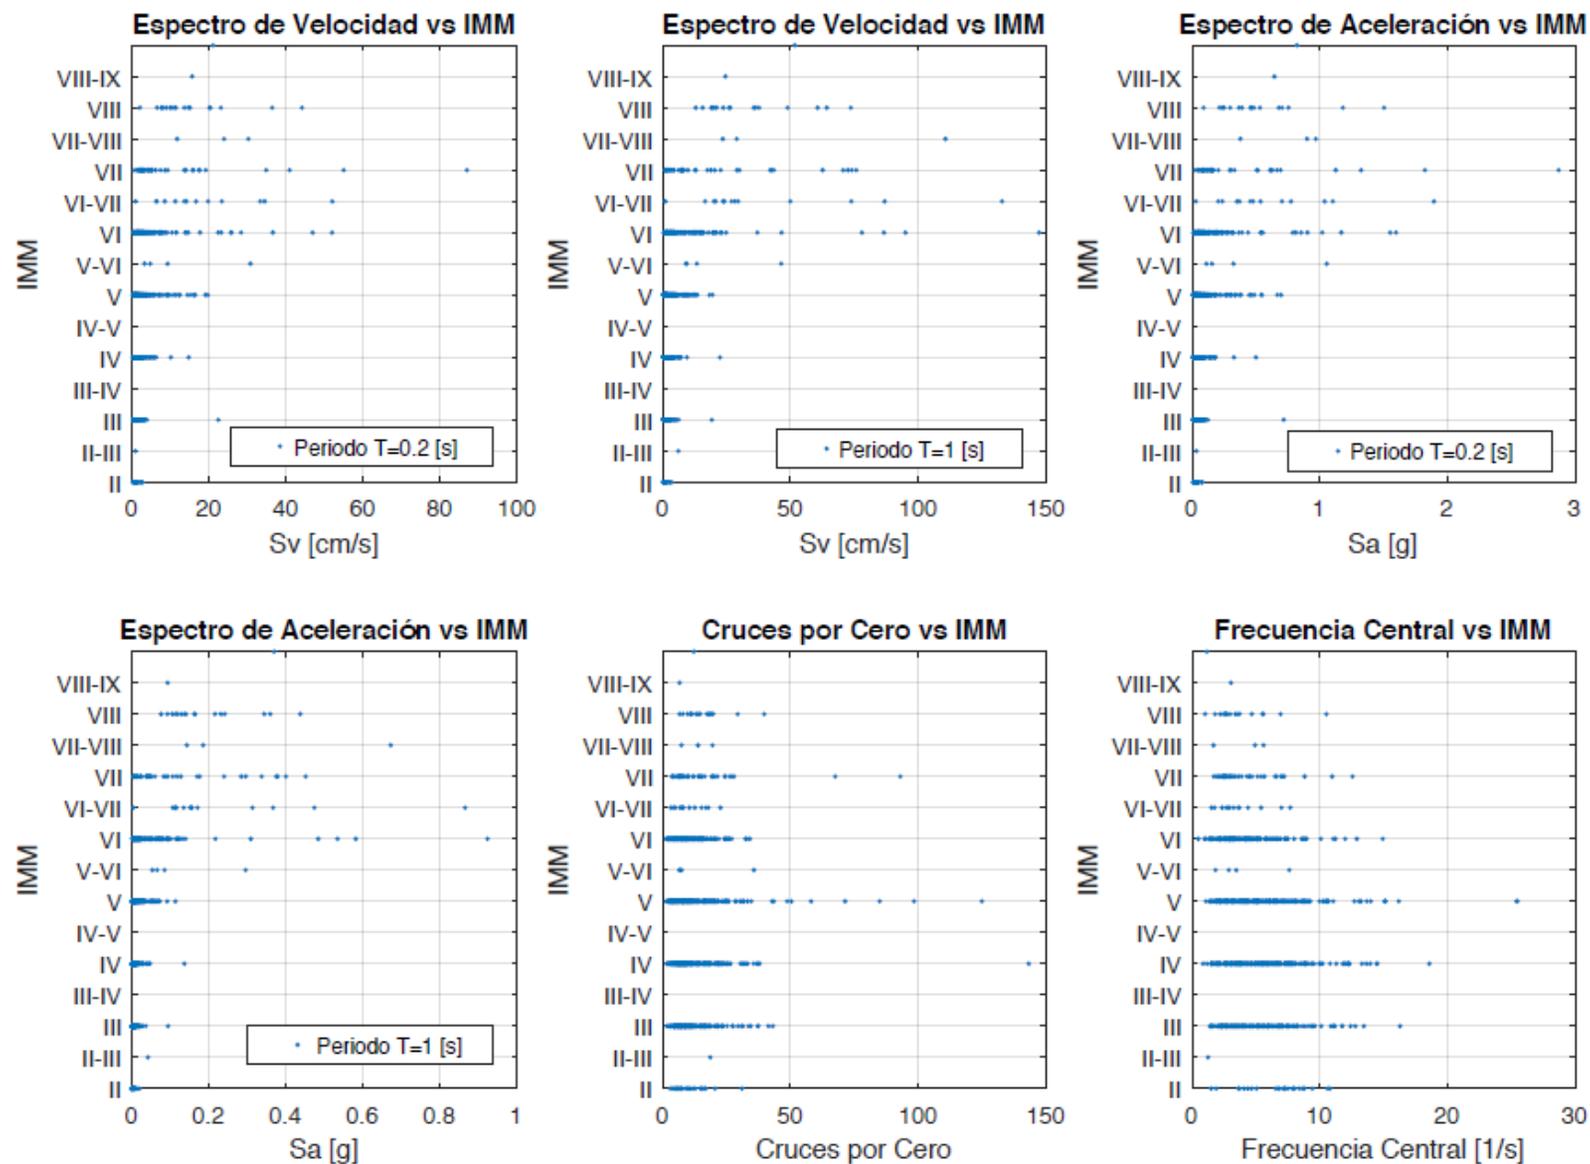


Figura B. 3: Relación de IMM y (a) Espectro de Velocidad T=0.2 [s], (b) Espectro de Velocidad T=1 [s], (c) Espectro de Aceleración T=0.2 [s], Espectro de Aceleración T=1 [s], (e) Cruces por Cero, (f) Frecuencia Central

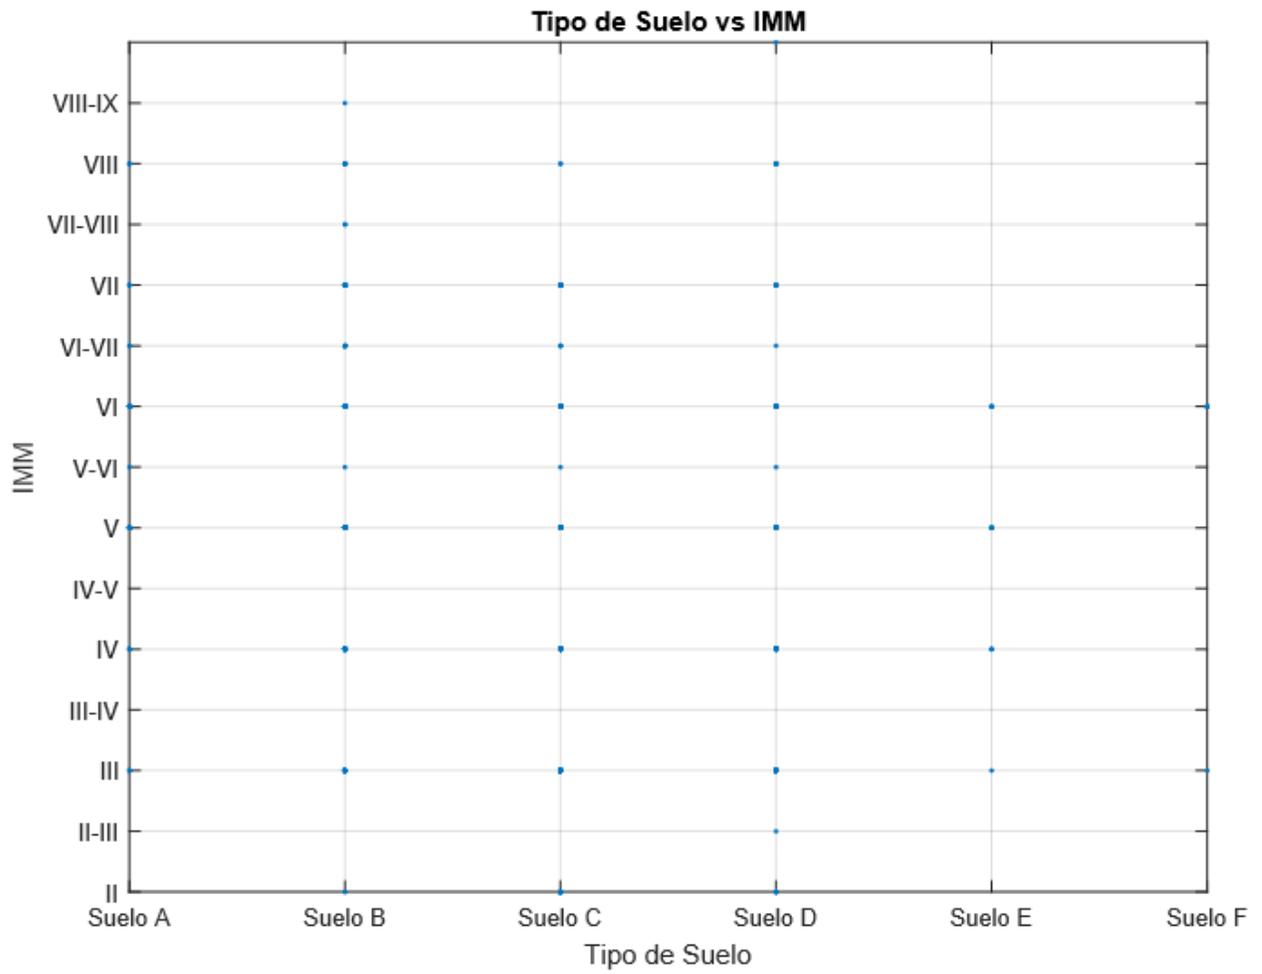


Figura B. 4: Relación de IMM y Tipo de Suelo

**ANEXO C: RELACIÓN ENTRE LAS VARIABLES
INDEPENDIENTES**

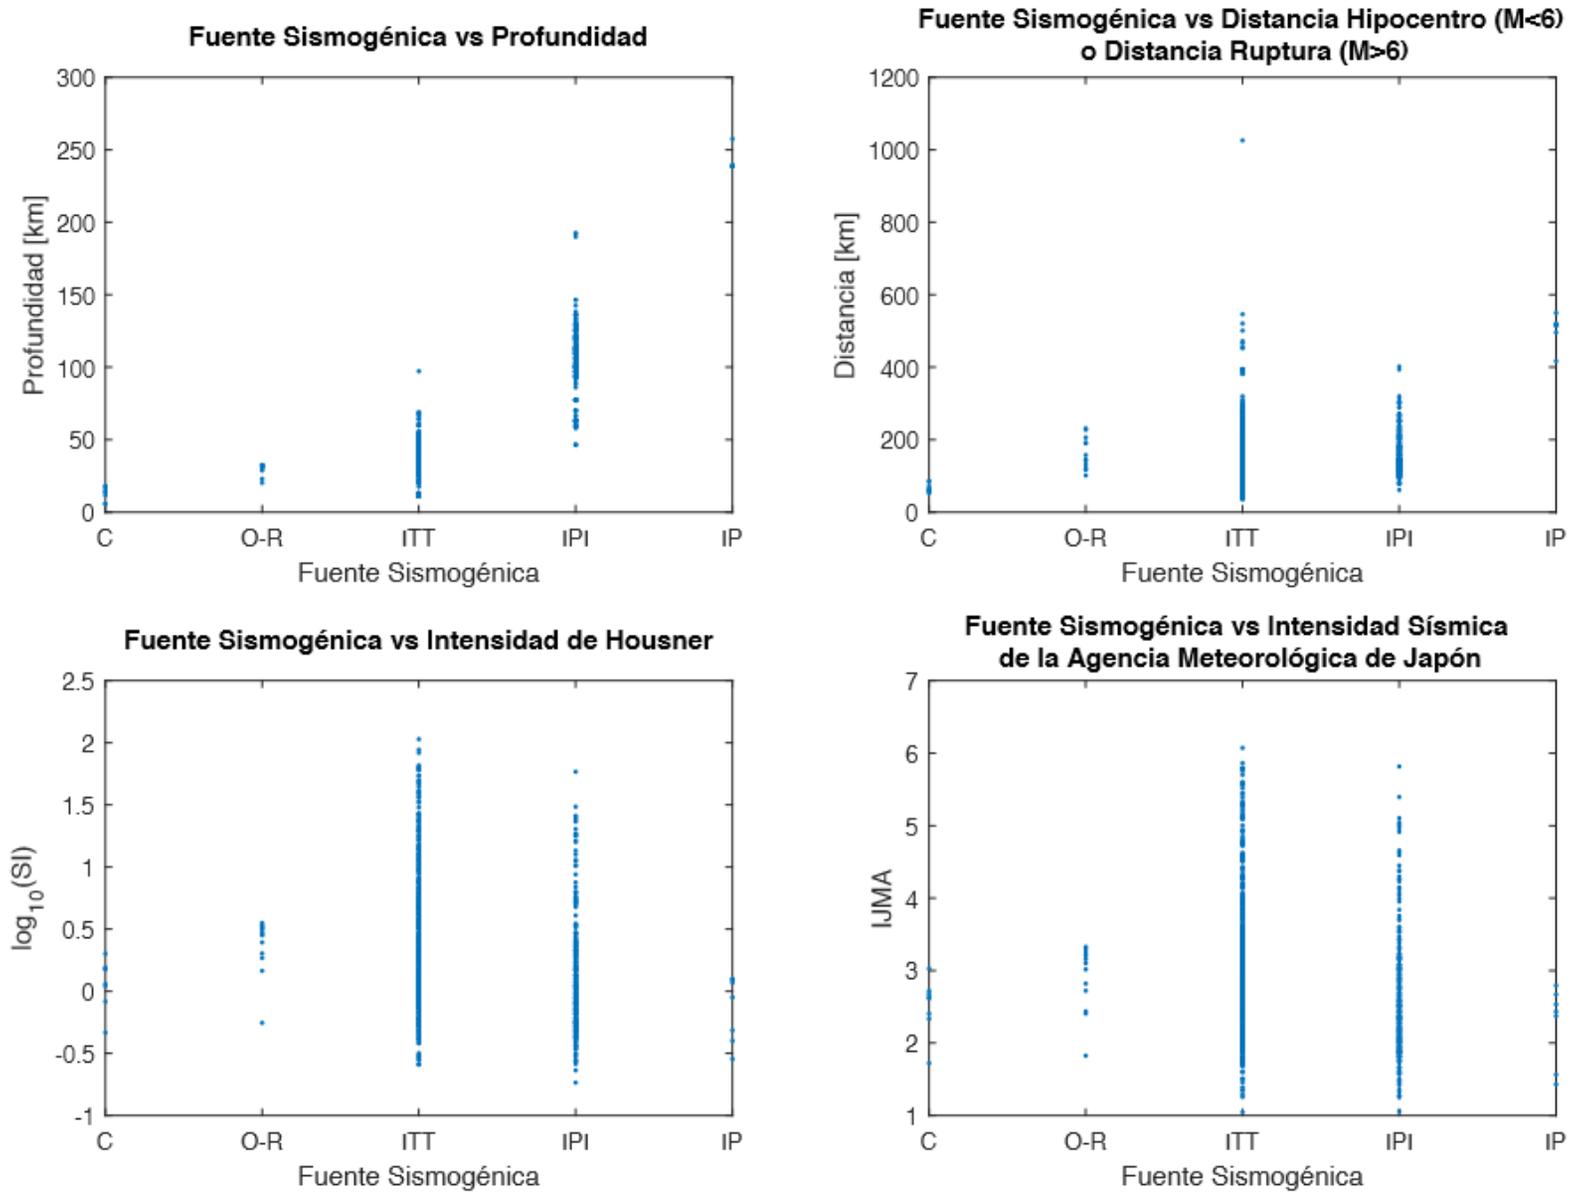


Figura C. 1: Relación entre Fuente Sismogénica y (a) Profundidad, (b) Distancia Hipocentro o Ruptura, (c) log(SI), (d) IJMA

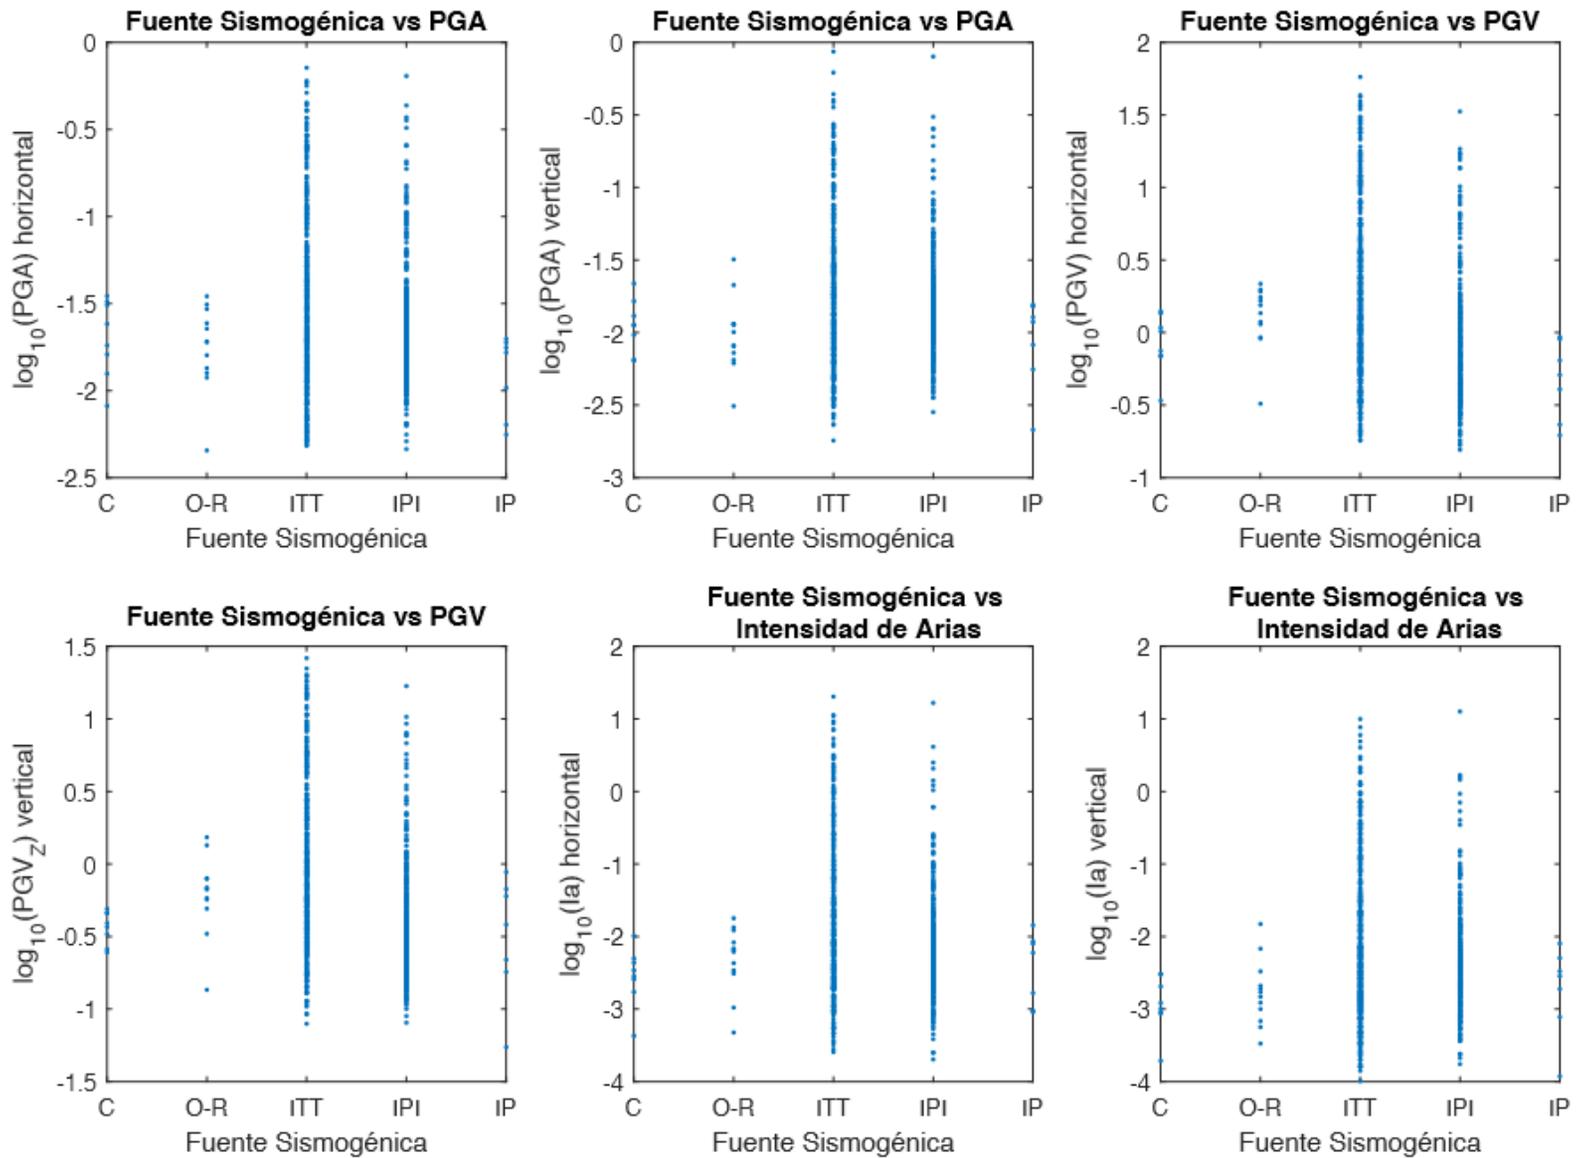


Figura C. 2: Relación entre Fuente Sismogénica y (a) log(PGA) horizontal, (b) log(PGA) vertical, (c) log(PGV) horizontal, (d) log(PGV) vertical, (e) log(Ia) horizontal, (f) log(Ia) vertical

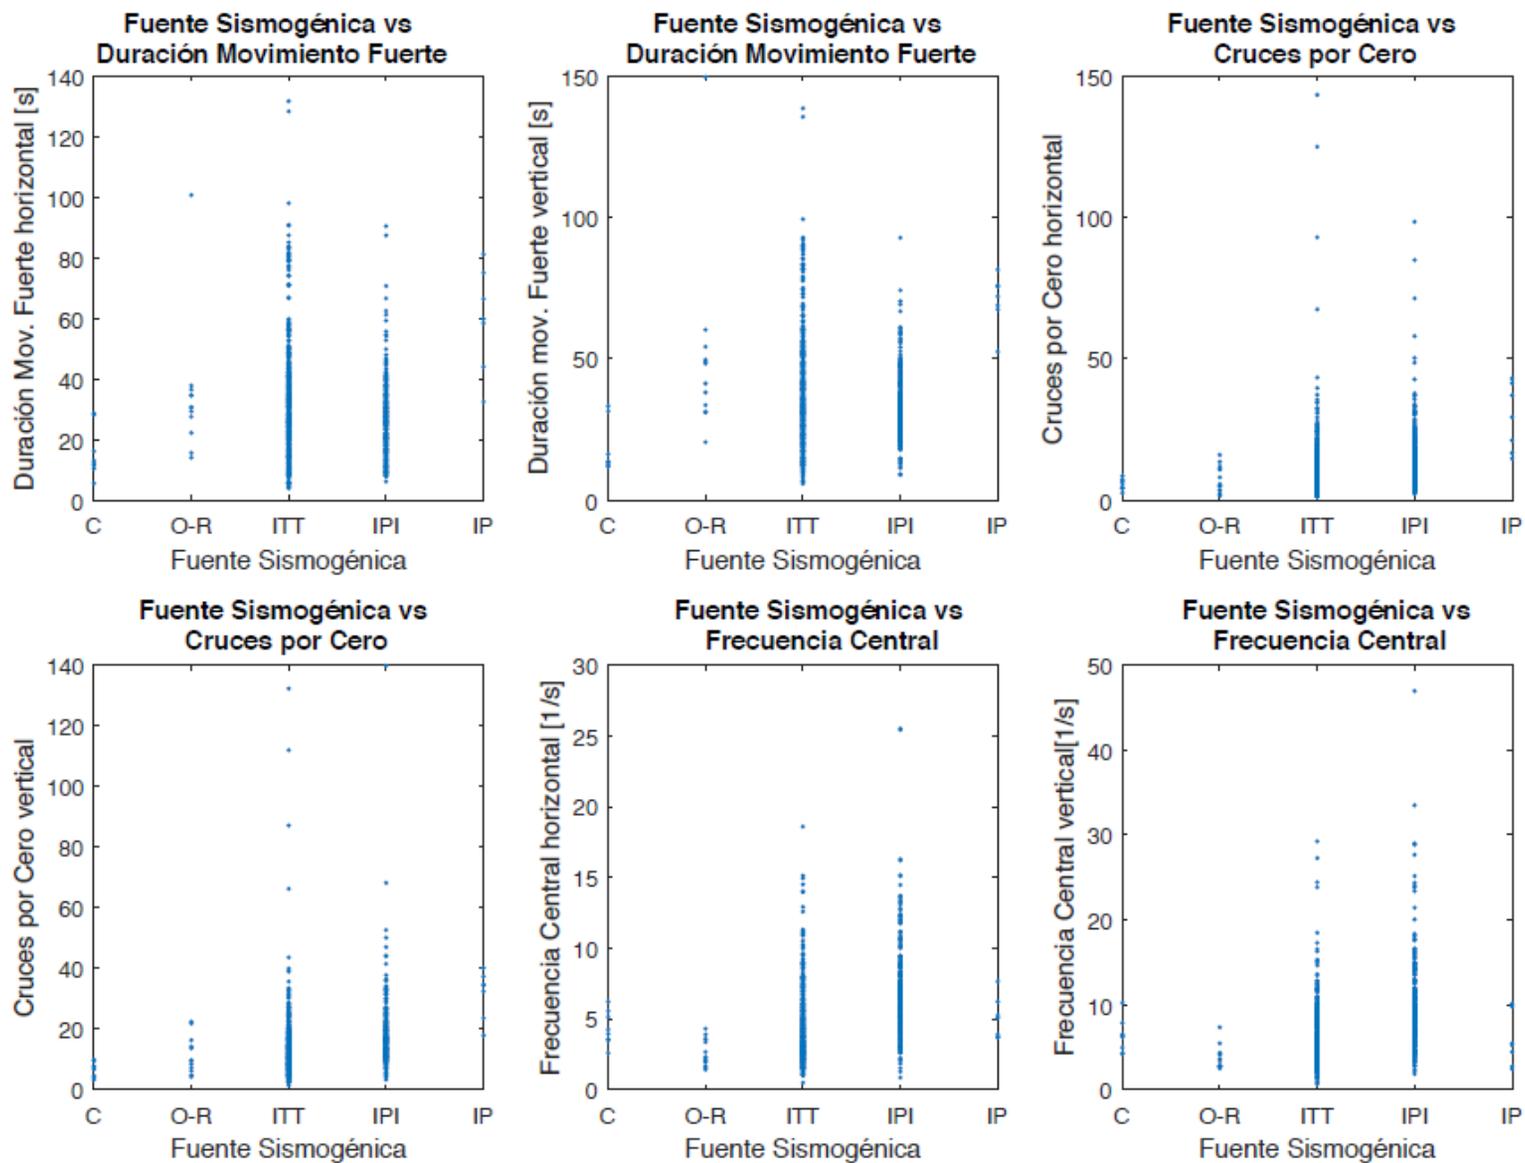


Figura C. 3: Relación entre Fuente Sismogénica y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.

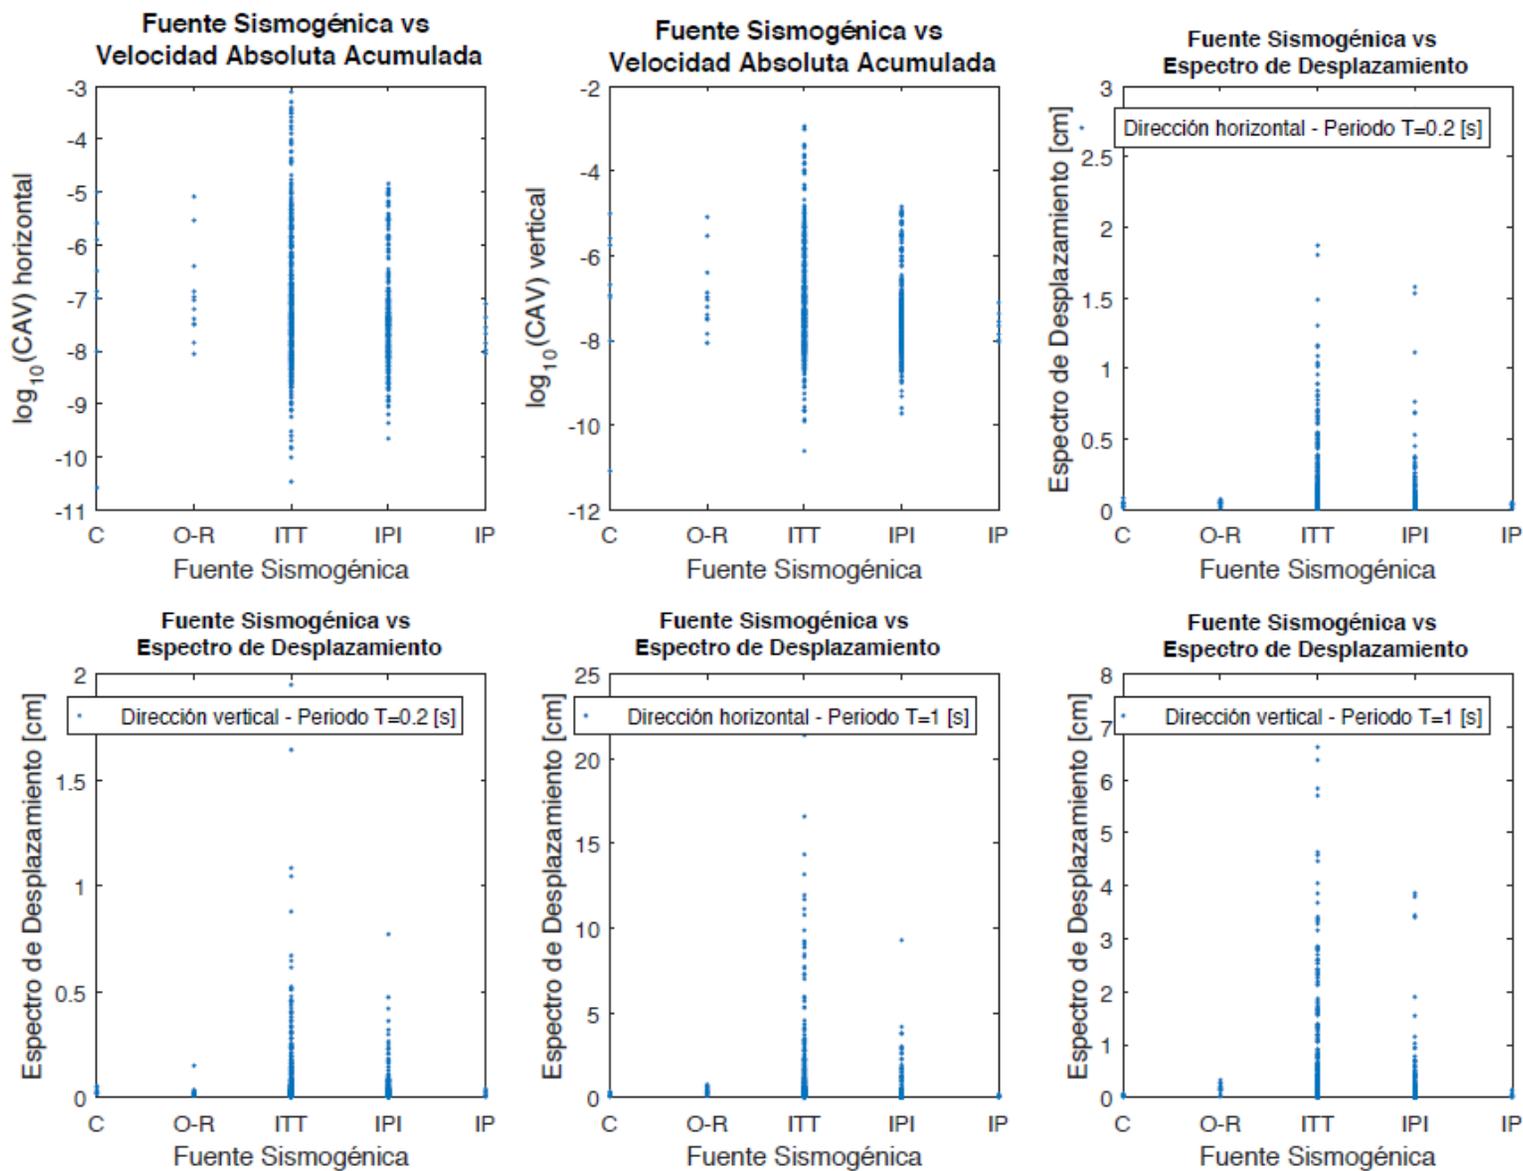


Figura C. 4: Relación entre Fuente Sismogénica y (a) $\log(\text{CAV})$ Horizontal, (b) $\log(\text{CAV})$ Vertical, (c) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (d) Espectro de Desplazamiento Vertical $T=0.2$ [s], (e) Espectro de Desplazamiento Horizontal $T=1$ [s], (f) Espectro de Desplazamiento Vertical $T=1$ [s].

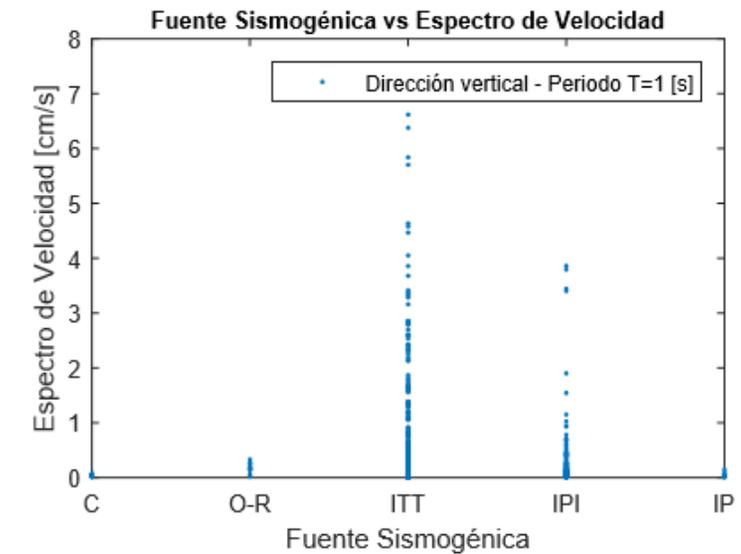
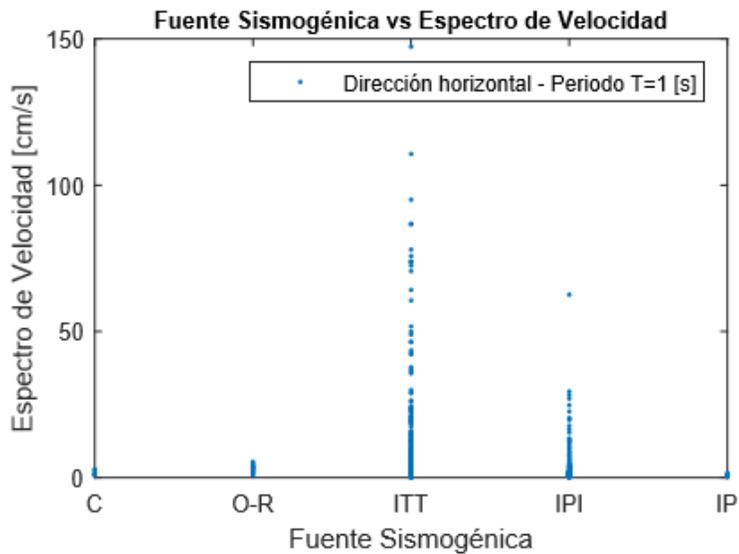
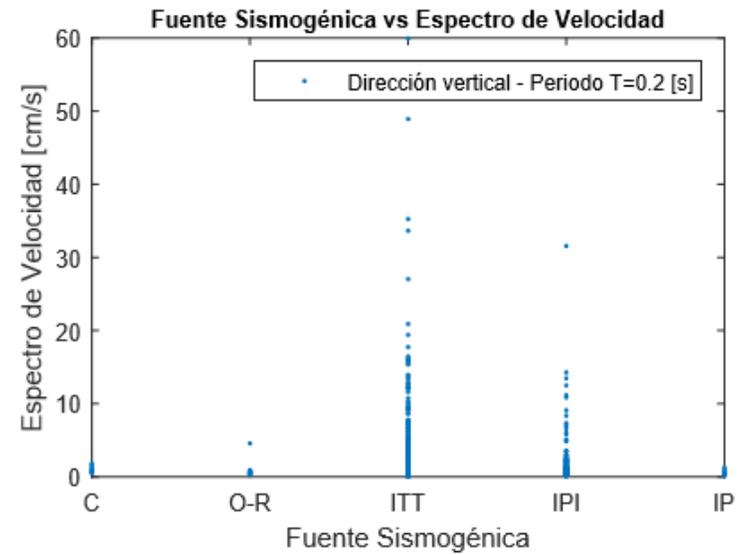
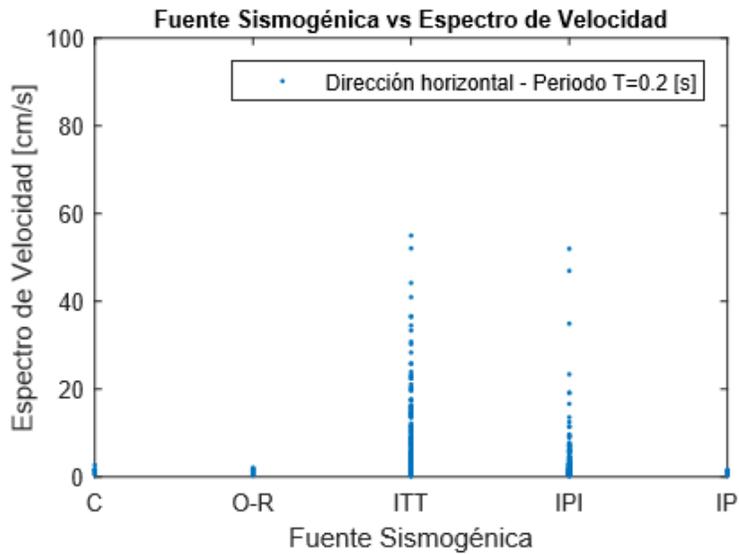


Figura C. 5: Relación entre Fuente Sismogénica y (a) Espectro de Velocidad Horizontal $T=0.2$ [s], (b) Espectro de Velocidad Vertical $T=0.2$ [s], (c) Espectro de Velocidad Horizontal $T=1$ [s], (d) Espectro de Velocidad Vertical $T=1$ [s].

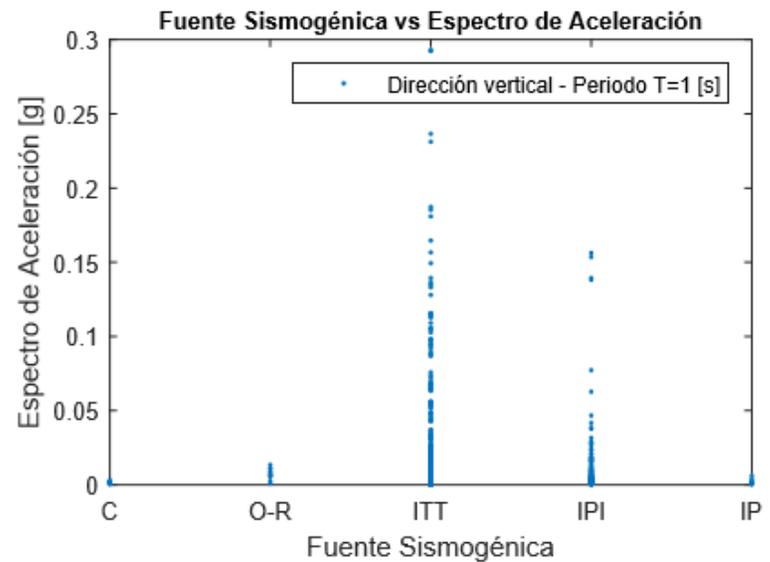
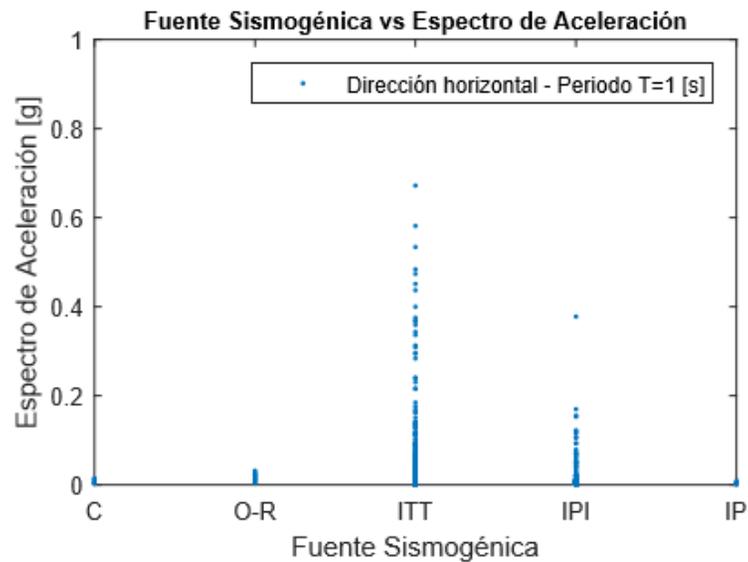
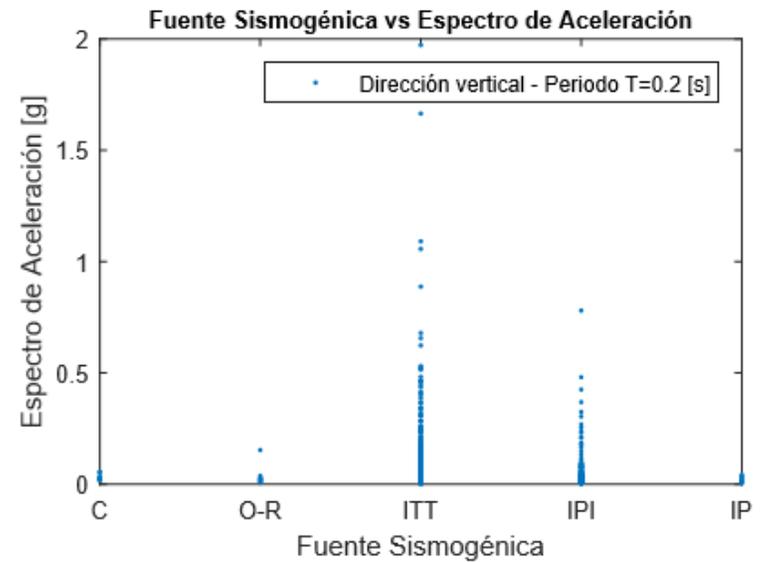
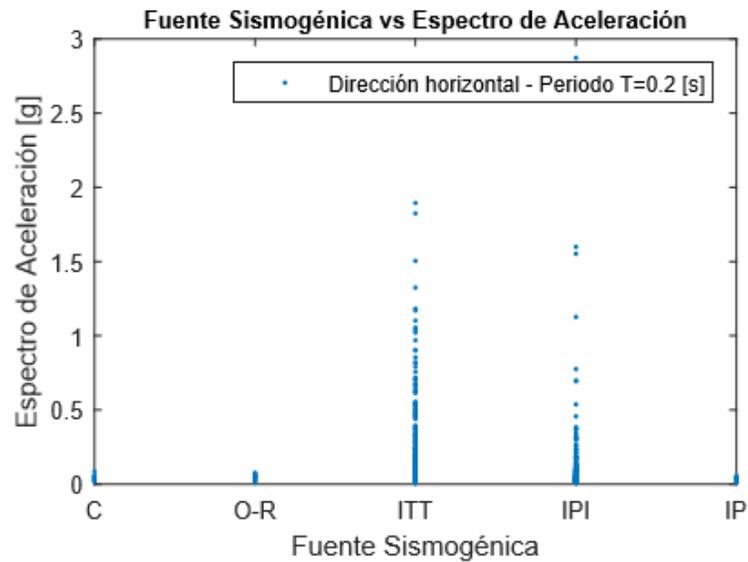


Figura C. 6: Relación entre Fuente Sismogénica y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].

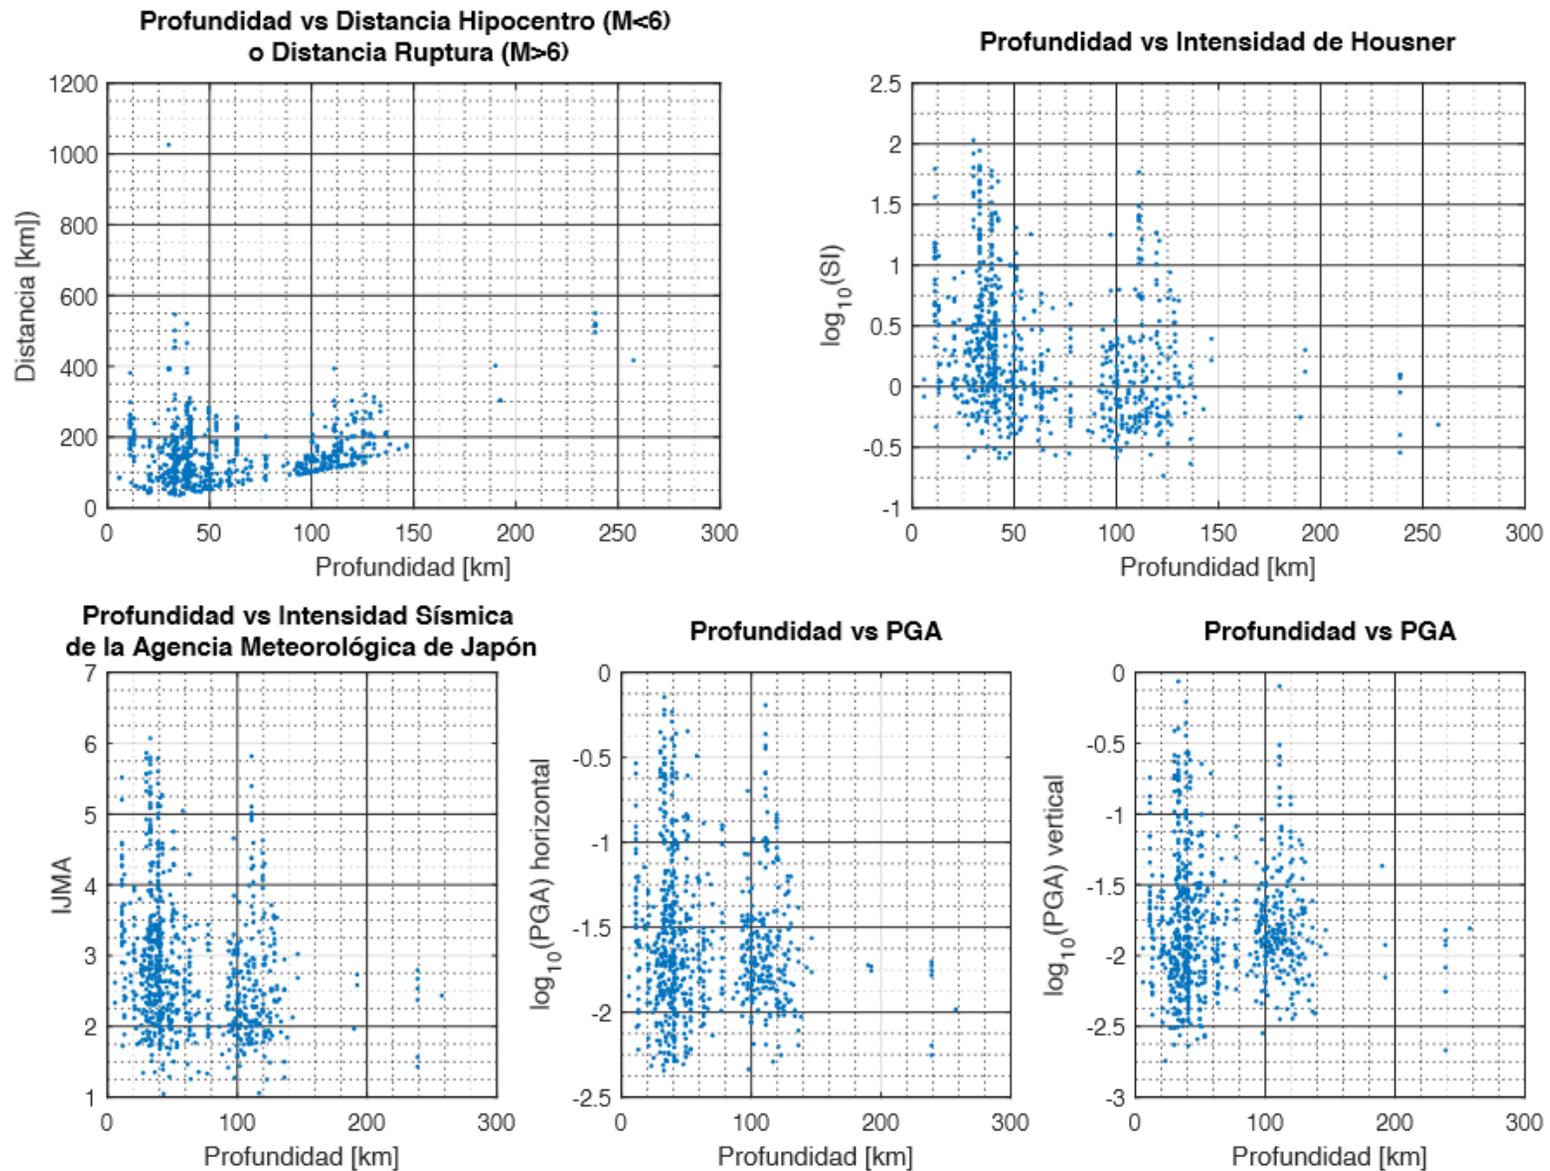


Figura C. 7: Relación entre Profundidad y (a) Distancia Hipocentro o Ruptura, (b) Intensidad de Housner, (c) IJMA, (d) $\log(\text{PGA})$ horizontal, (e) $\log(\text{PGA})$ vertical.

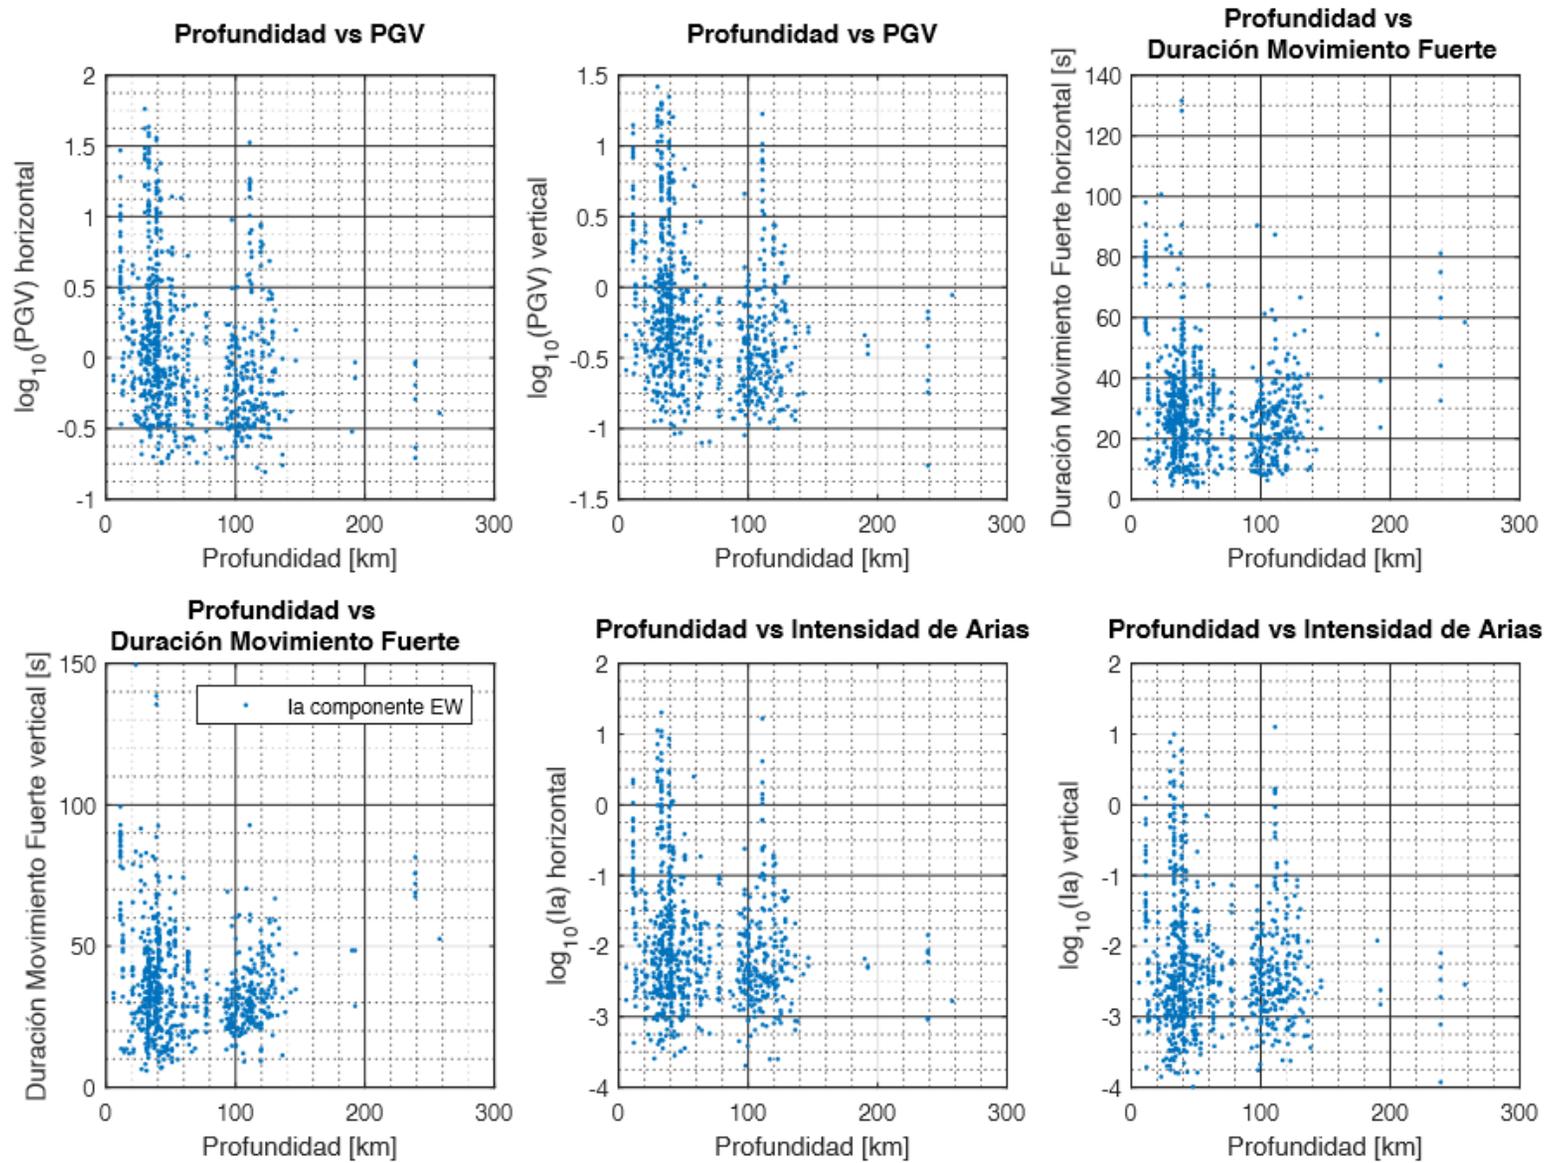


Figura C. 8: Relación entre Profundidad y (a) $\log(\text{PGV})$ horizontal, (b) $\log(\text{PGV})$ vertical, (c) Duración Mov. Fuerte horizontal, (d) Duración Mov. Fuerte Vertical, (e) $\log(\text{Ia})$ horizontal, (f) $\log(\text{Ia})$ vertical.

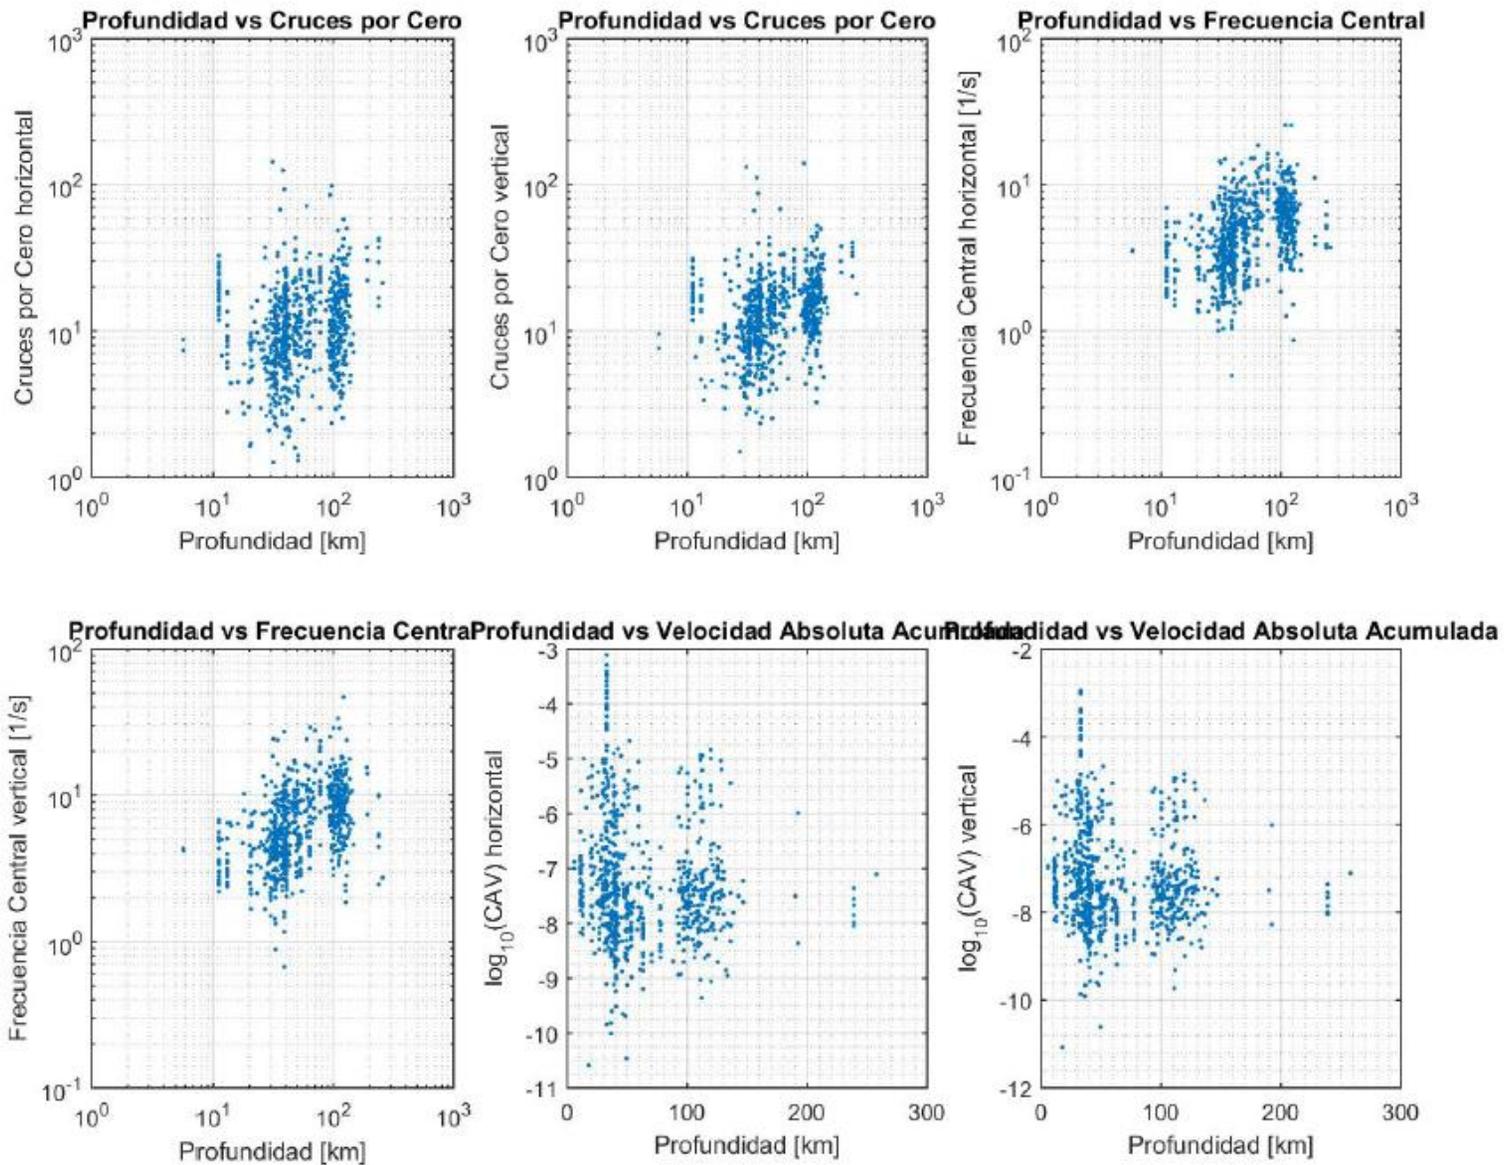


Figura C. 9: Relación entre Profundidad y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical, (e) $\log(\text{CAV})$ Horizontal, (f) $\log(\text{CAV})$ Vertical.

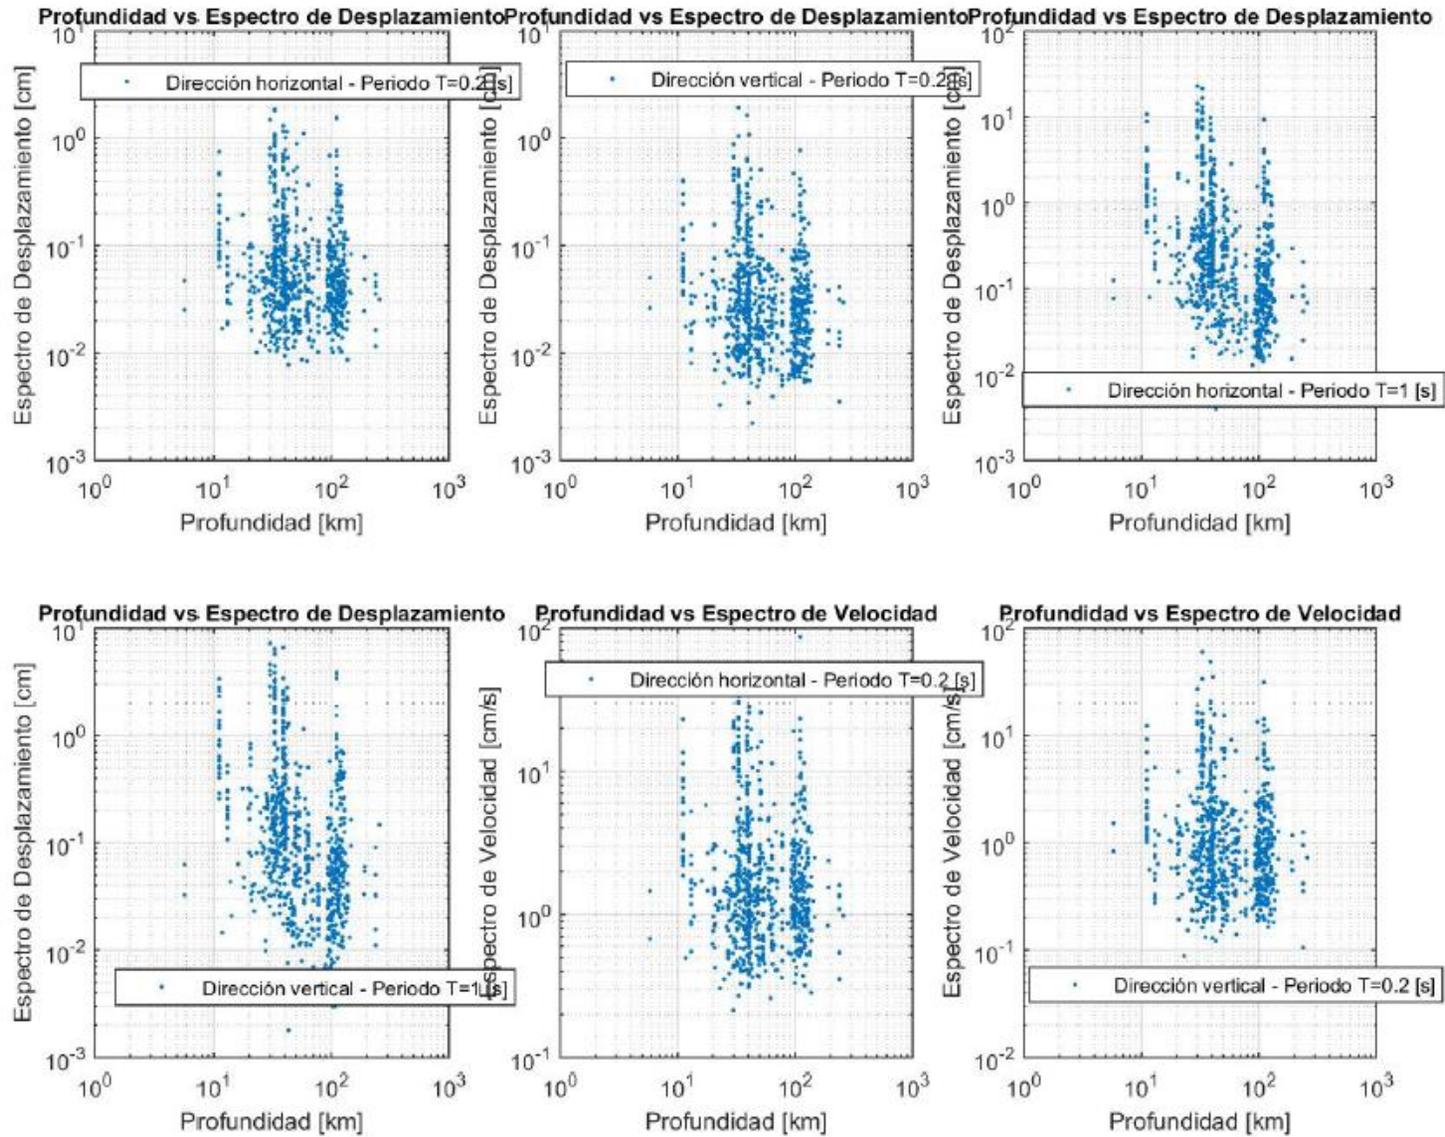


Figura C. 10: Relación entre Profundidad y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].

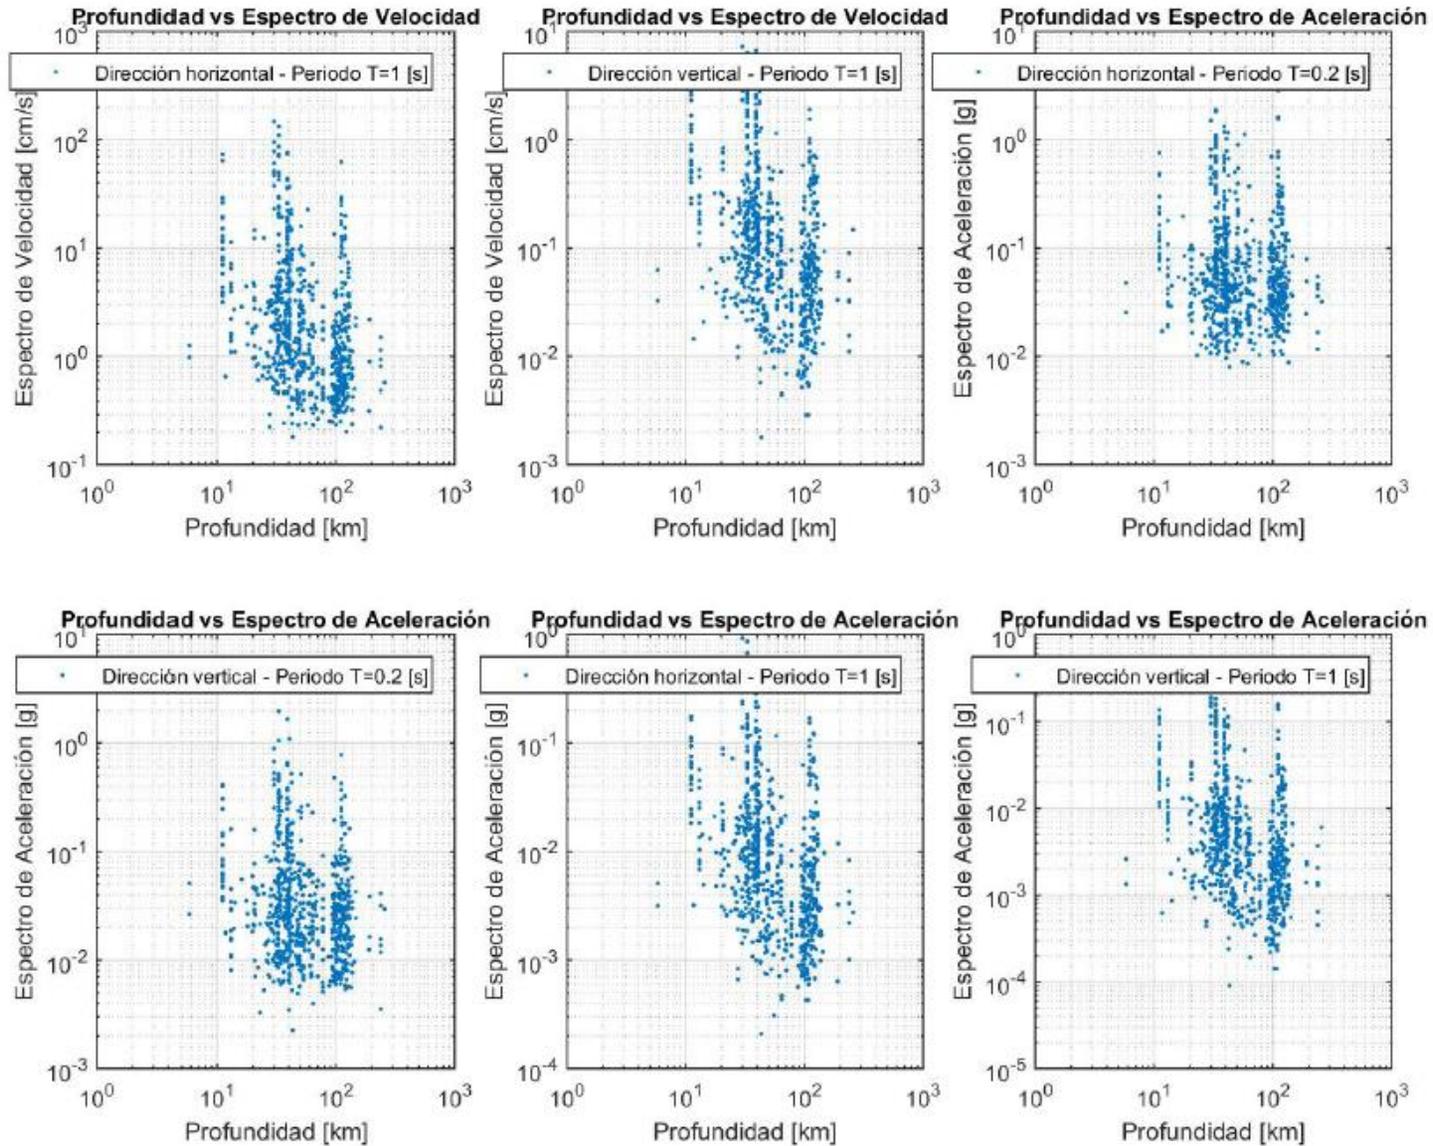


Figura C. 11: Relación entre Profundidad y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

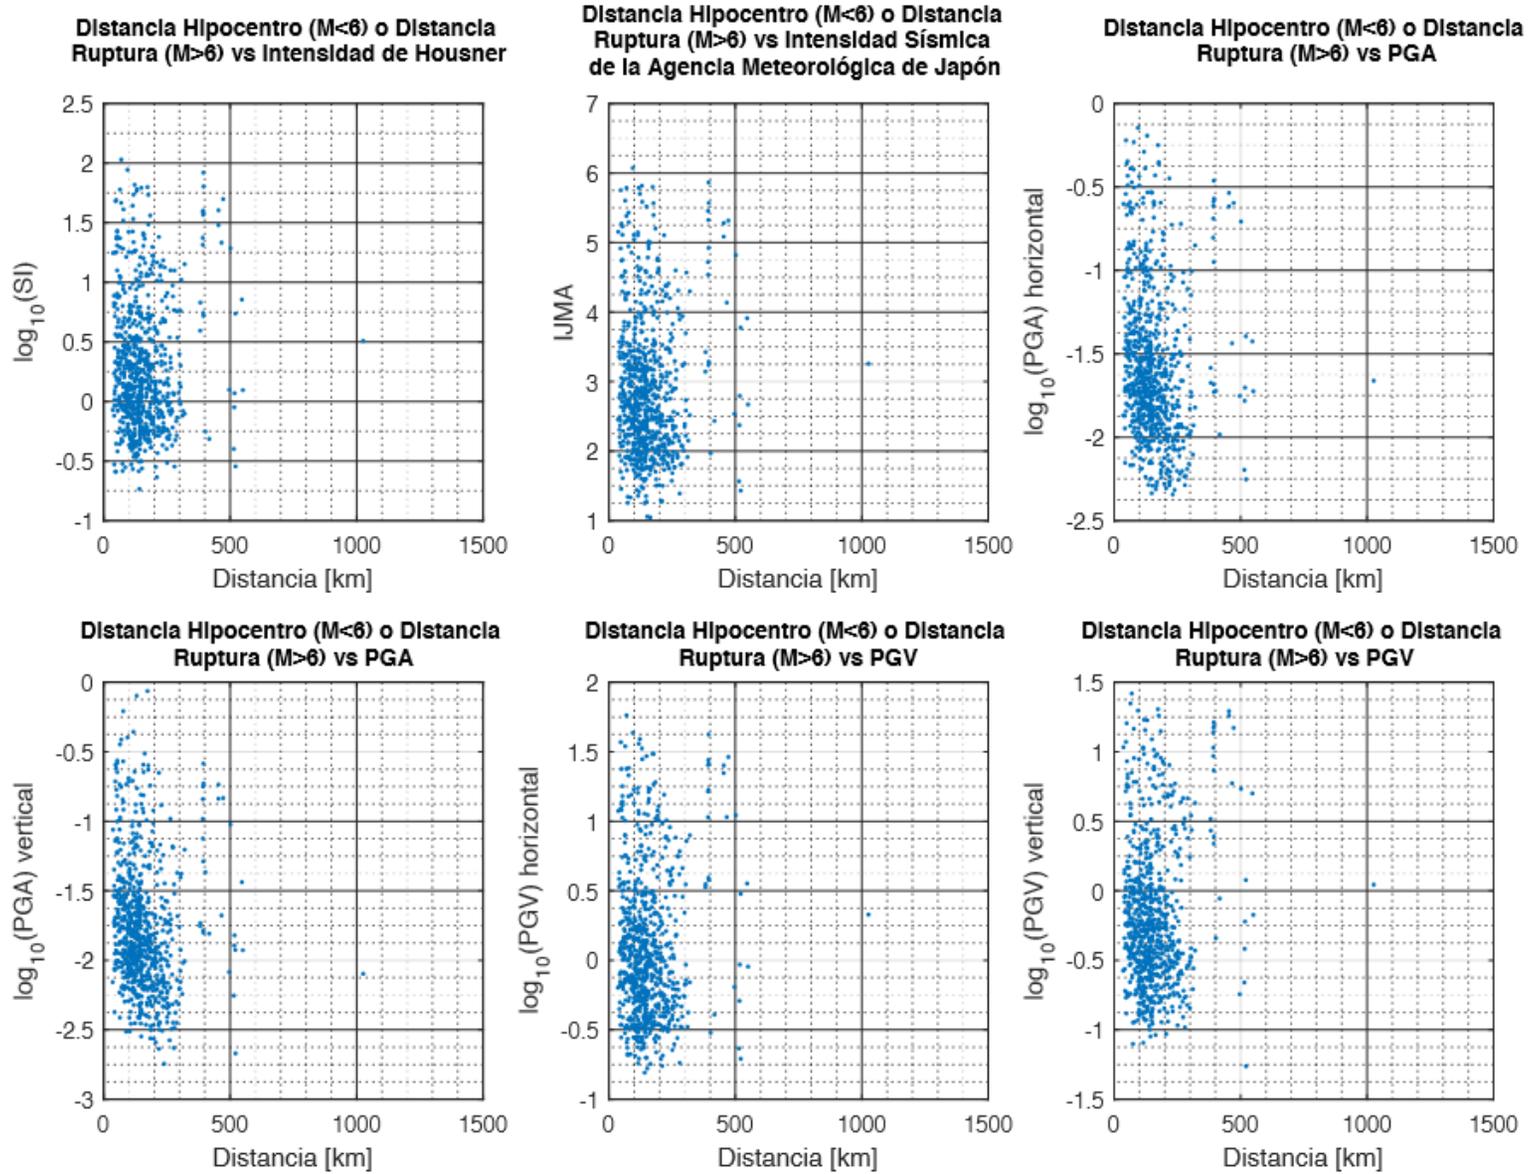


Figura C. 12: Relación entre Distancia Hipocentro o Ruptura y (a) $\log(SI)$, (b) IJMA, (c) $\log(PGA)$ Horizontal, (d) $\log(PGA)$ Vertical, (e) $\log(PGV)$ Horizontal, (f) $\log(PGV)$ Vertical.

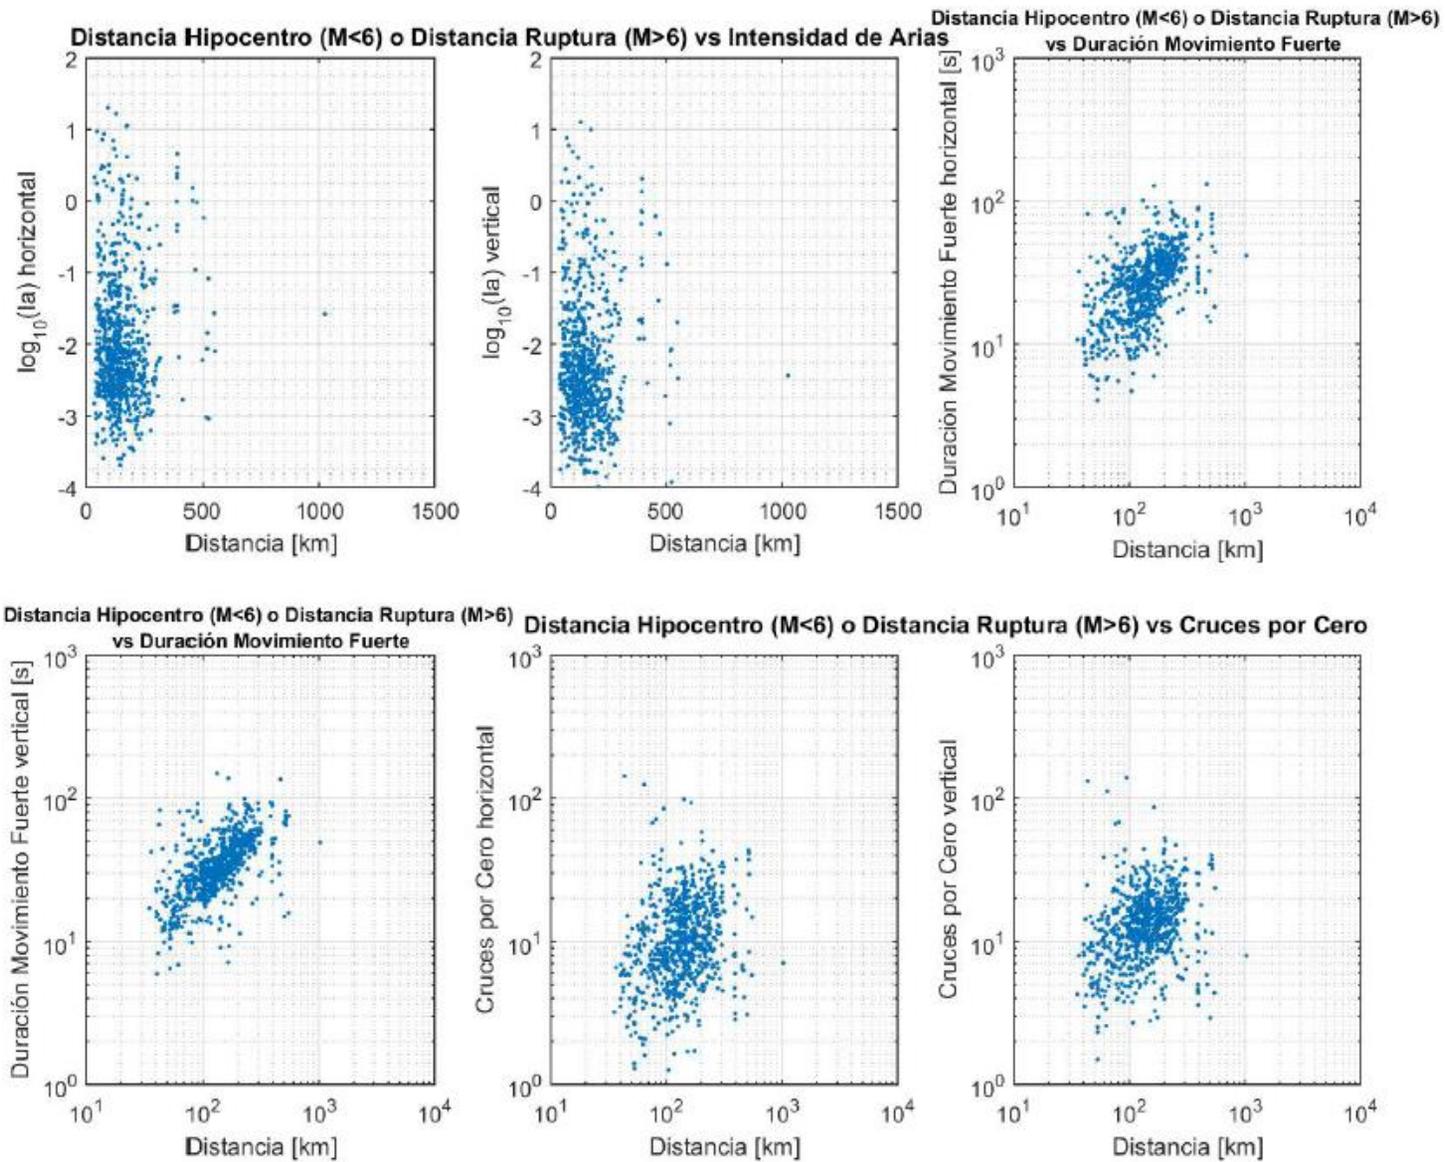


Figura C. 13: Relación entre Distancia Hipocentro o Ruptura y (a) $\log(I_a)$ Horizontal, (b) $\log(I_a)$ Vertical, (c) Duración Mov. Fuerte Horizontal, (d) Duración Mov. Fuerte Vertical, (e) Cruces por Cero Horizontal, (f) Cruces por Cero Vertical.

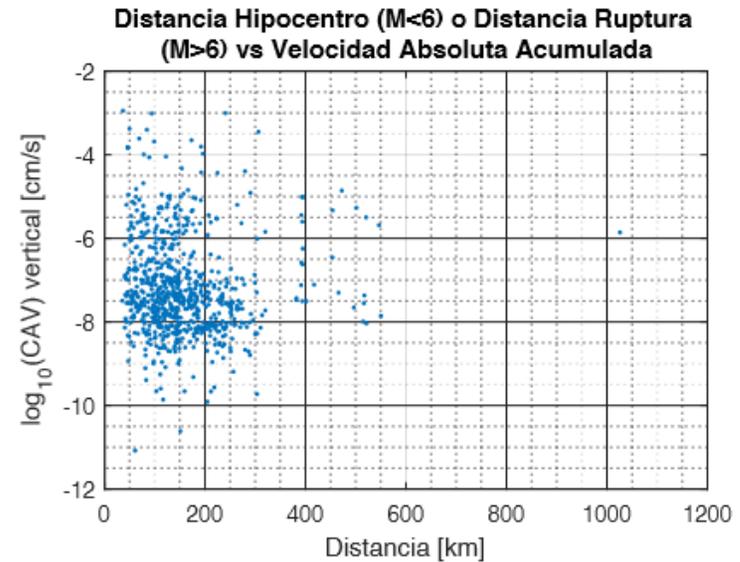
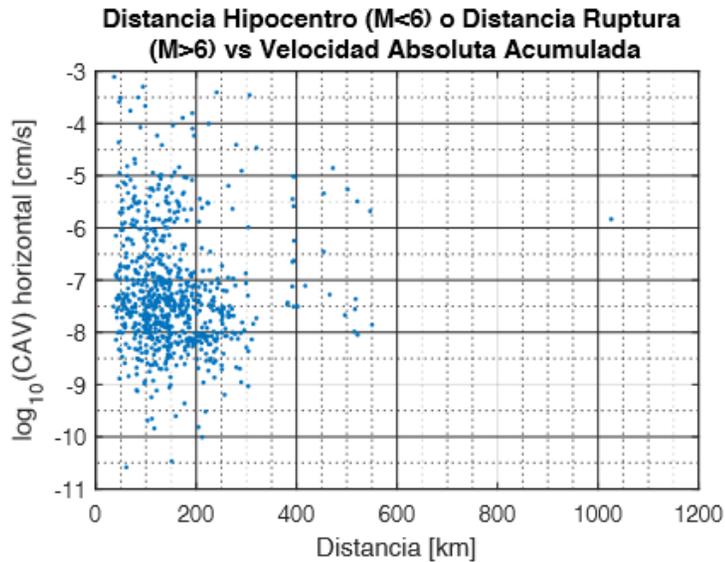
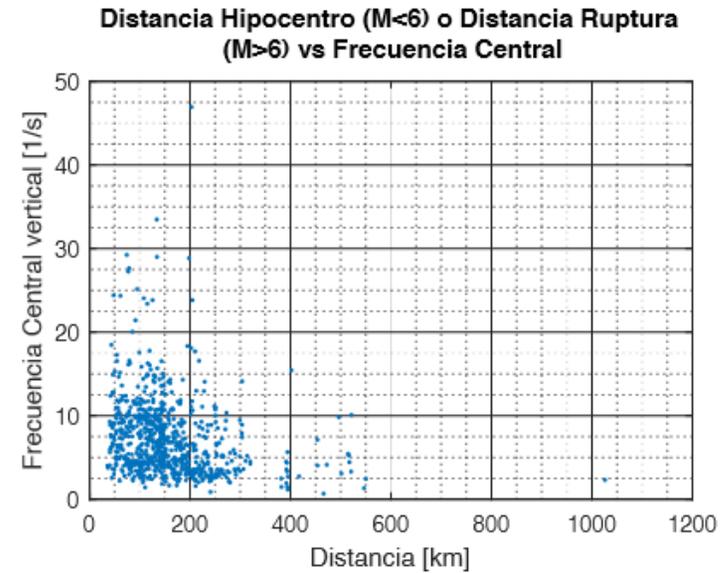
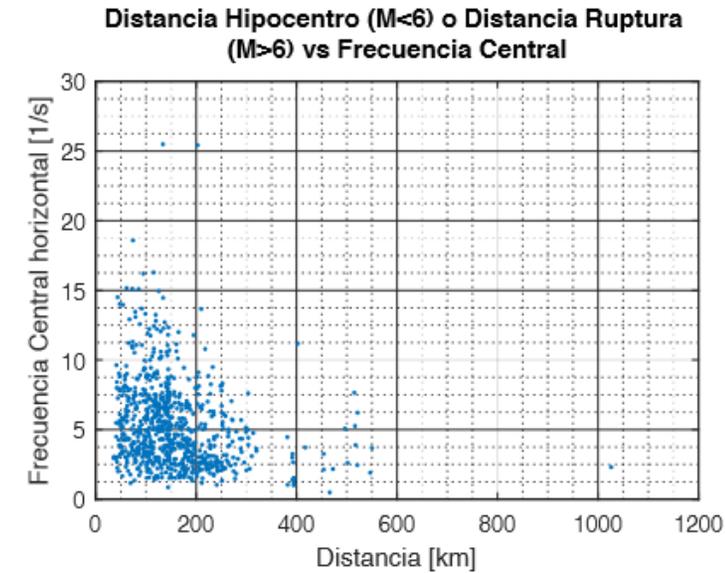


Figura C. 14: Relación entre Distancia Hipocentro o Ruptura y (a) Frecuencia Central Horizontal, (b) Frecuencia Central Vertical, (c) $\log(\text{CAV})$ Horizontal, (d) $\log(\text{CAV})$ Vertical.

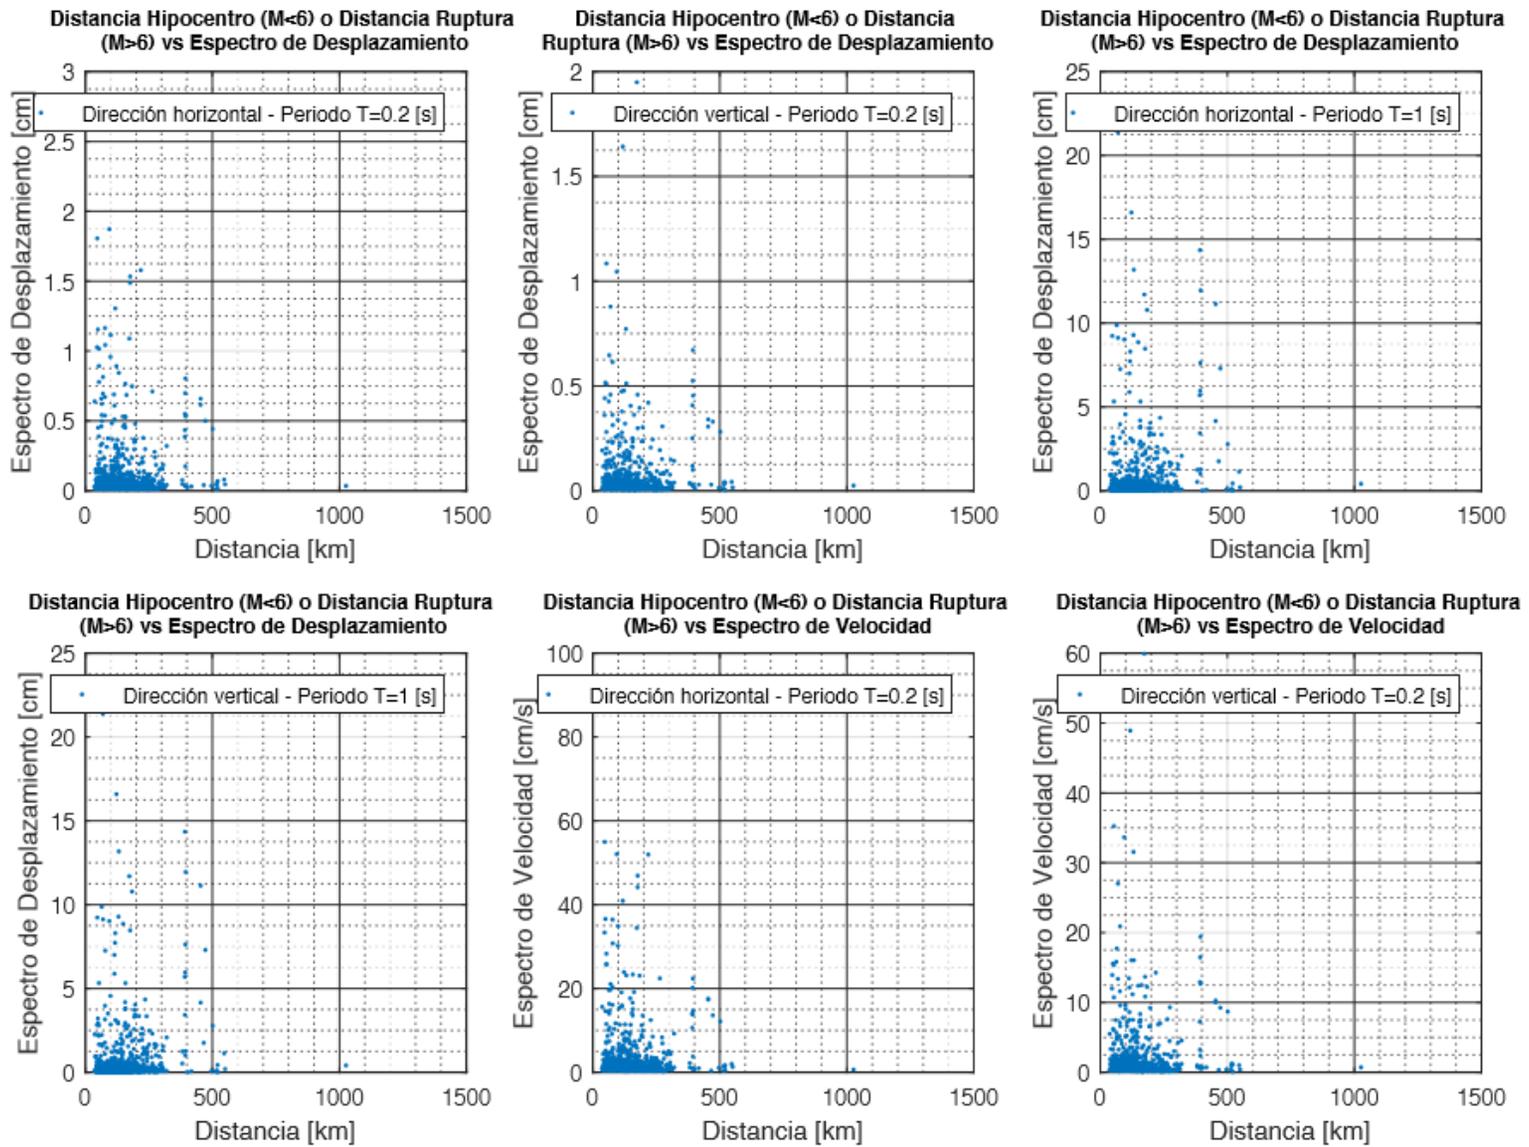


Figura C. 15: Relación entre Distancia Hipocentro o Ruptura y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s].

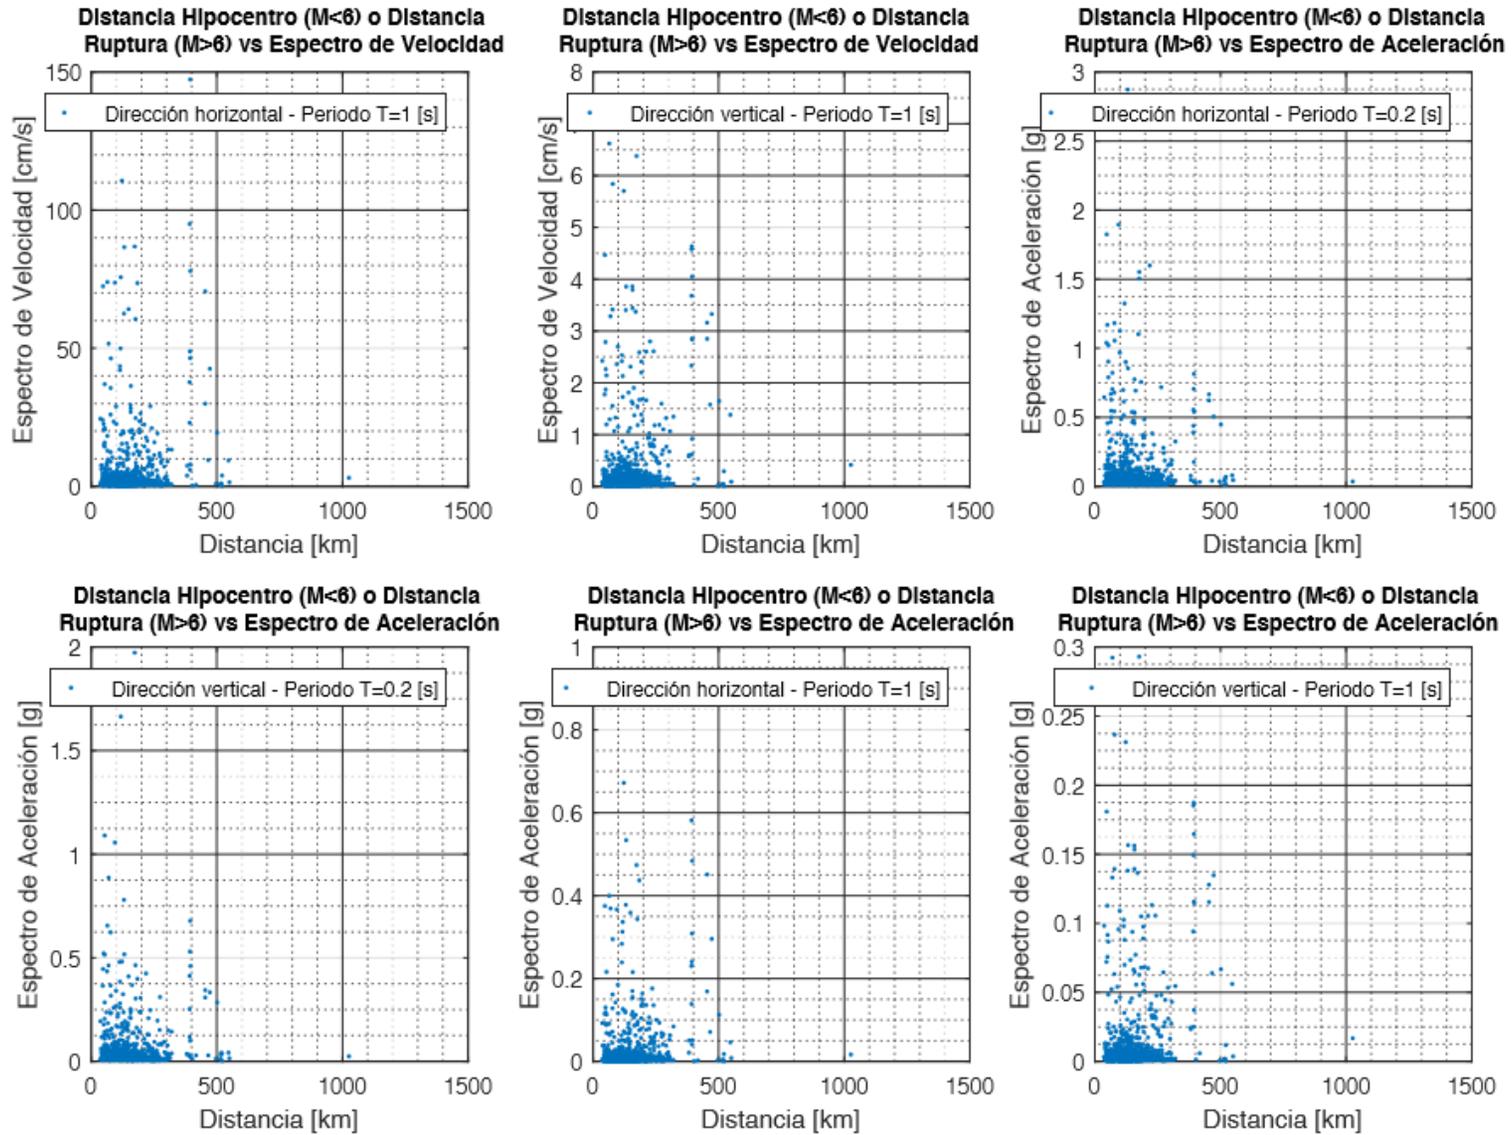


Figura C. 16: Relación entre Distancia Hipocentro o Ruptura y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

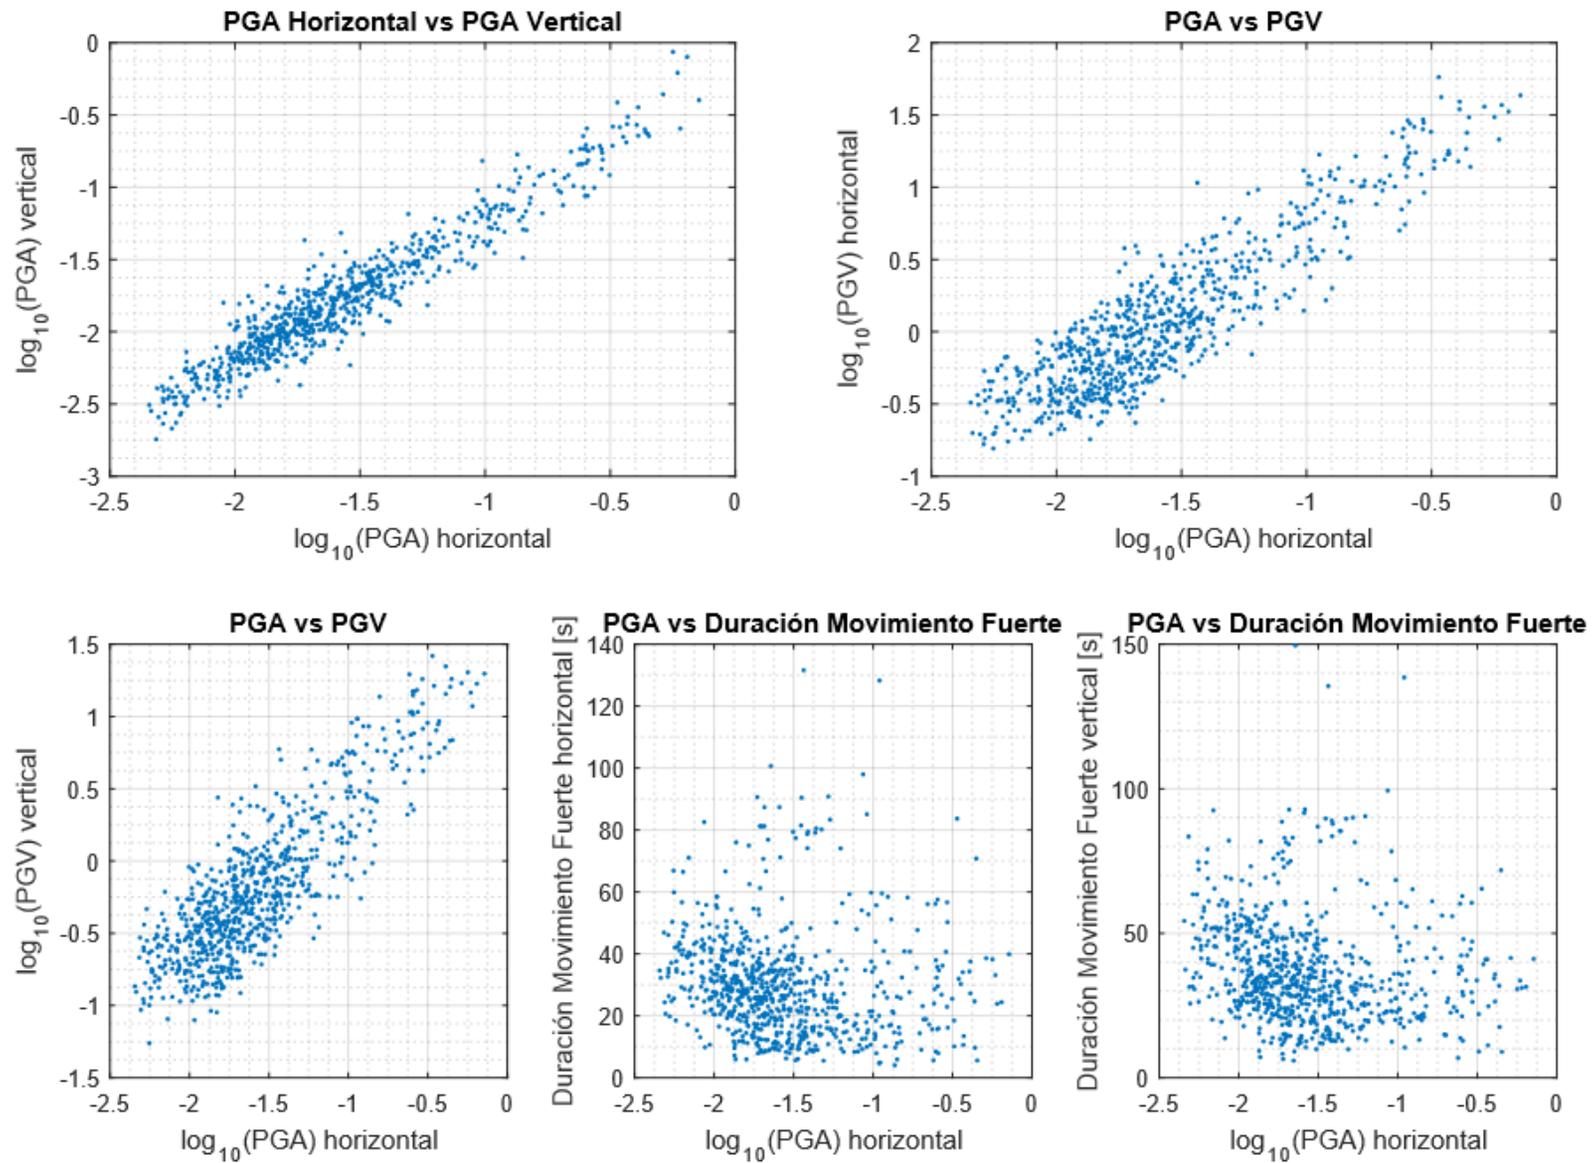


Figura C. 17: Relación entre $\log(\text{PGA})$ Horizontal y (a) $\log(\text{PGA})$ Vertical, (b) $\log(\text{PGV})$ Horizontal, (c) $\log(\text{PGV})$ Vertical, (d) Duración Mov. Fuerte Horizontal, (e) Duración Mov. Fuerte Vertical.

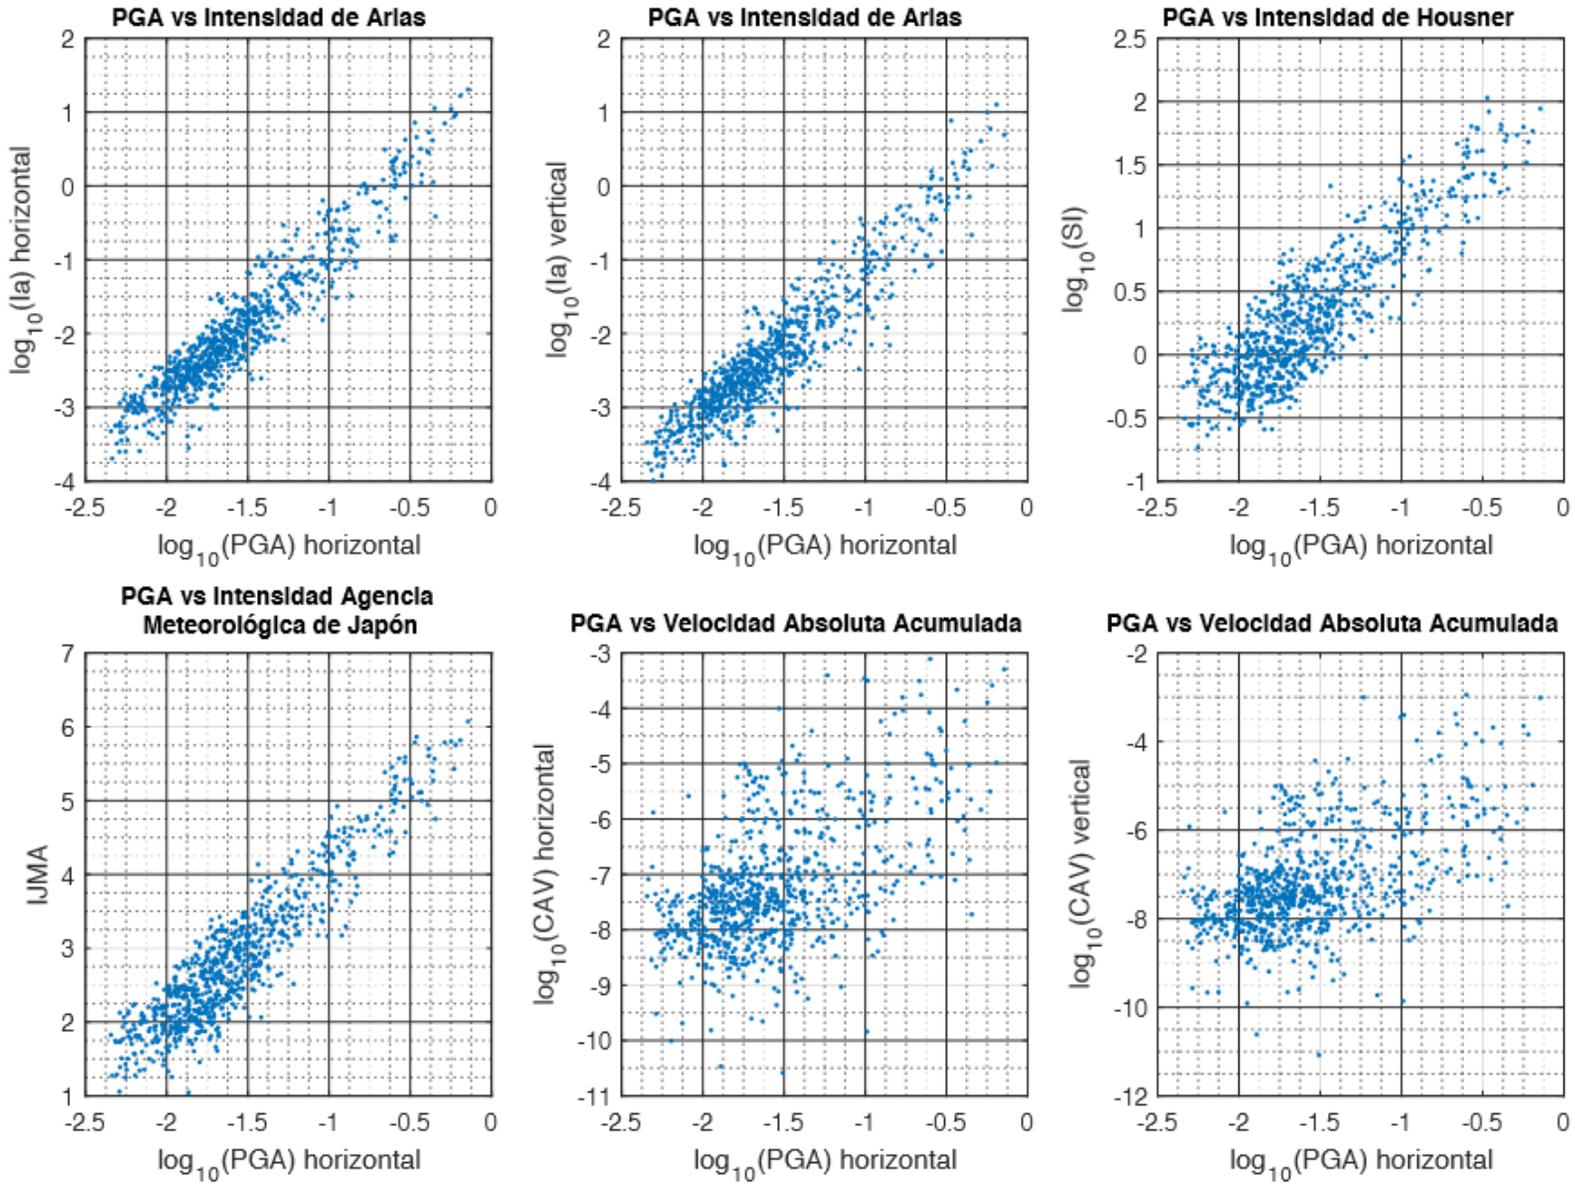


Figura C. 18: Relación entre $\log(\text{PGA})$ Horizontal y (a) $\log(I_a)$ Horizontal, (b) $\log(I_a)$ Vertical, (c) $\log(SI)$, (d) IJMA, (e) $\log(\text{CAV})$ Horizontal, (f) $\log(\text{CAV})$ Vertical

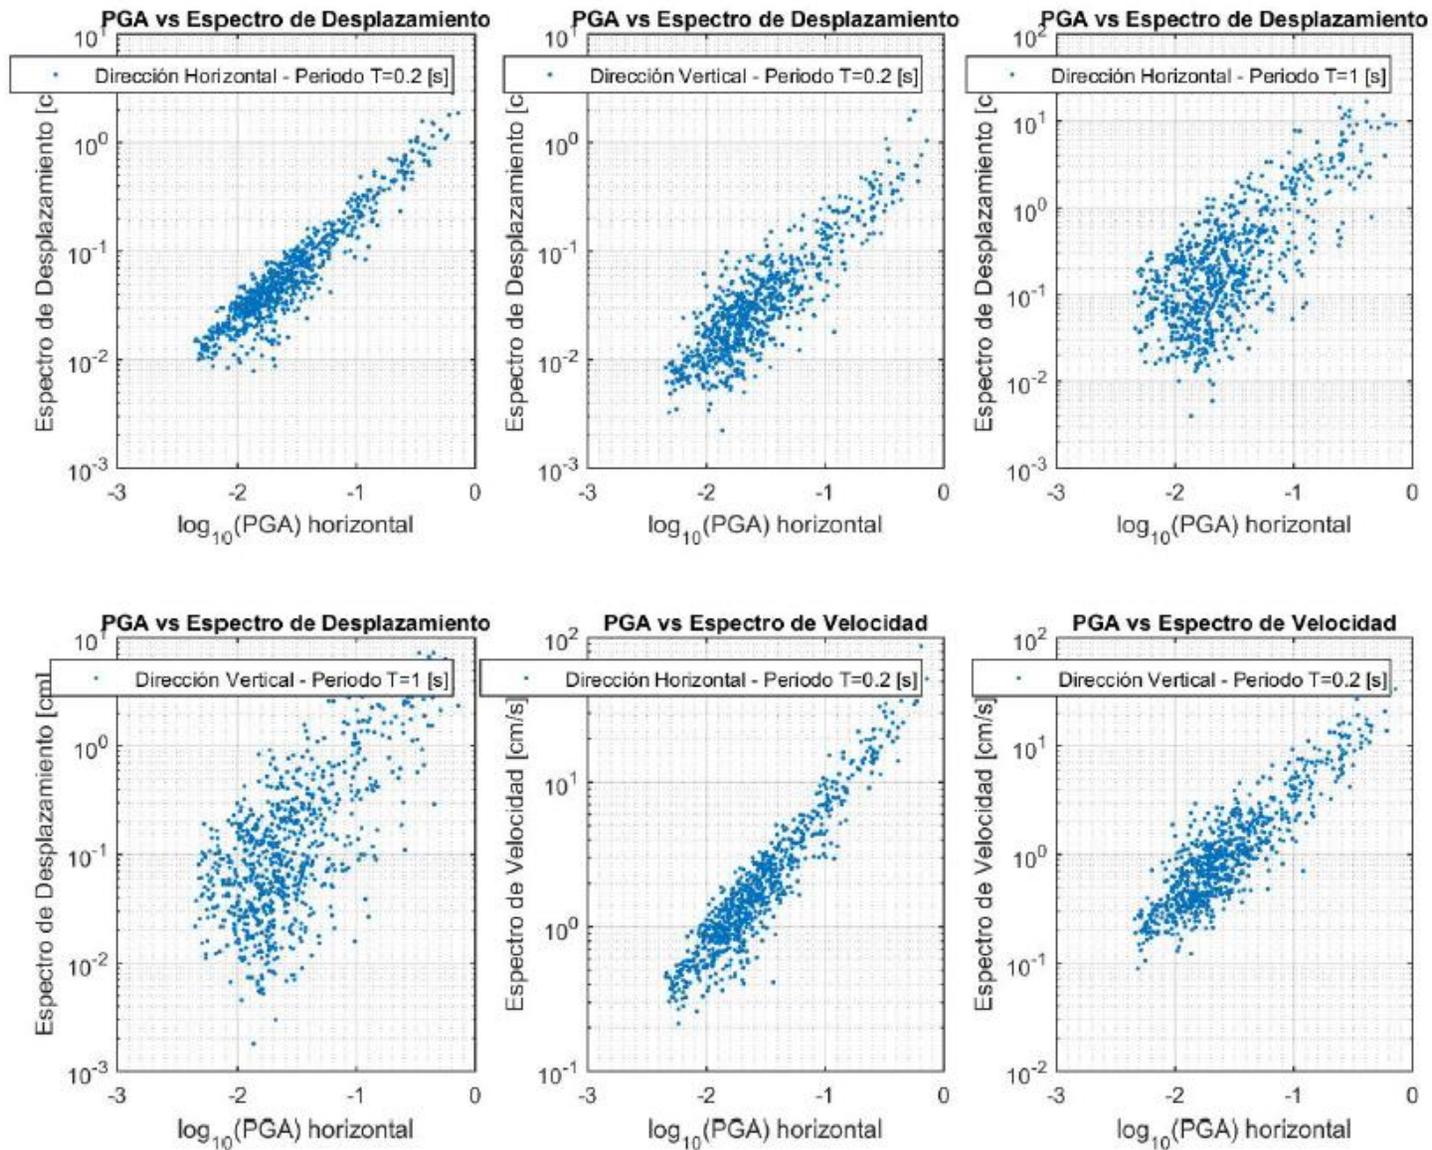


Figura C. 19: Relación entre $\log(\text{PGA})$ Horizontal y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s].

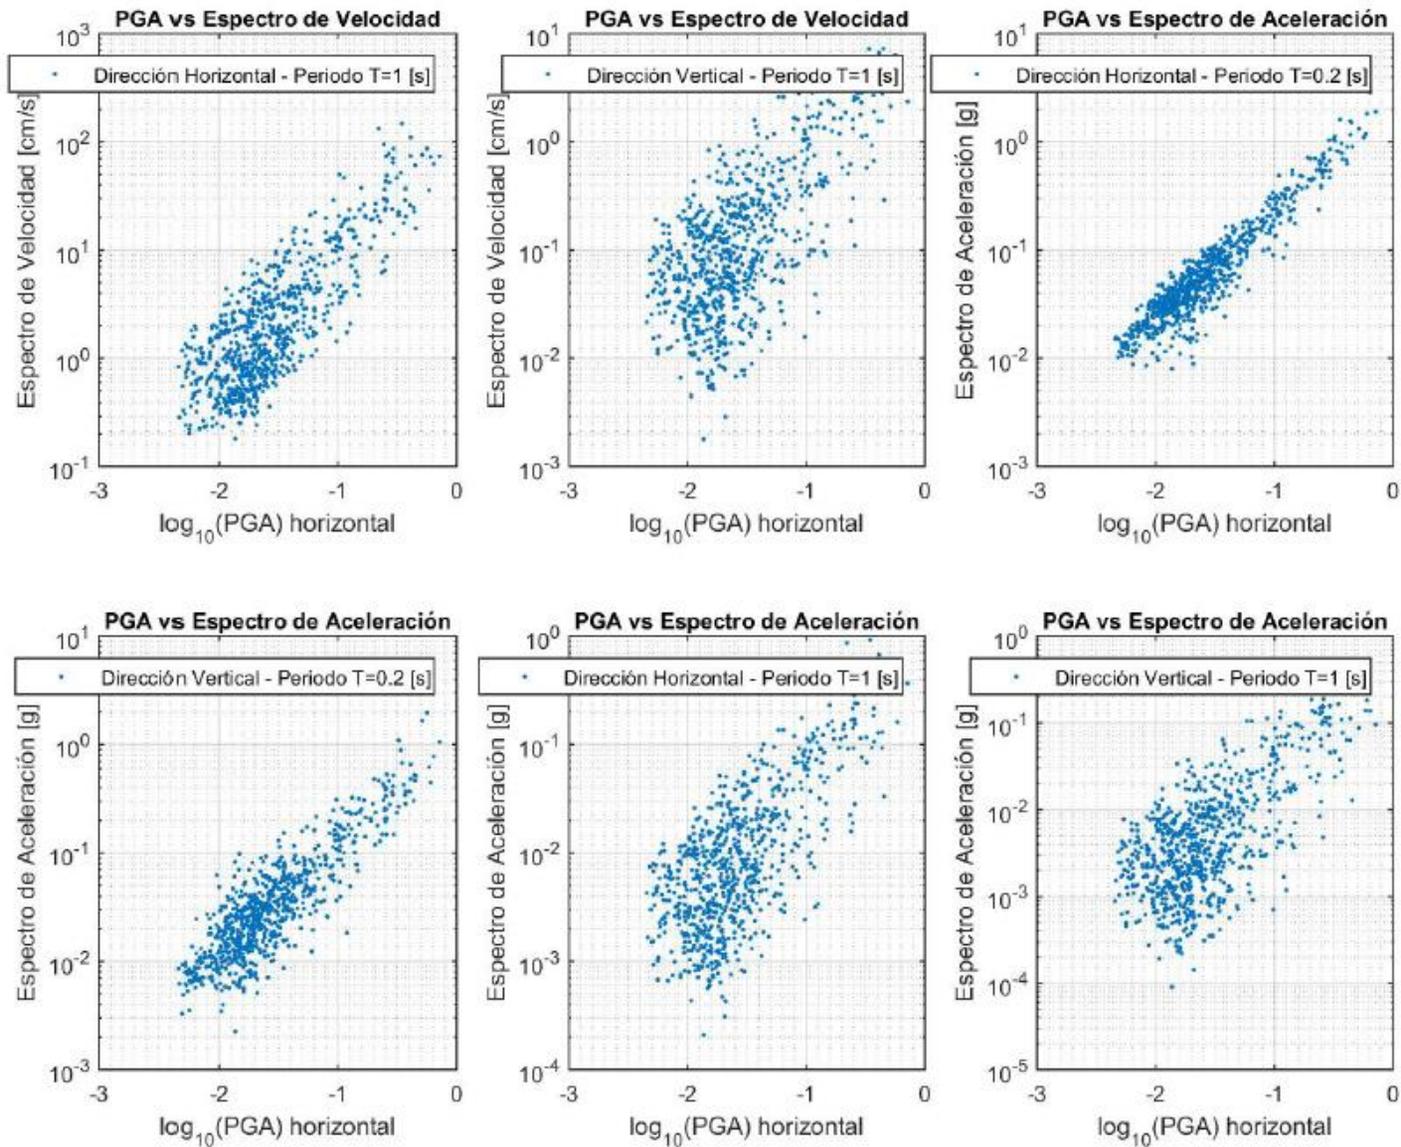


Figura C. 20: Relación entre $\log_{10}(\text{PGA})$ Horizontal y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]

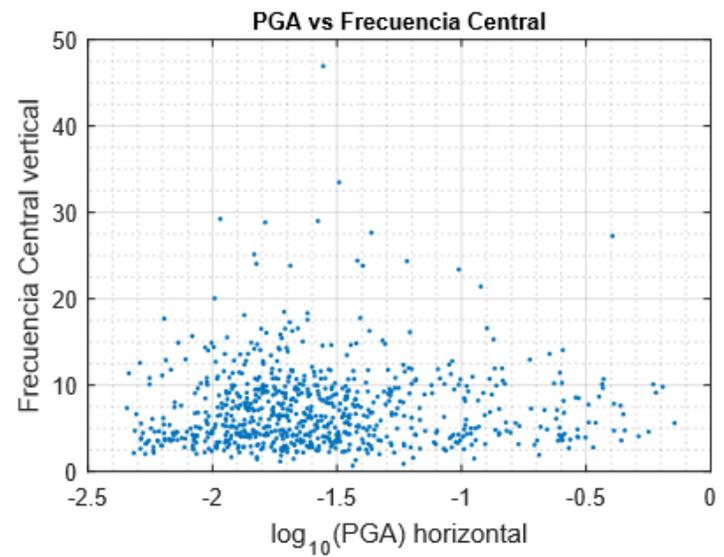
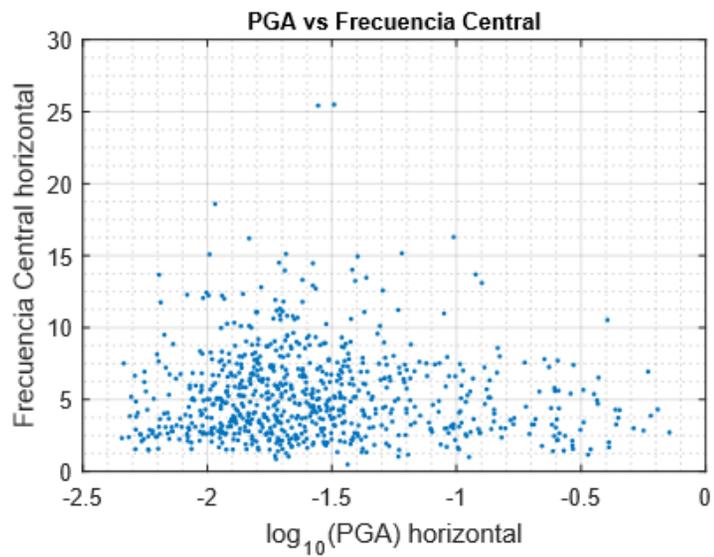
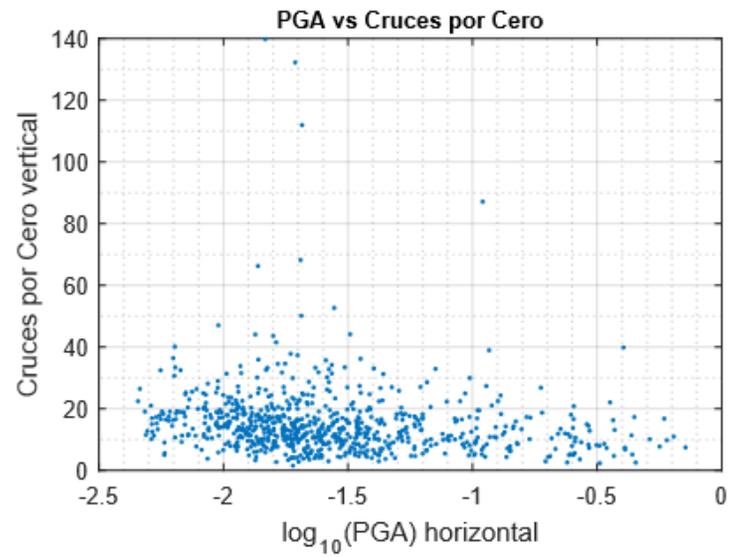
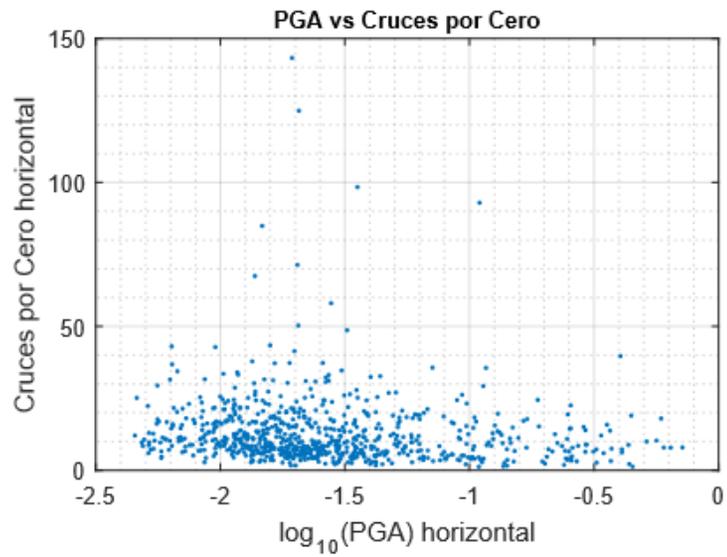


Figura C. 21: Relación entre $\log(\text{PGA})$ Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

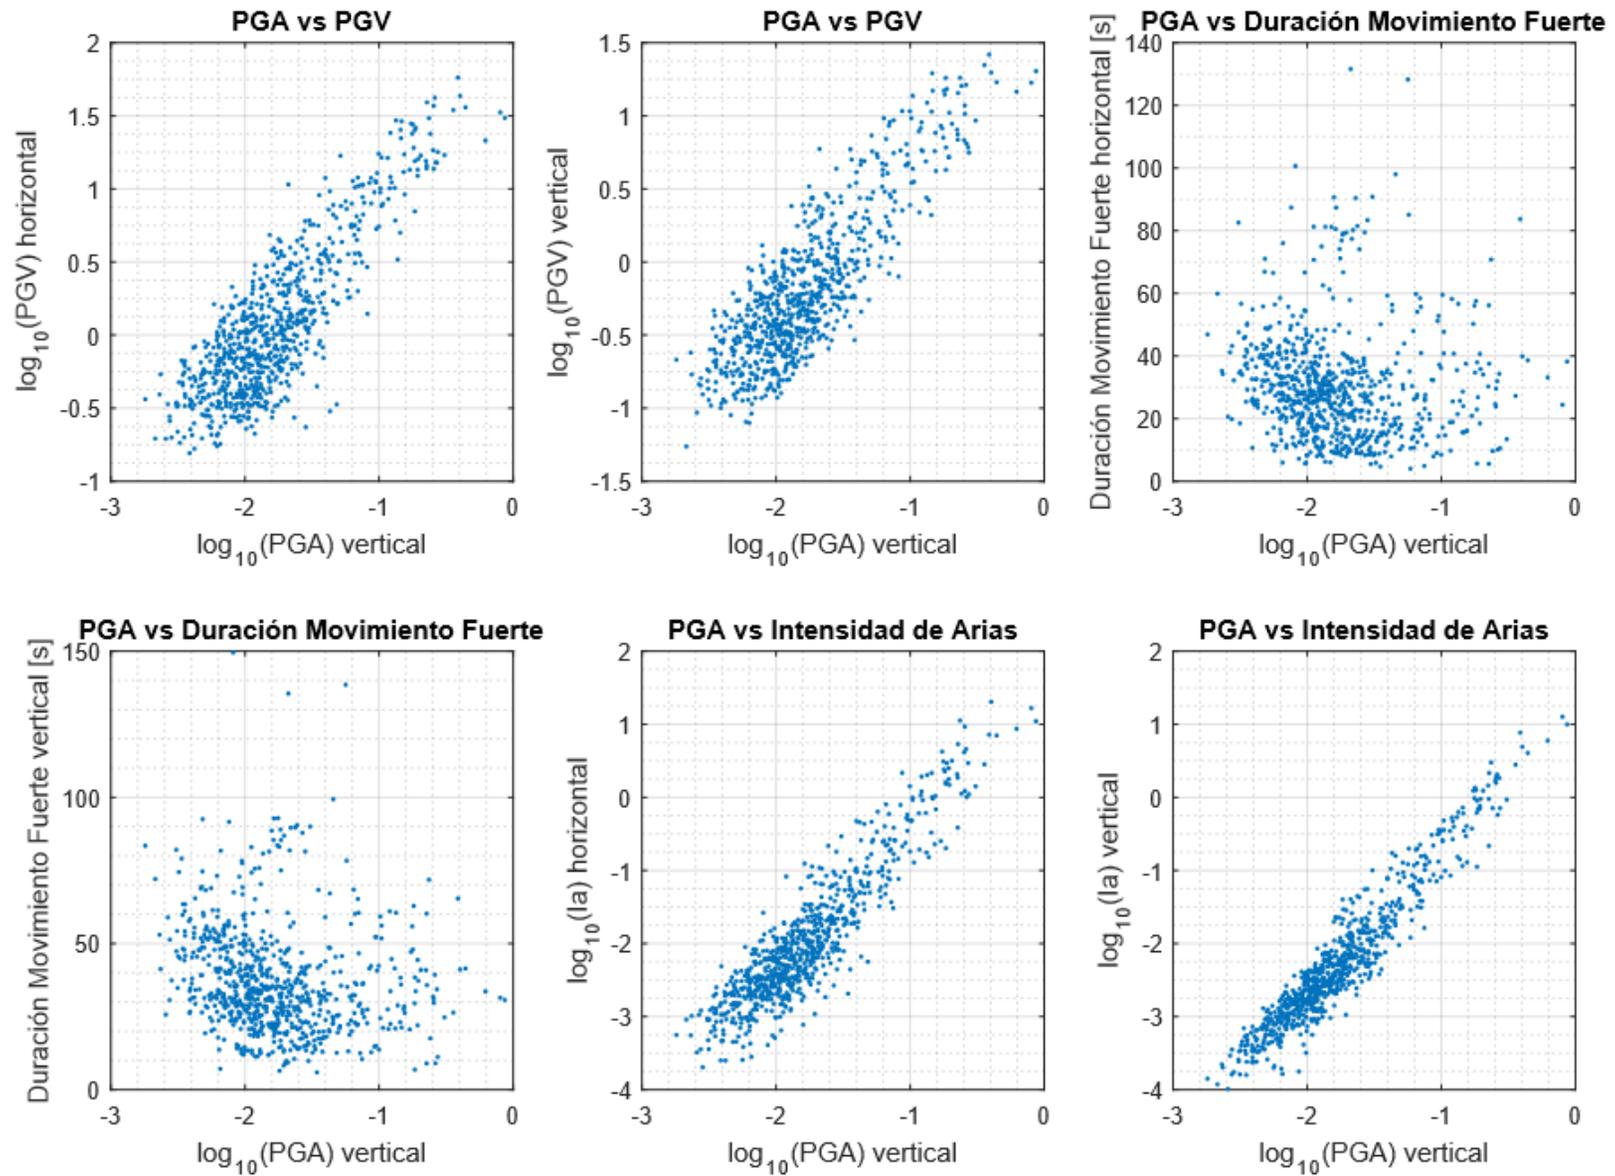


Figura C. 22: Relación entre $\log(\text{PGA})$ Vertical y (a) $\log(\text{PGV})$ Horizontal, (b) $\log(\text{PGV})$ Vertical, (c) Duración Mov. Fuerte Horizontal, (d) Duración Mov. Fuerte Vertical, (e) $\log(I_a)$ Horizontal, (f) $\log(I_a)$ Vertical.

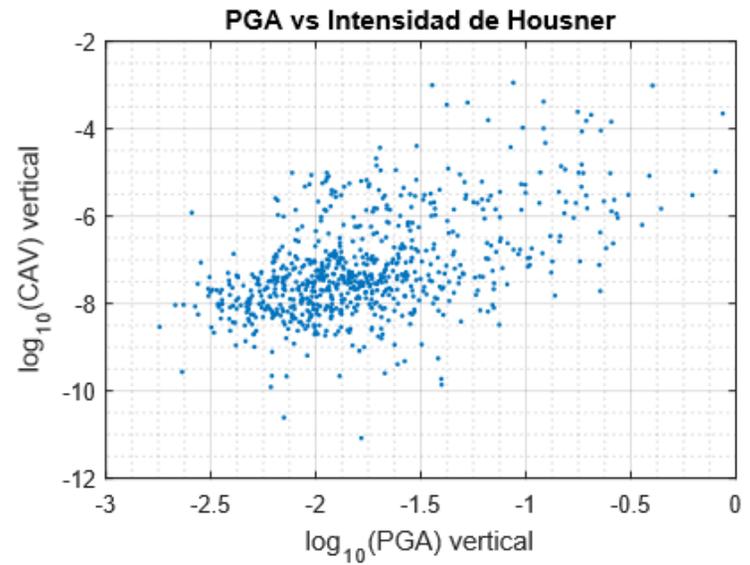
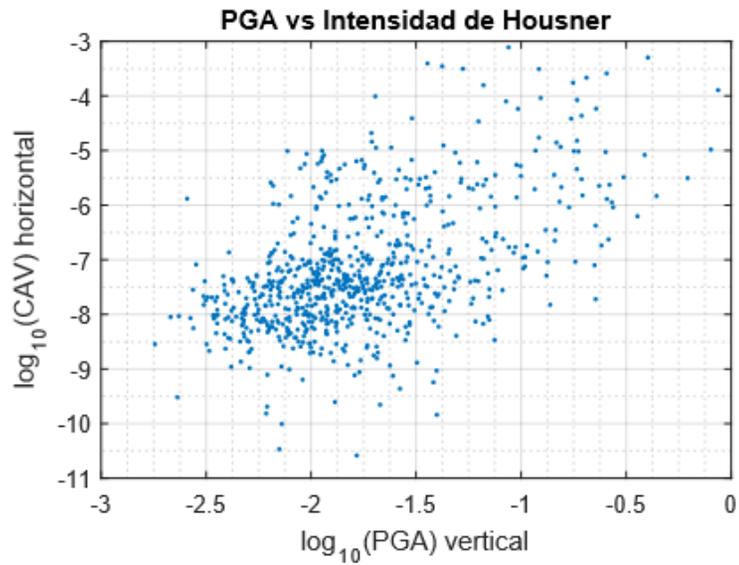
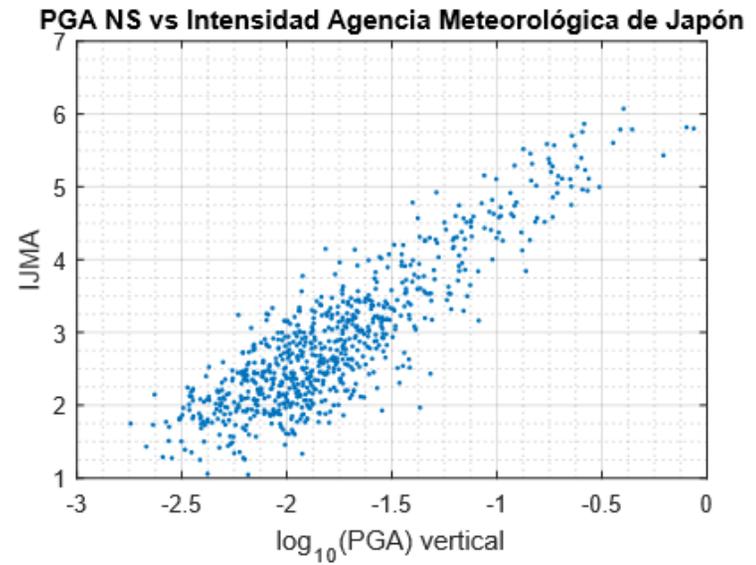
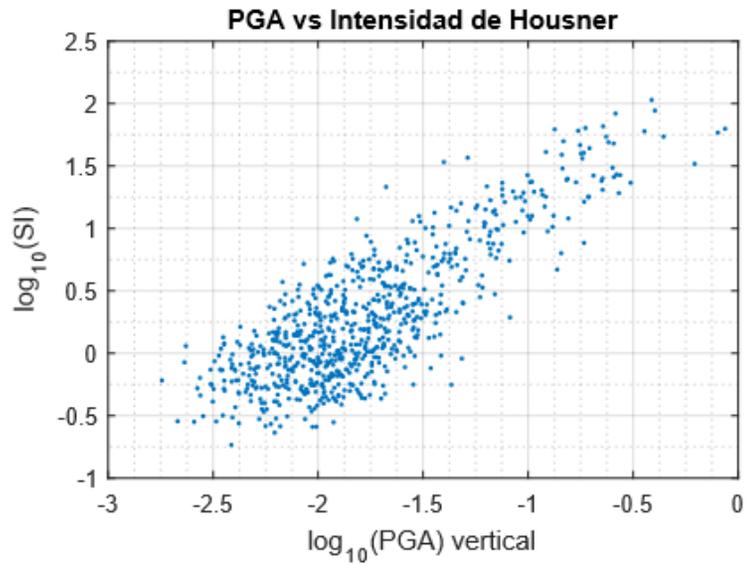


Figura C. 23: Relación entre $\log(\text{PGA})$ Vertical y (a) $\log(SI)$, (b) IJMA, (c) $\log(\text{CAV})$ Horizontal, (d) $\log(\text{CAV})$ Vertical

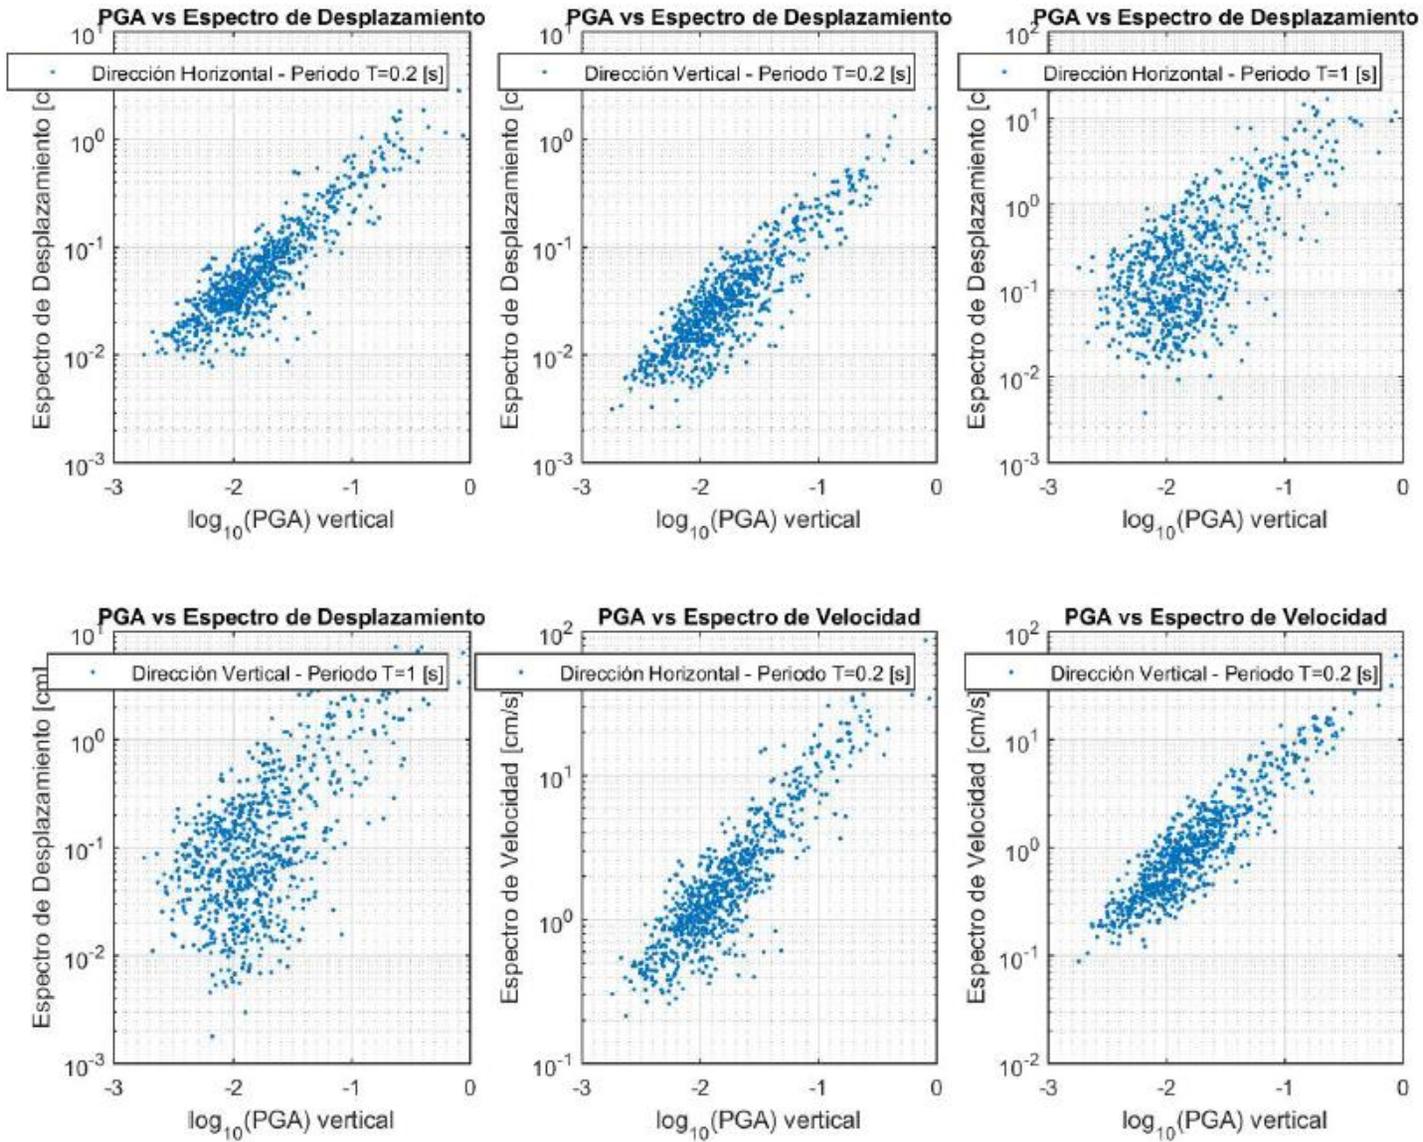


Figura C. 24: Relación entre $\log(\text{PGA})$ Vertical y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s].

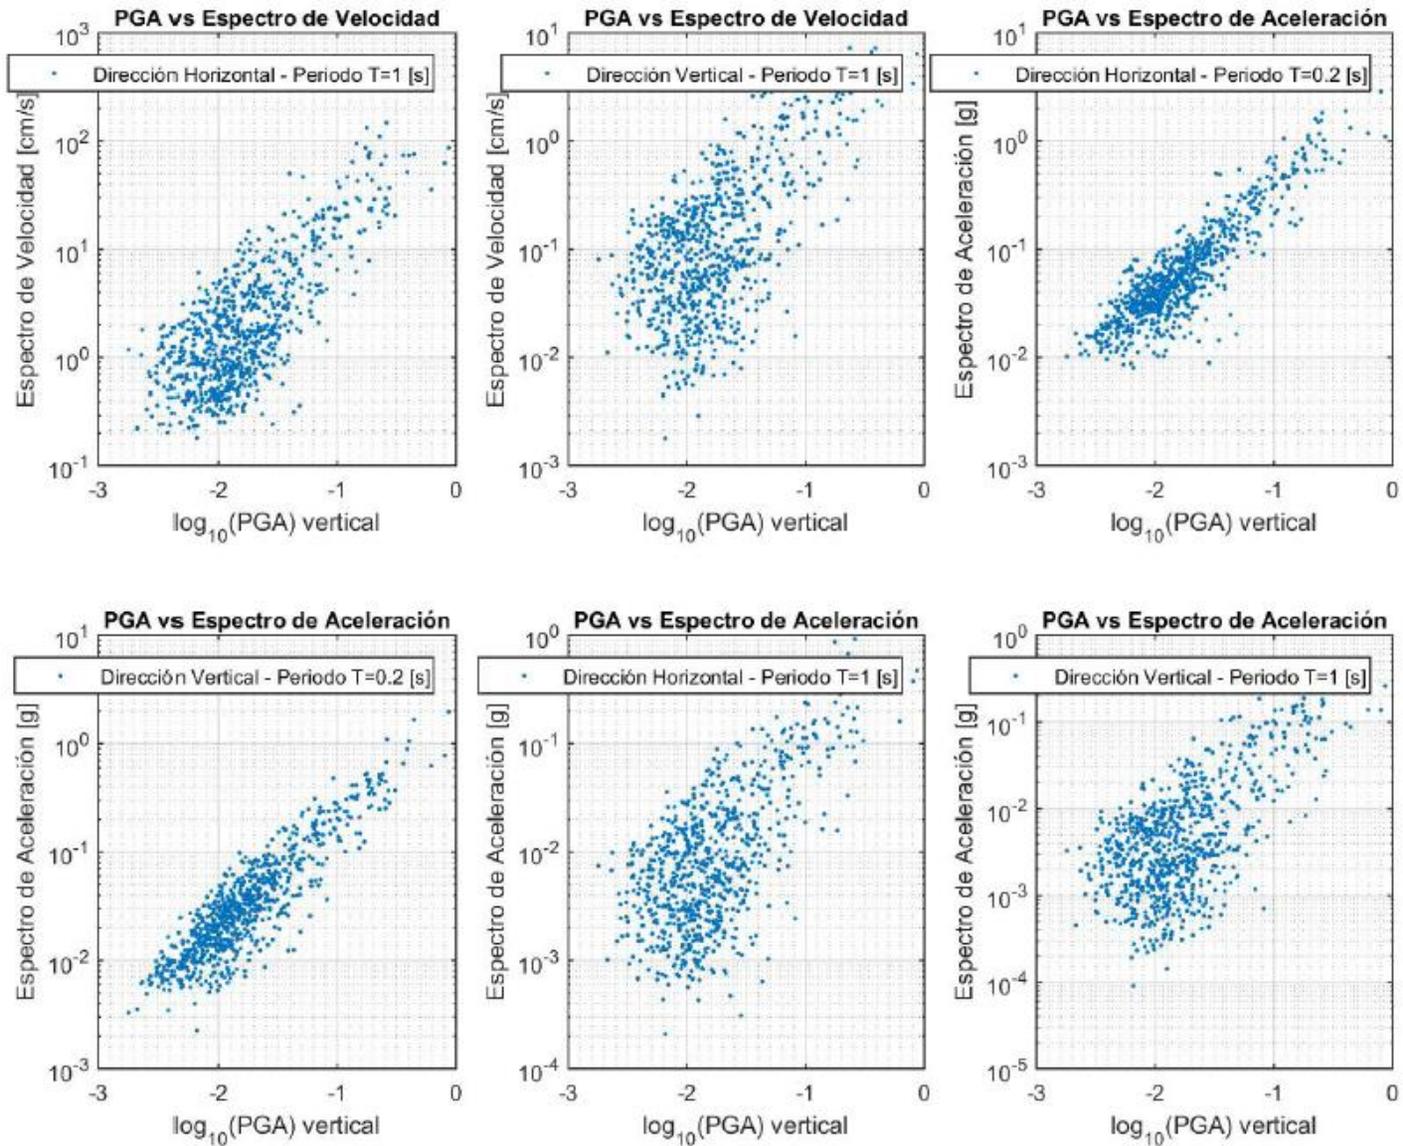


Figura C. 25: Relación entre $\log(\text{PGA})$ Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

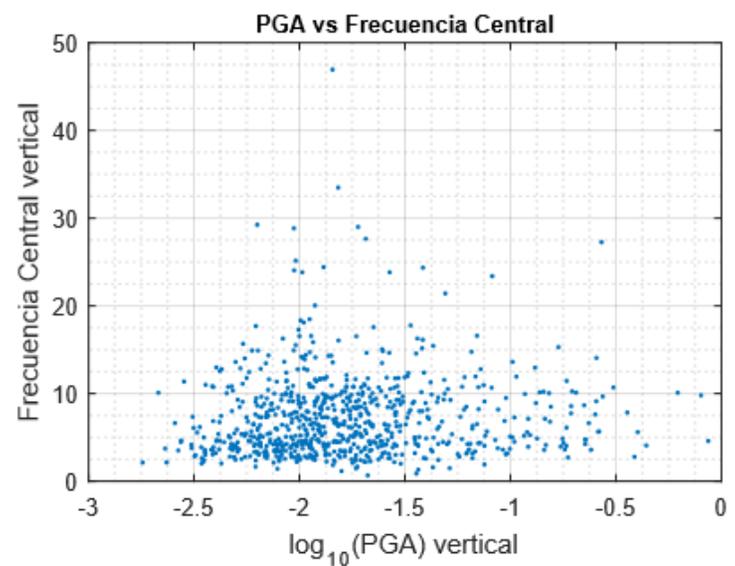
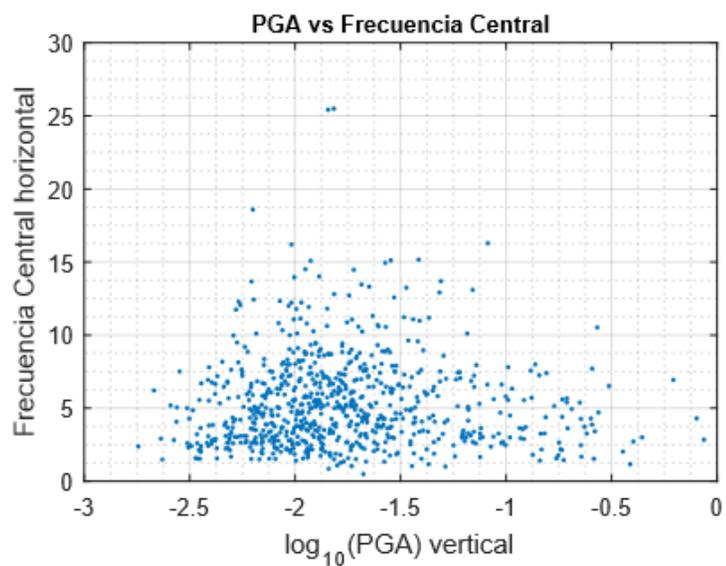
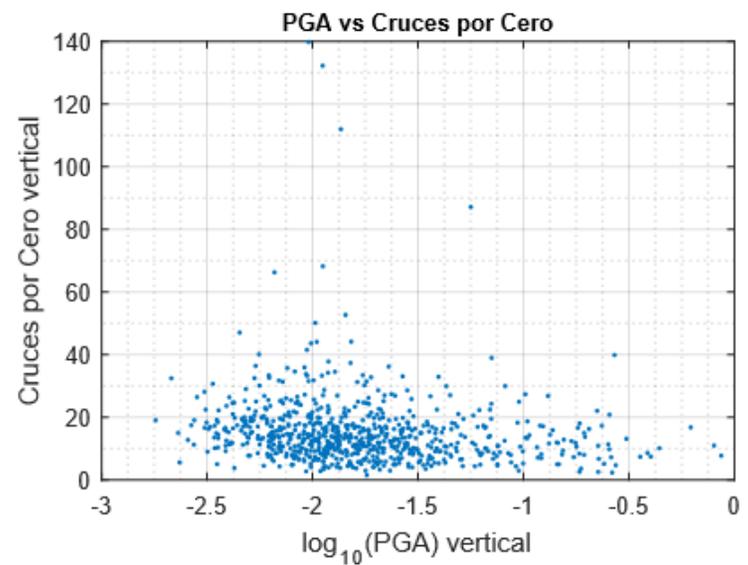
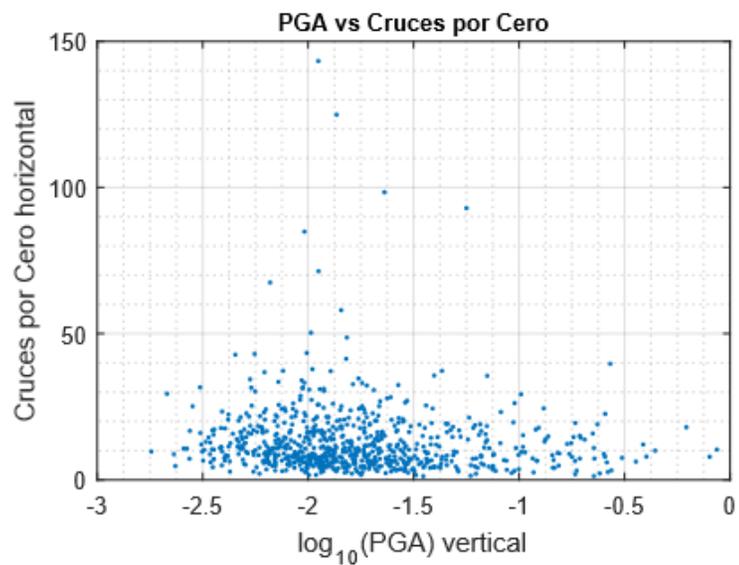


Figura C. 26: Relación entre $\log(\text{PGA})$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

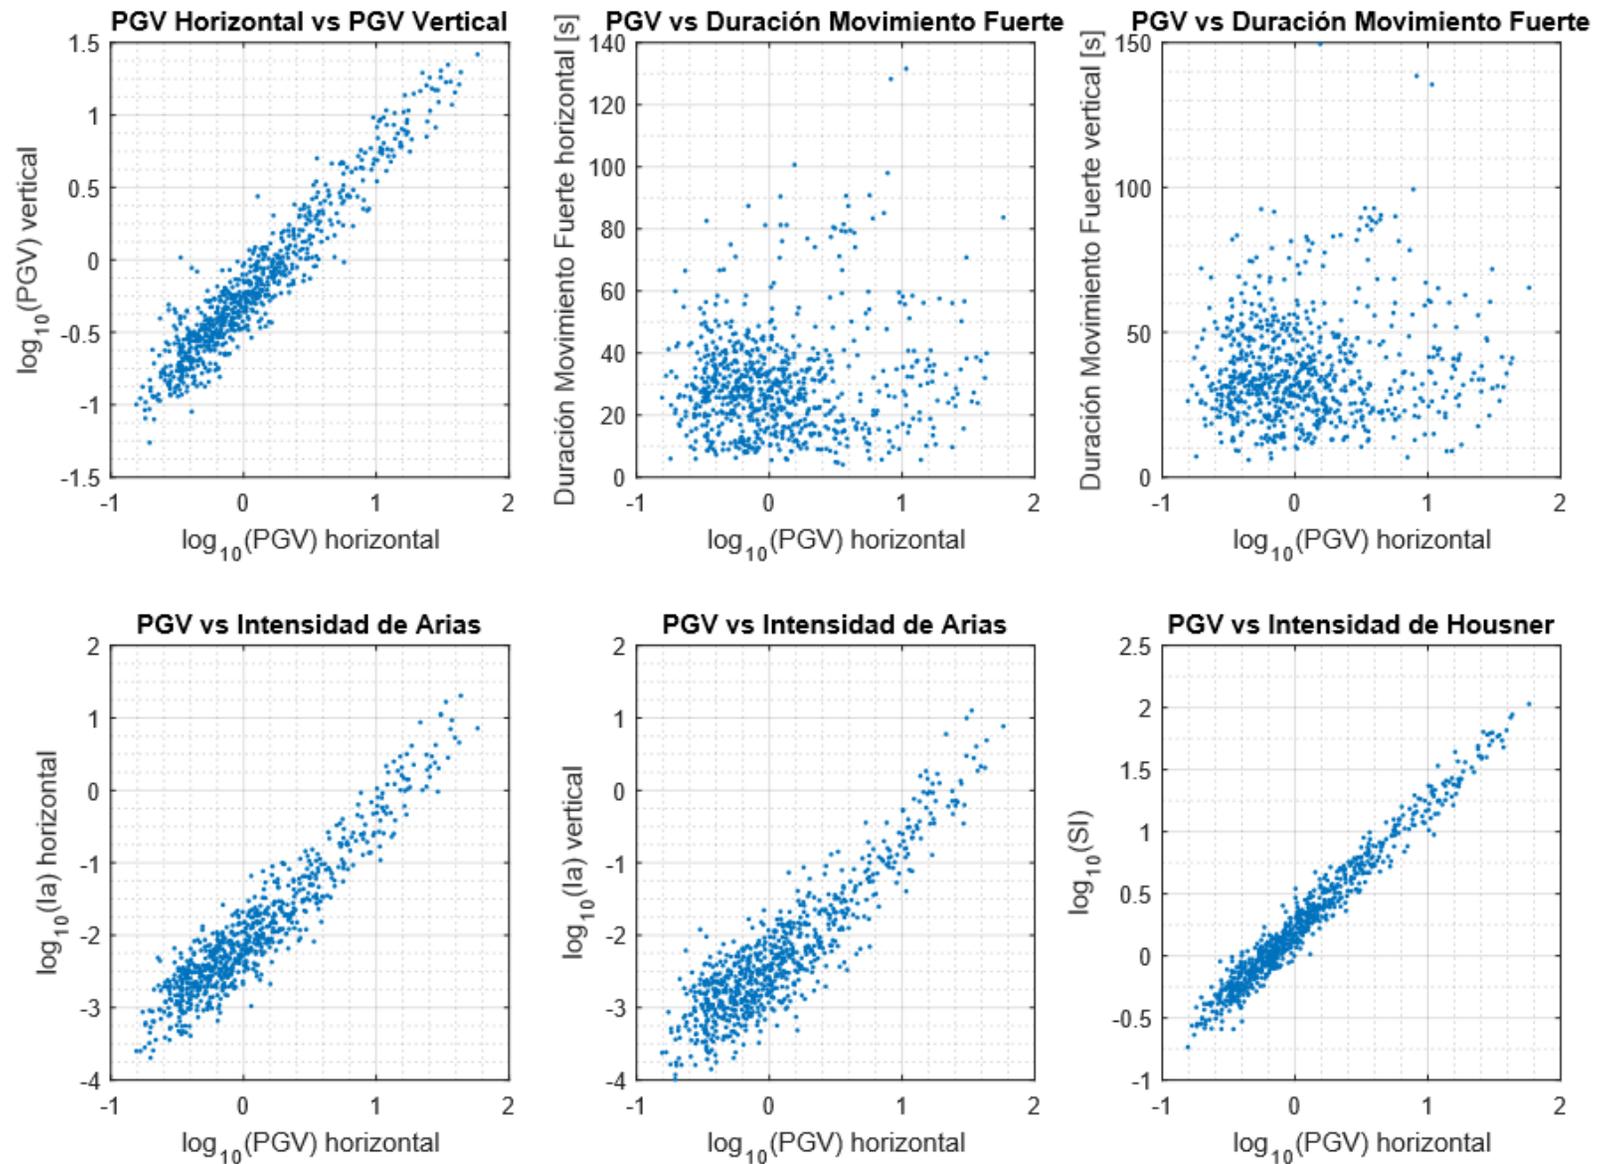


Figura C. 27: Relación entre $\log(\text{PGV})$ Horizontal y (a) $\log(\text{PGV})$ Vertical, (b) Duración Mov. Fuerte Horizontal, (c) Duración Mov. Fuerte Vertical, (d) $\log(I_a)$ Horizontal, (e) $\log(I_a)$ Vertical, (f) $\log(SI)$.

PGV vs Intensidad Agencia Meteorológica de JMA vs Velocidad Absoluta Acumulada **PGV vs Velocidad Absoluta Acumulada**

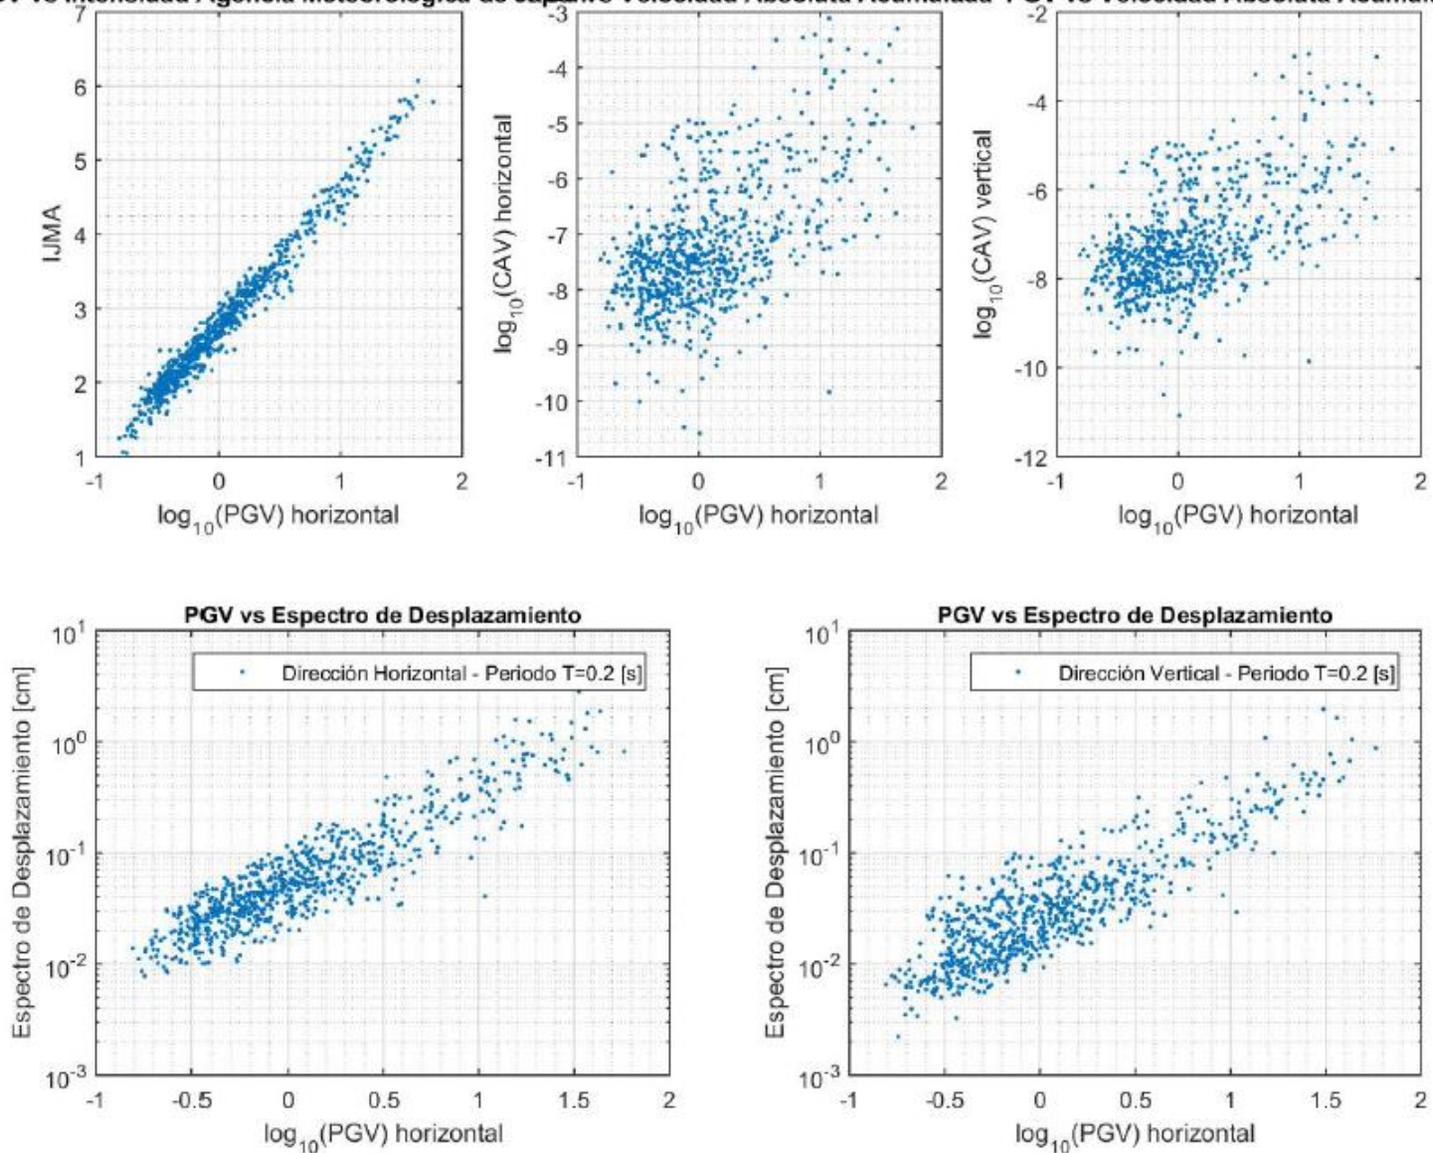


Figura C. 28: Relación entre $\log(\text{PGV})$ Horizontal y (a) IJMA, (b) $\log(\text{CAV})$ Horizontal, (c) $\log(\text{CAV})$ Vertical, (d) Espectro de Desplazamiento Horizontal T=0.2 [s], (e) Espectro de Desplazamiento Vertical T=0.2 [s]

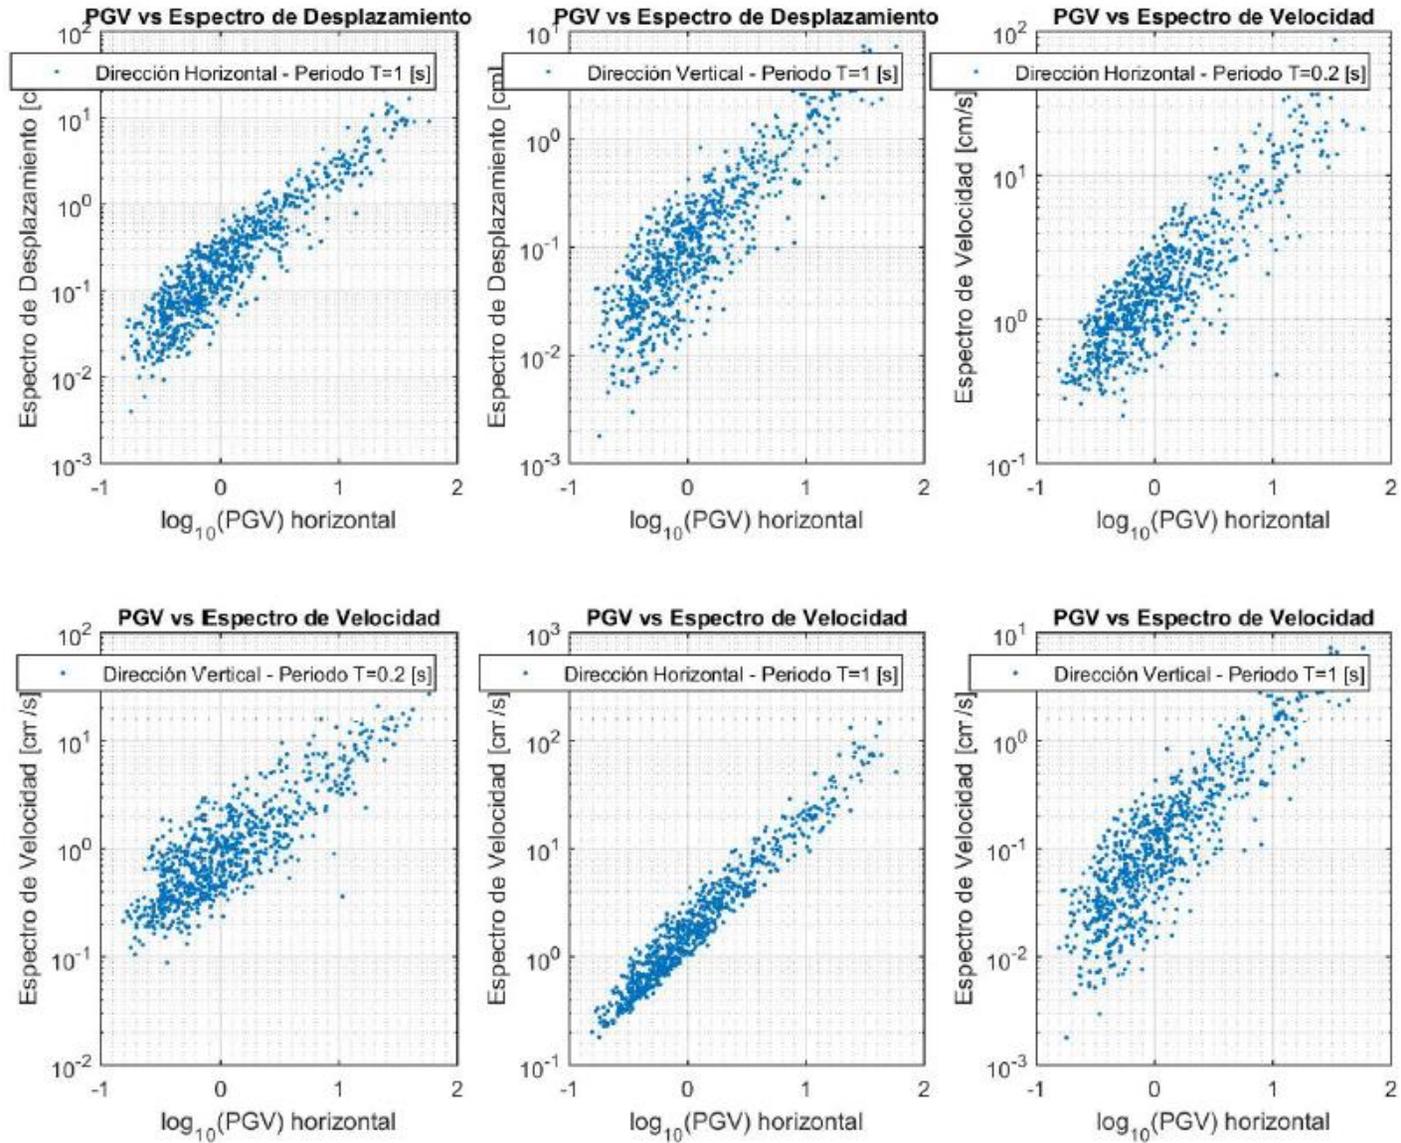


Figura C. 29: Relación entre $\log(\text{PGV})$ Horizontal y (a) Espectro de Desplazamiento Horizontal T=1 [s], (b) Espectro de Desplazamiento Vertical T=1 [s], (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s]

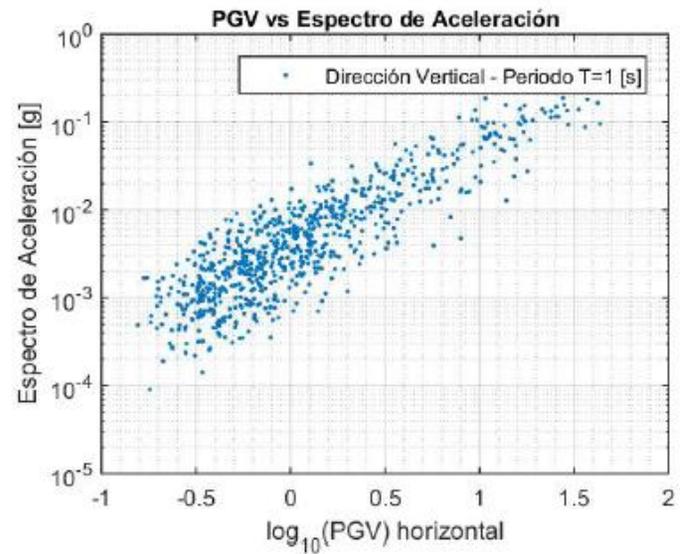
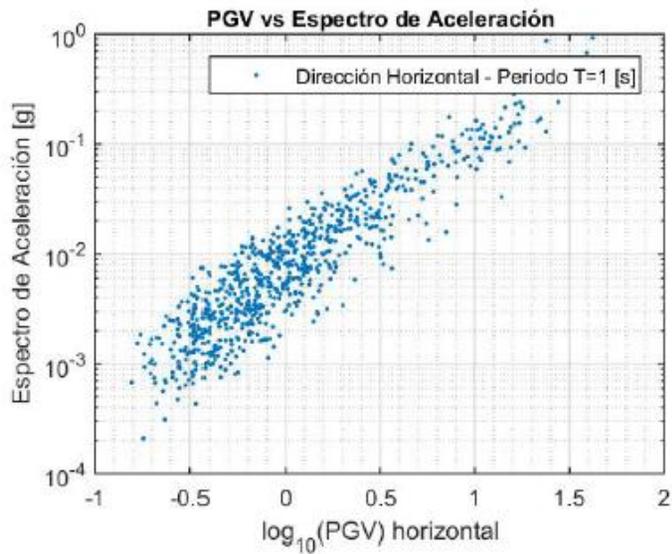
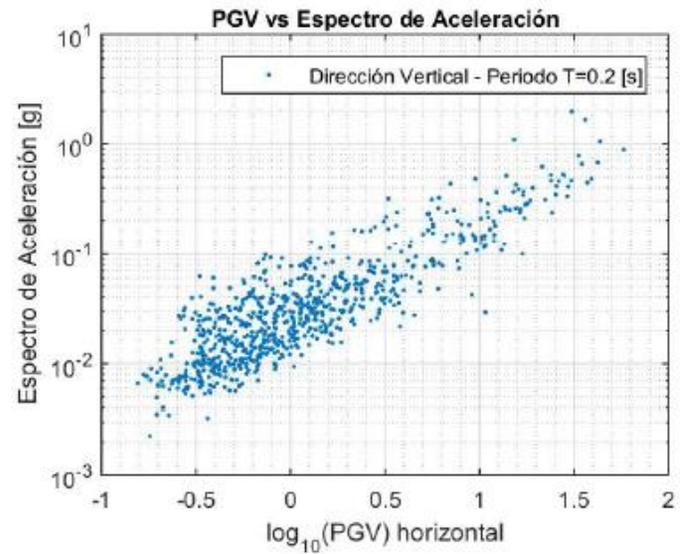
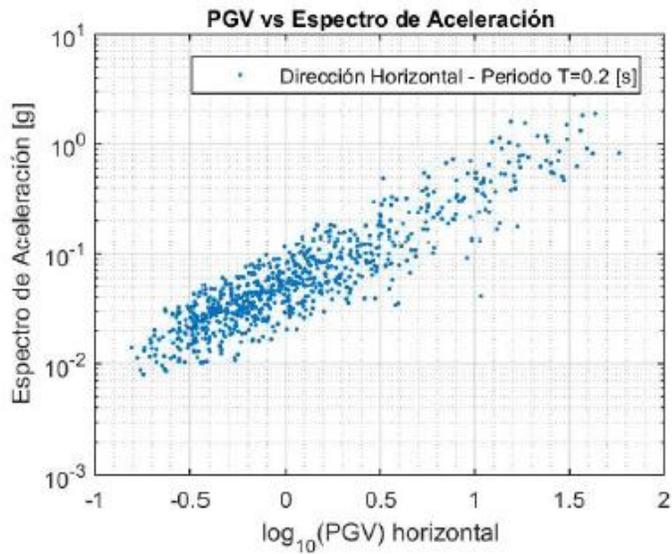


Figura C. 30: Relación entre $\log(\text{PGV})$ Horizontal y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s]

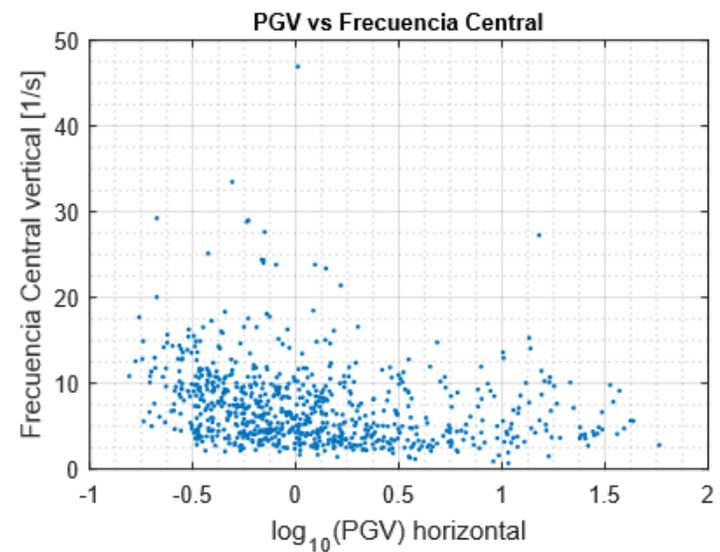
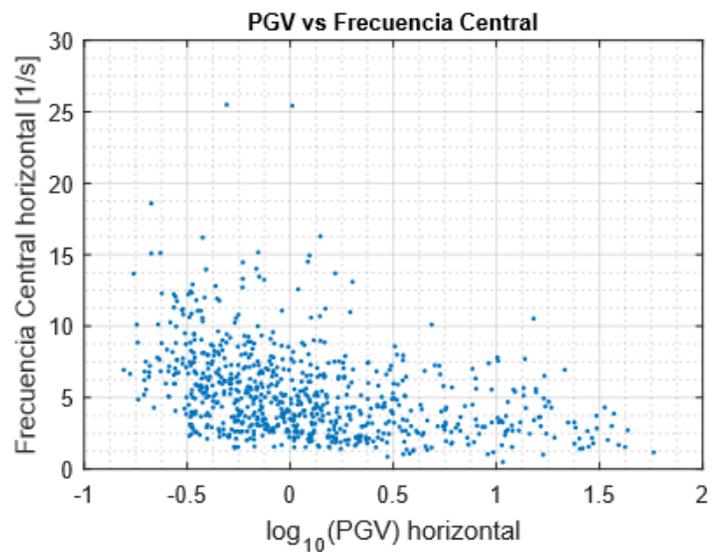
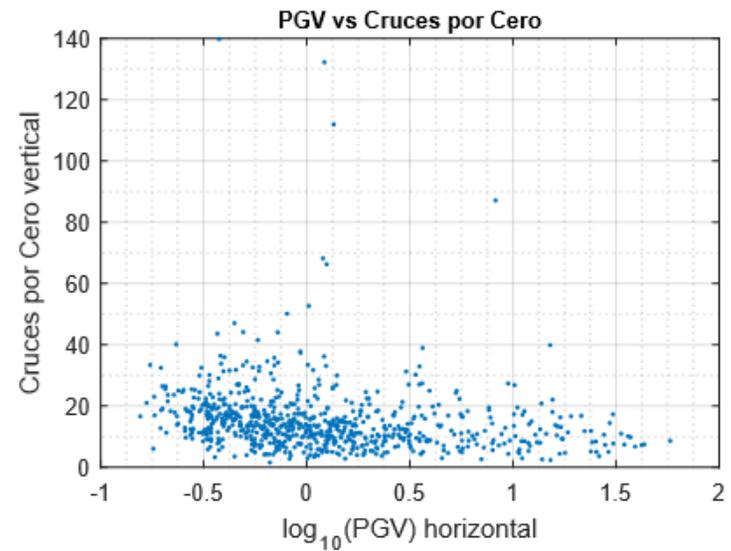
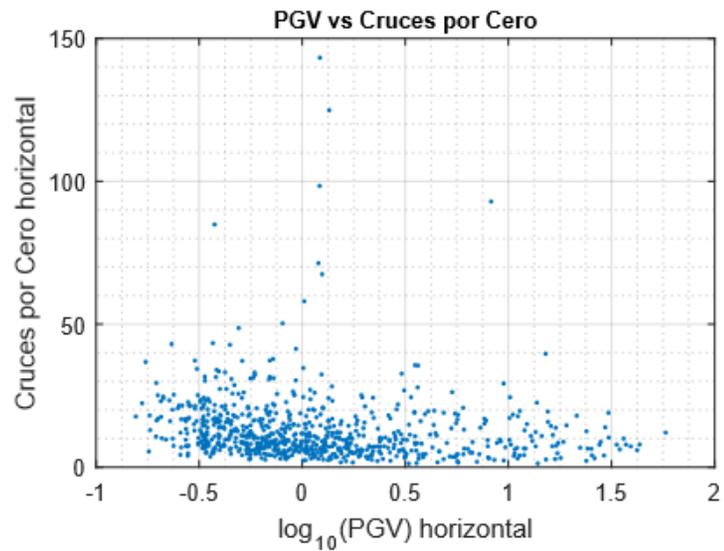


Figura C. 31: Relación entre $\log(\text{PGV})$ y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical

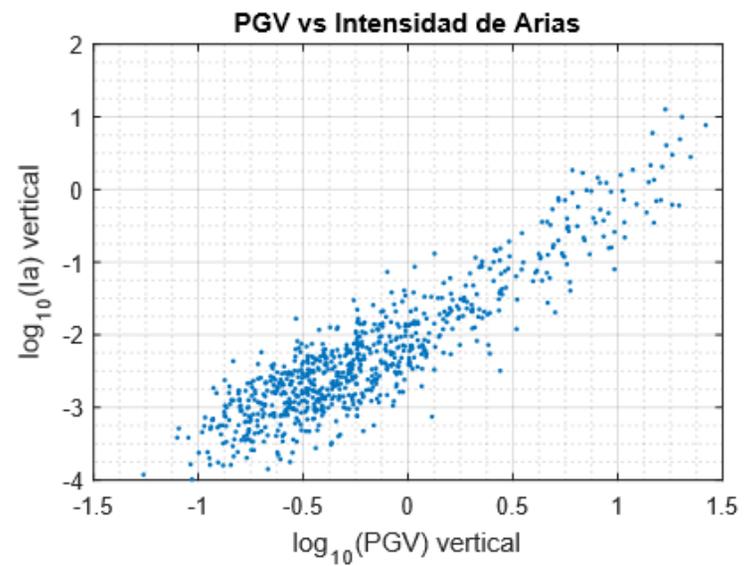
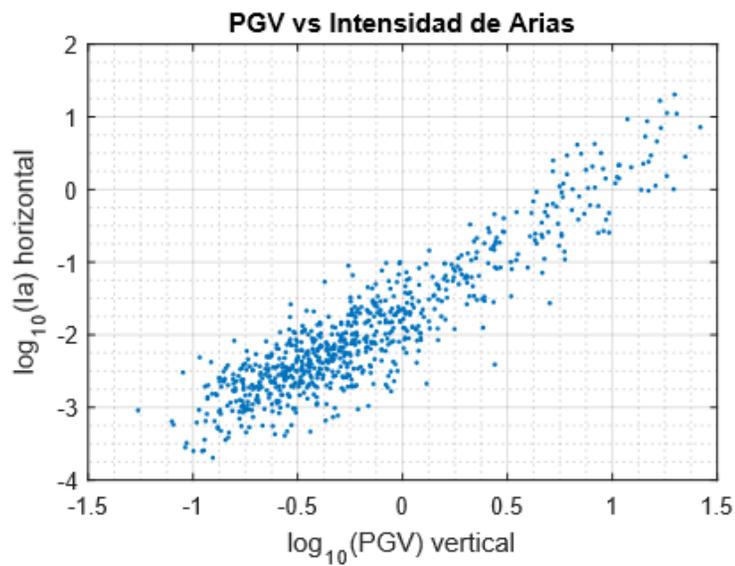
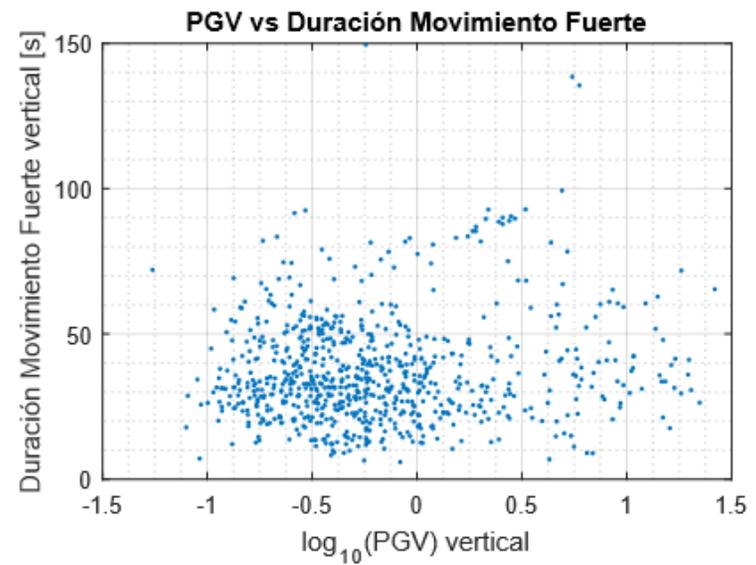
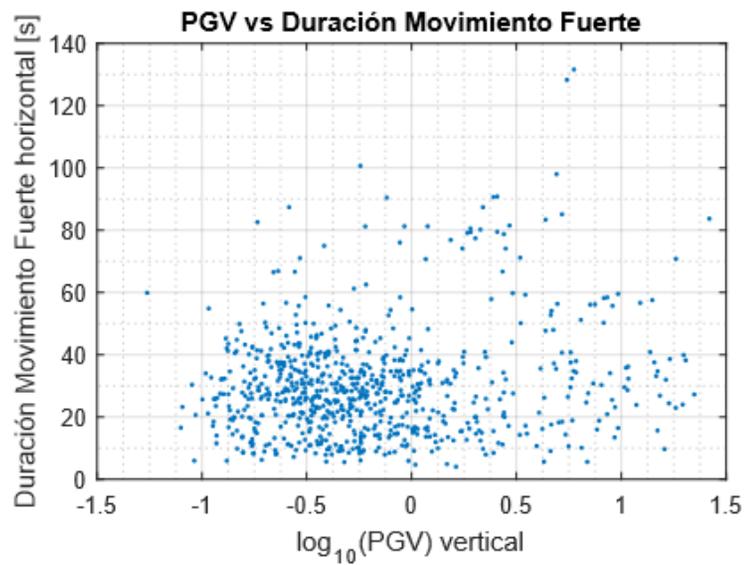


Figura C. 32: Relación entre $\log(\text{PGV})$ Vertical y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) $\log(I_a)$ Horizontal, (d) $\log(I_a)$ Vertical

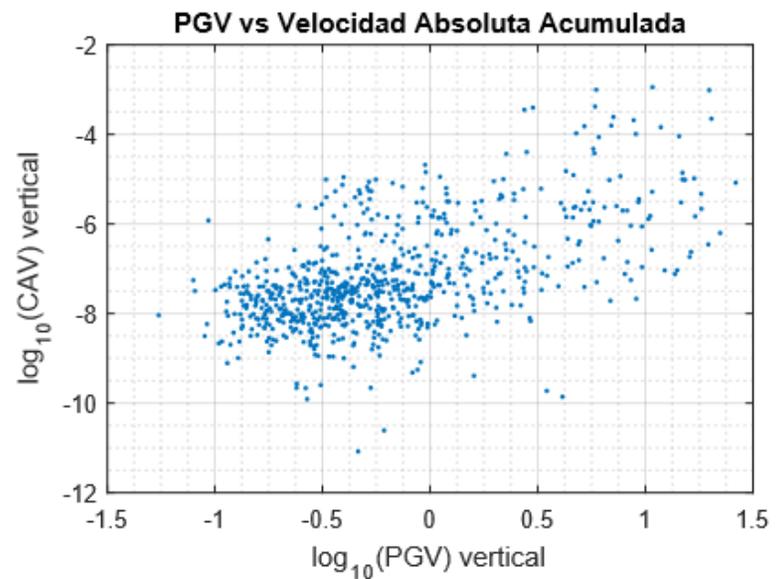
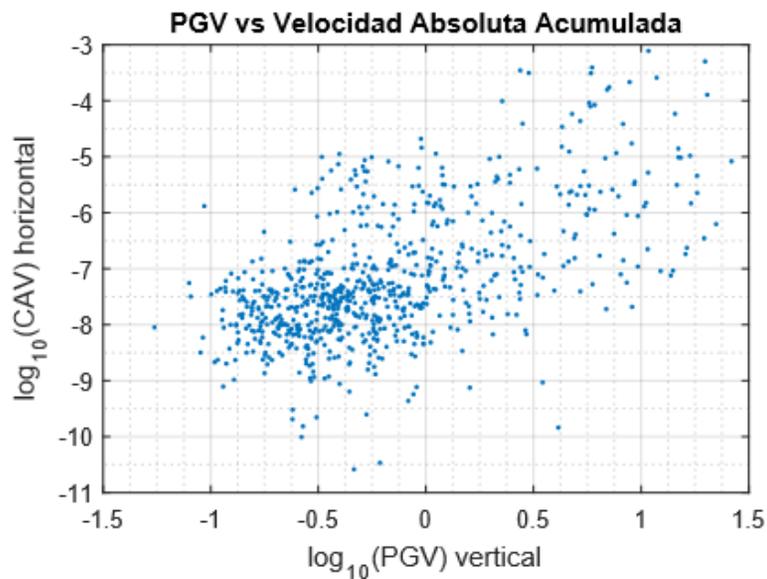
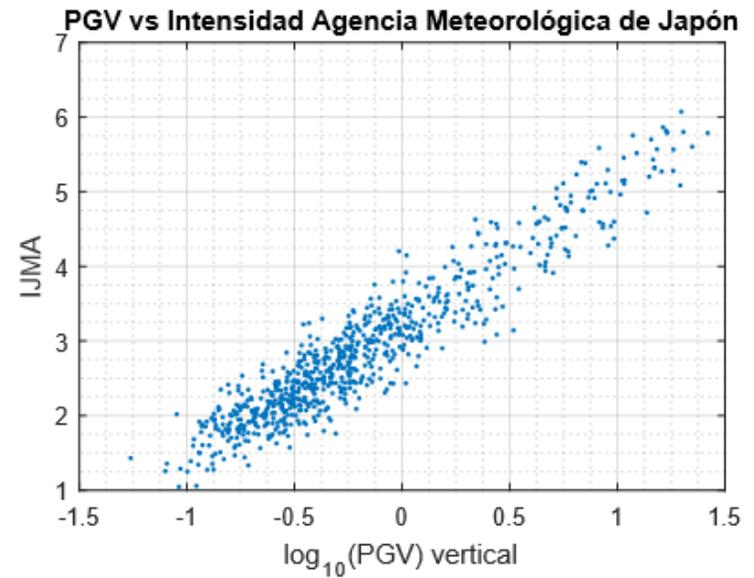
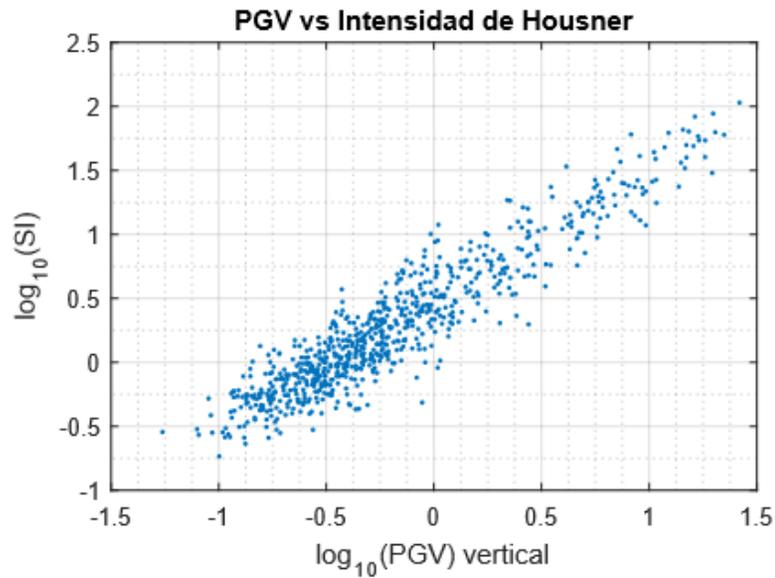


Figura C. 33: Relación entre $\log(\text{PGV})$ Vertical y (a) $\log(\text{SI})$, (b) IJMA, (c) $\log(\text{CAV})$ Horizontal, (d) $\log(\text{CAV})$ Vertical.

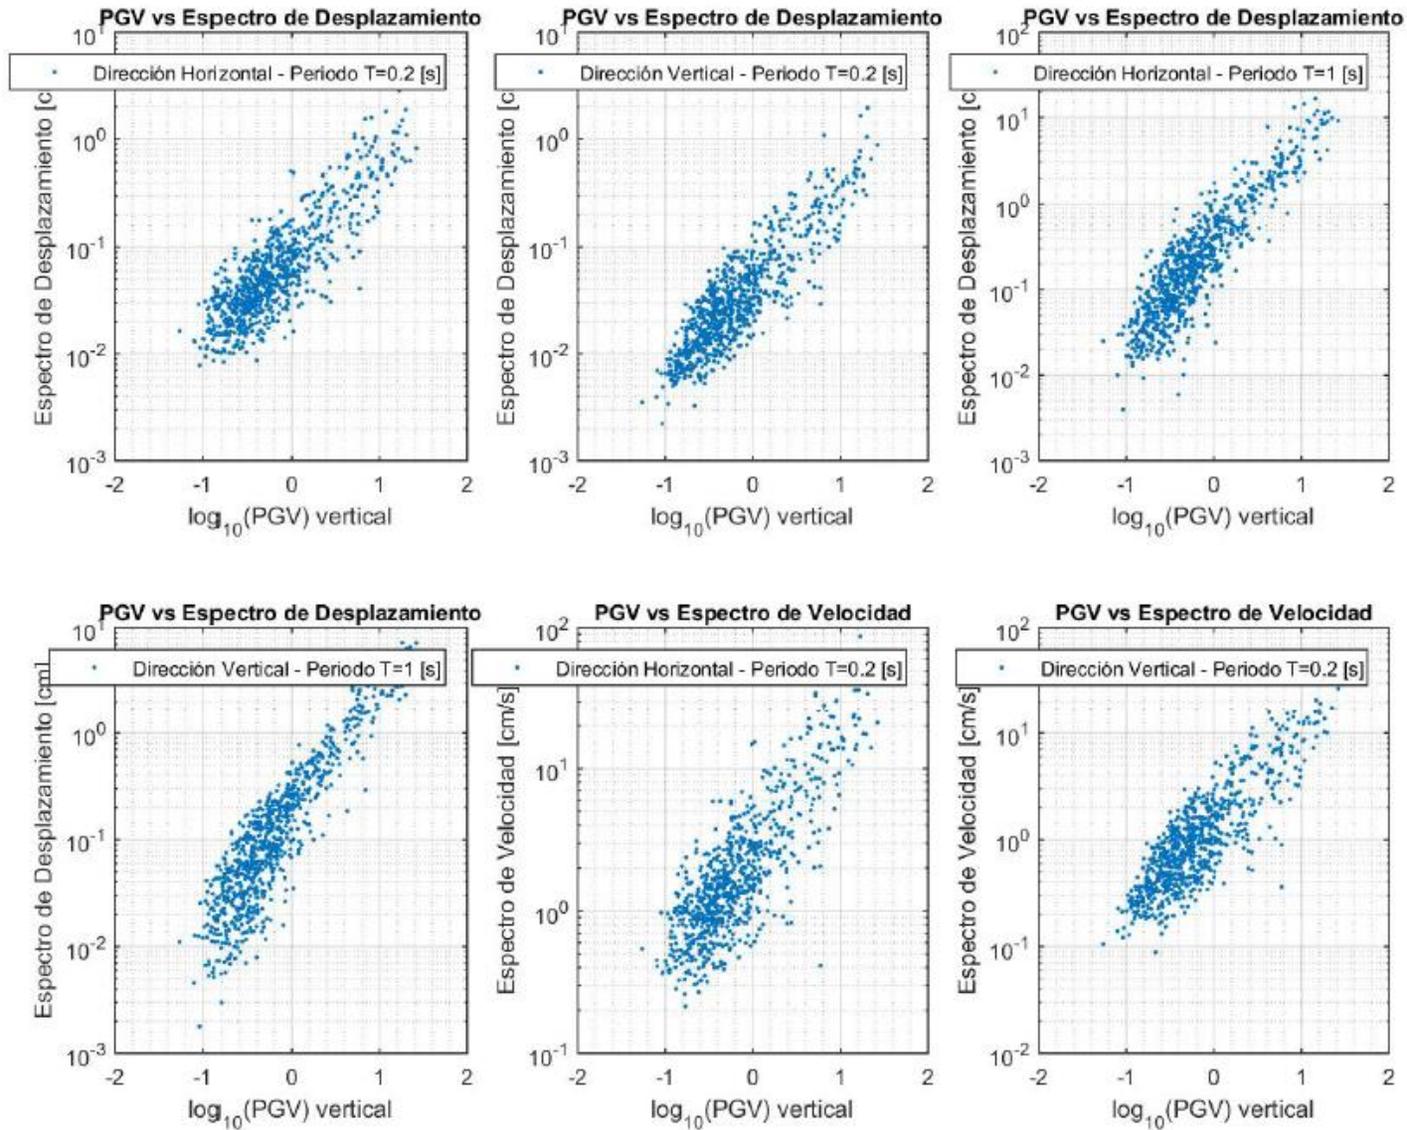


Figura C. 34: Relación entre $\log(\text{PGV})$ Vertical y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s]

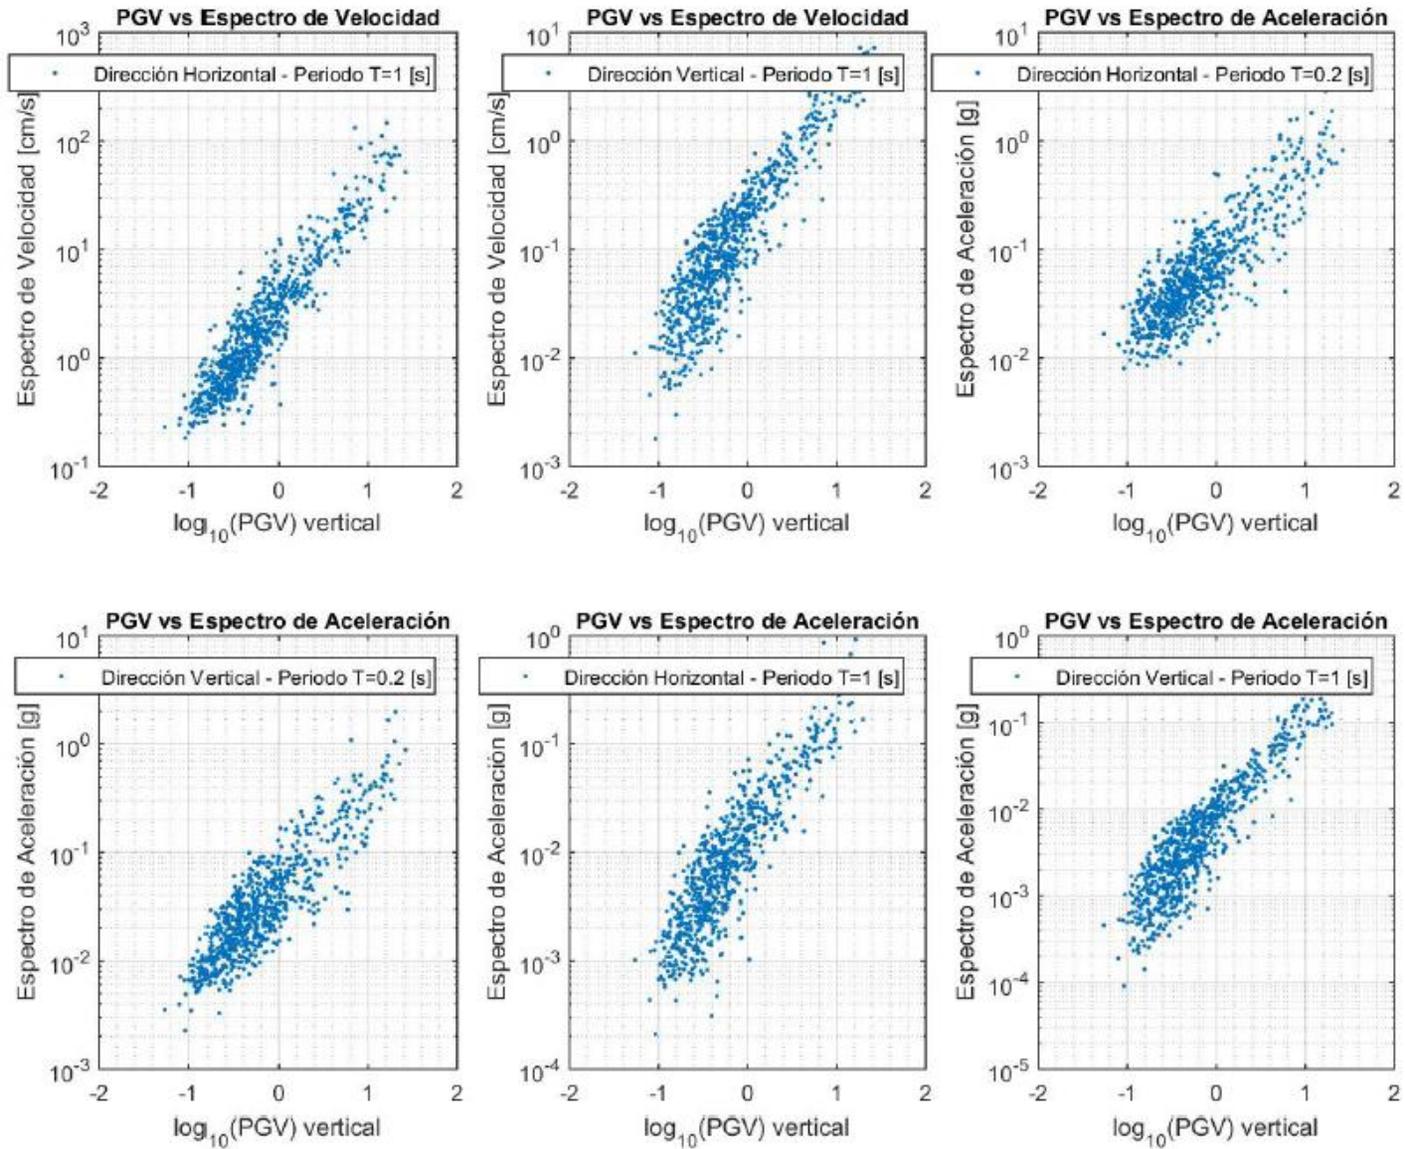


Figura C. 35: Relación entre $\log(\text{PGV})$ Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]

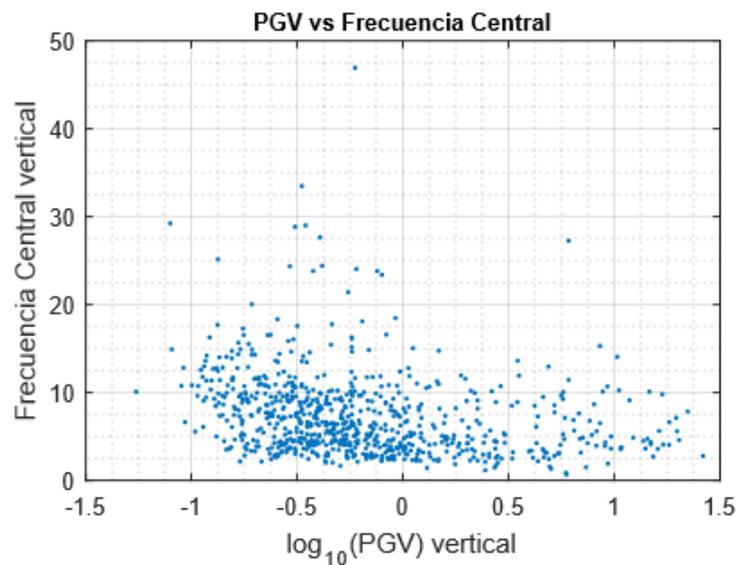
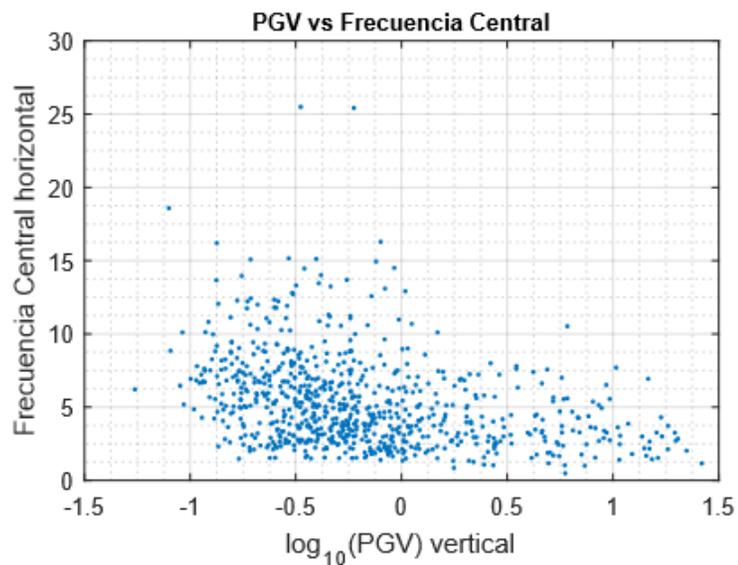
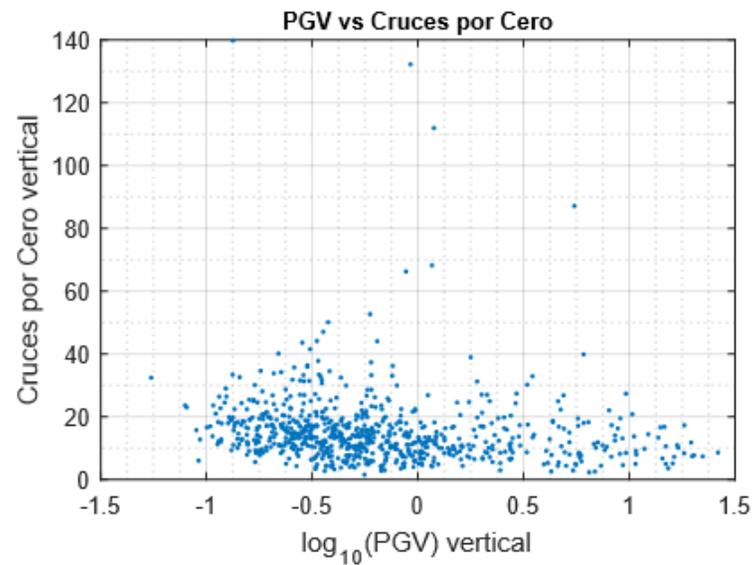
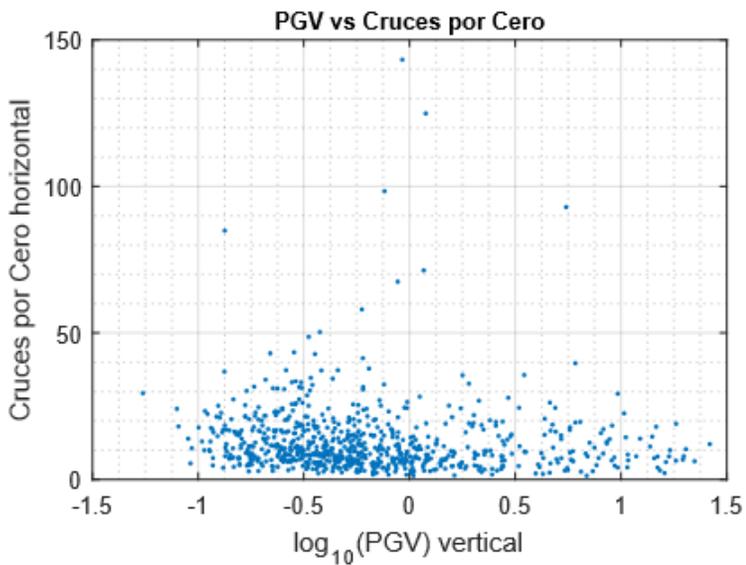


Figura C. 36: Relación entre $\log(\text{PGV})$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical

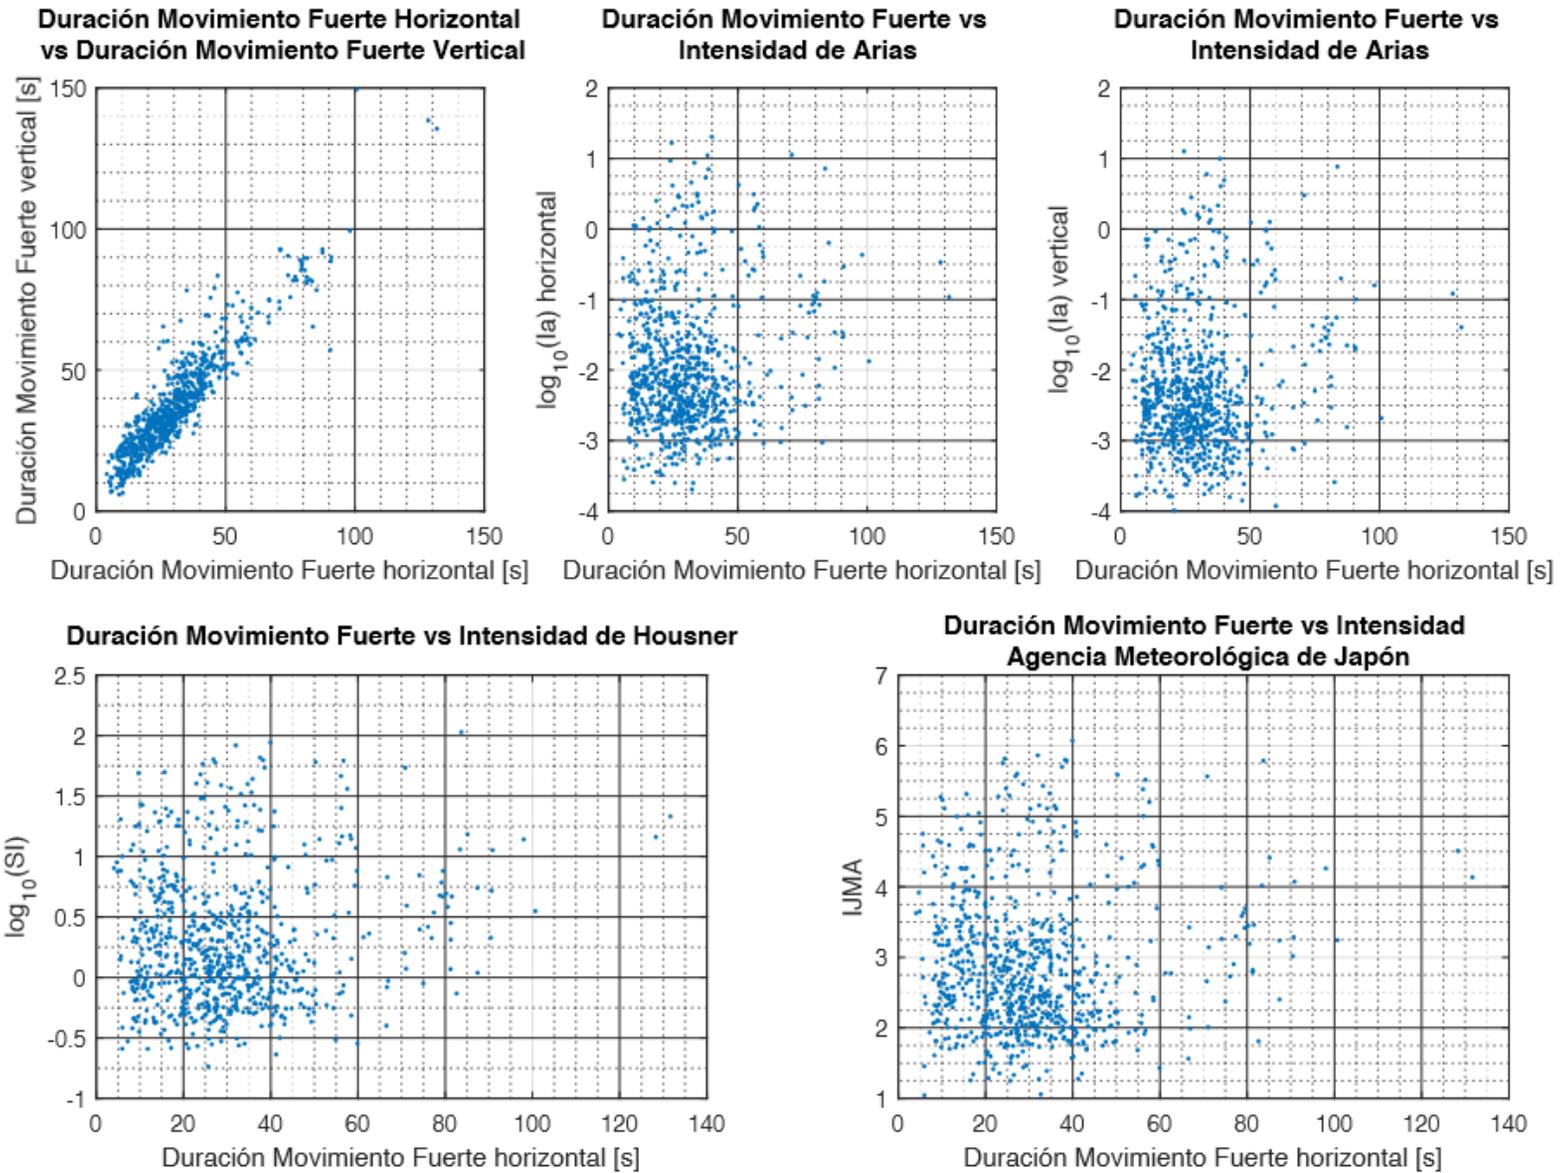


Figura C. 37: Relación entre Duración Mov. Fuerte Horizontal y (a) Duración Mov. Fuerte Vertical, (b) $\log(I_a)$ Horizontal, (c) $\log(I_a)$ Vertical, (d) $\log(S_I)$, (e) IJMA.

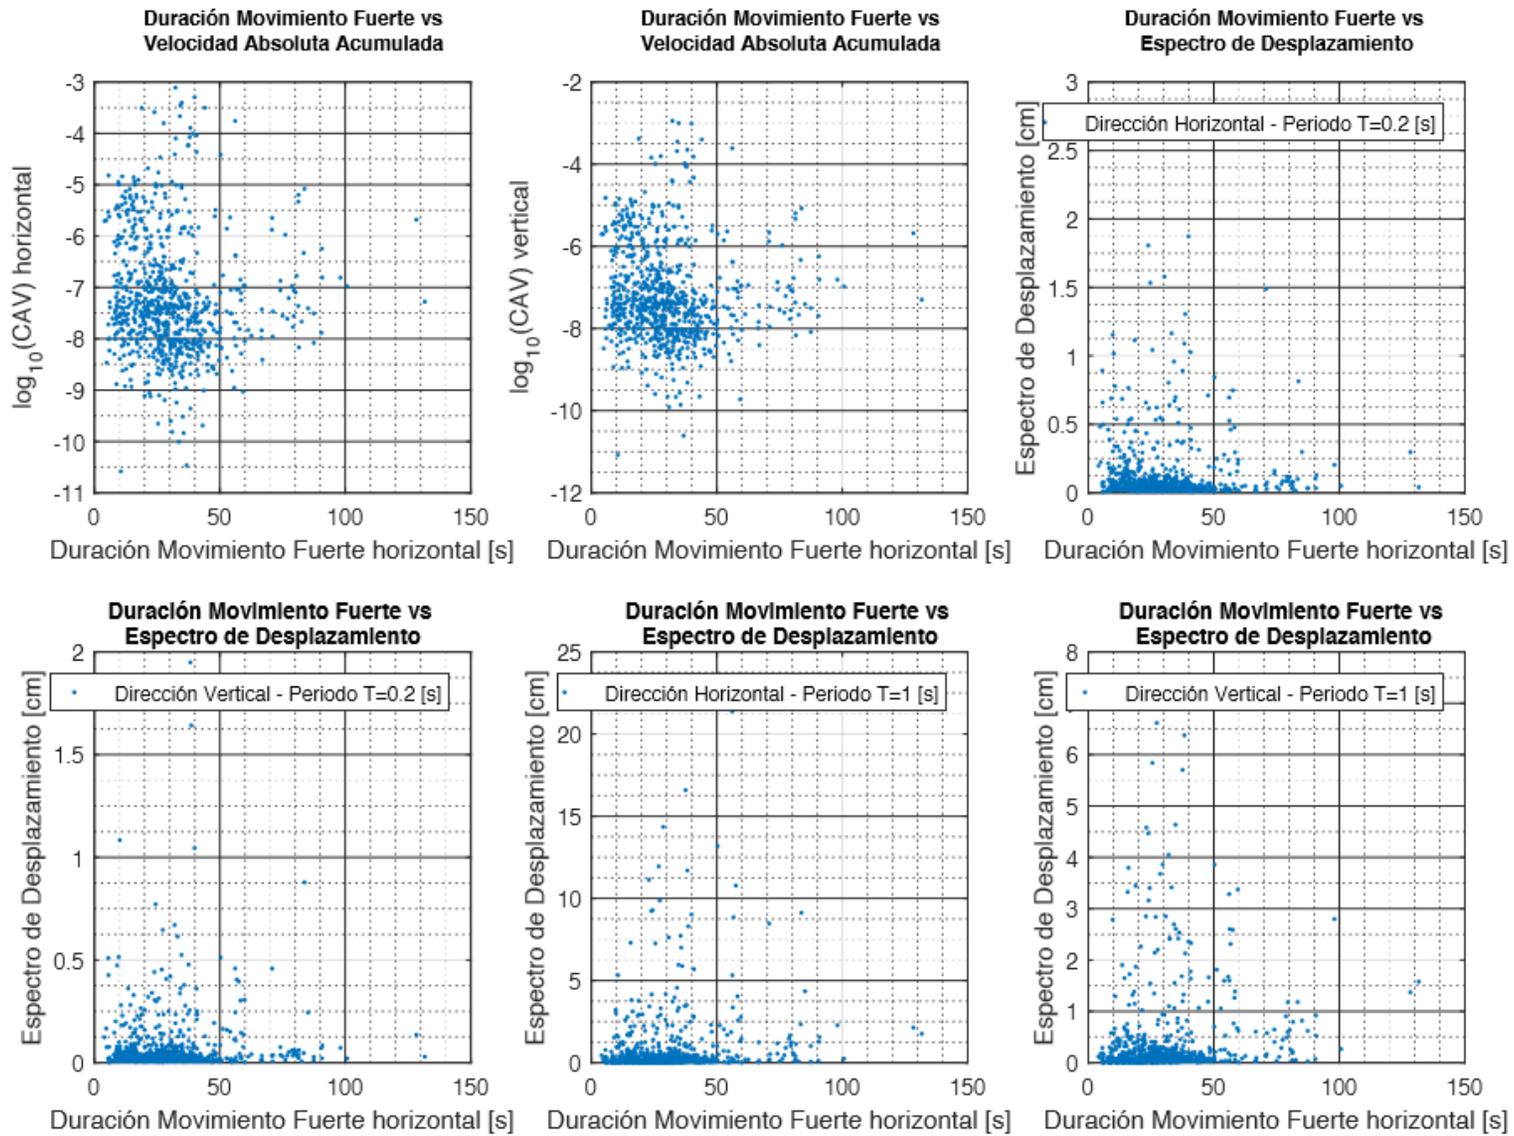


Figura C. 38: Relación entre Duración Mov. Fuerte Horizontal y (a) $\log(\text{CAV})$ Horizontal, (b) $\log(\text{CAV})$ Vertical, (c) Espectro de Desplazamiento Horizontal T=0.2 [s], (d) Espectro de Desplazamiento Vertical T=0.2 [s], (e) Espectro de Desplazamiento Horizontal T=1 [s], (f) Espectro de Desplazamiento Vertical T=1 [s]

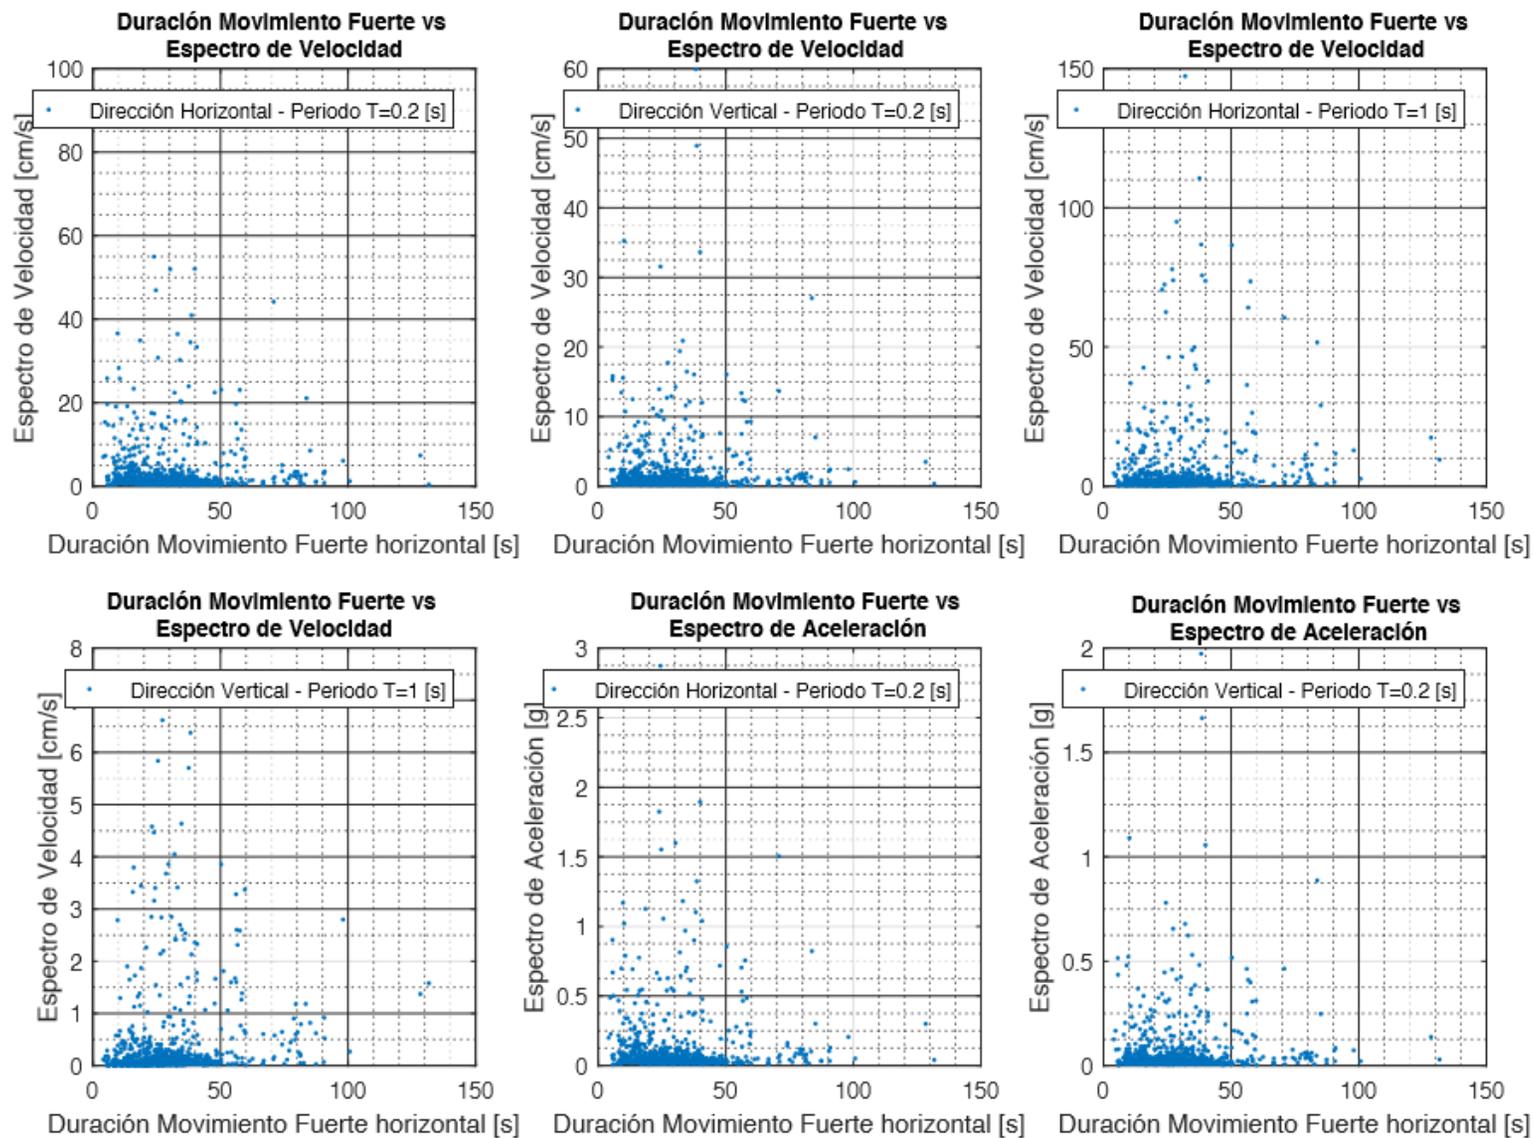


Figura C. 39: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Velocidad Horizontal $T=0.2$ [s], (b) Espectro de Velocidad Vertical $T=0.2$ [s], (c) Espectro de Velocidad Horizontal $T=1$ [s], (d) Espectro de Velocidad Vertical $T=1$ [s], (e) Espectro de Aceleración Horizontal $T=0.2$ [s], (f) Espectro de Aceleración Vertical $T=0.2$ [s]

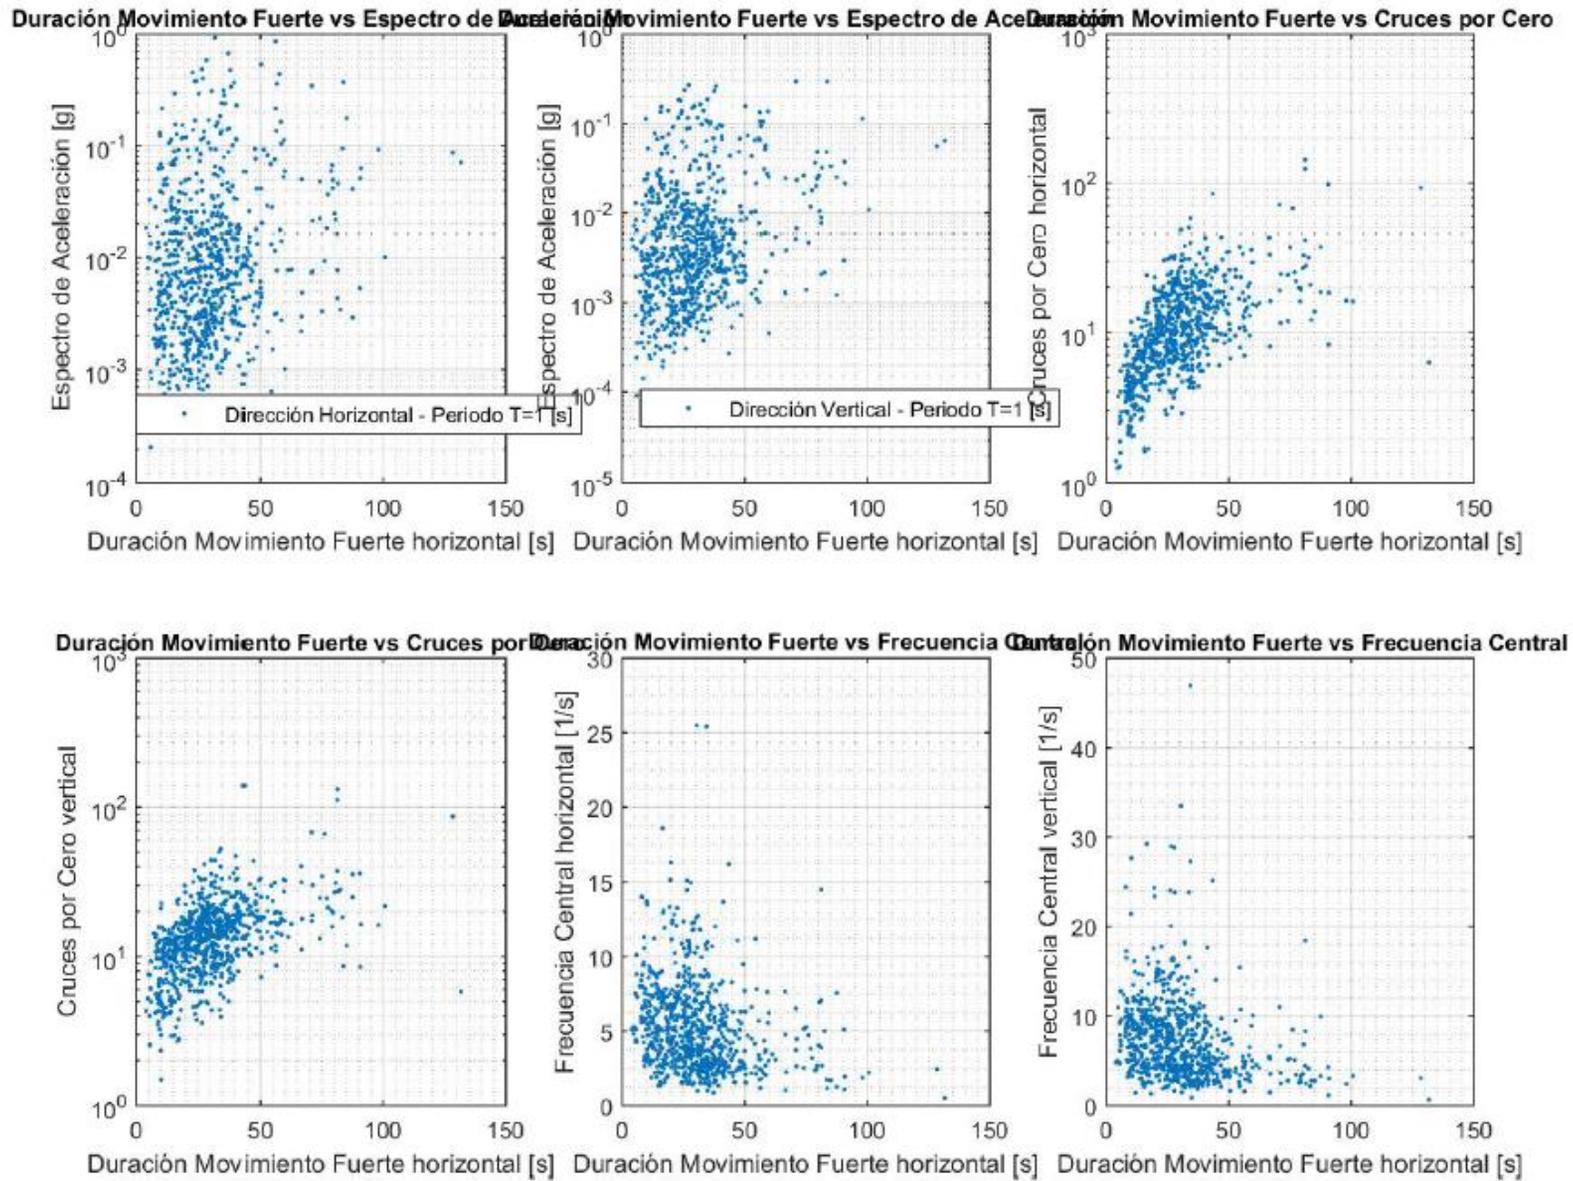


Figura C. 40: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical

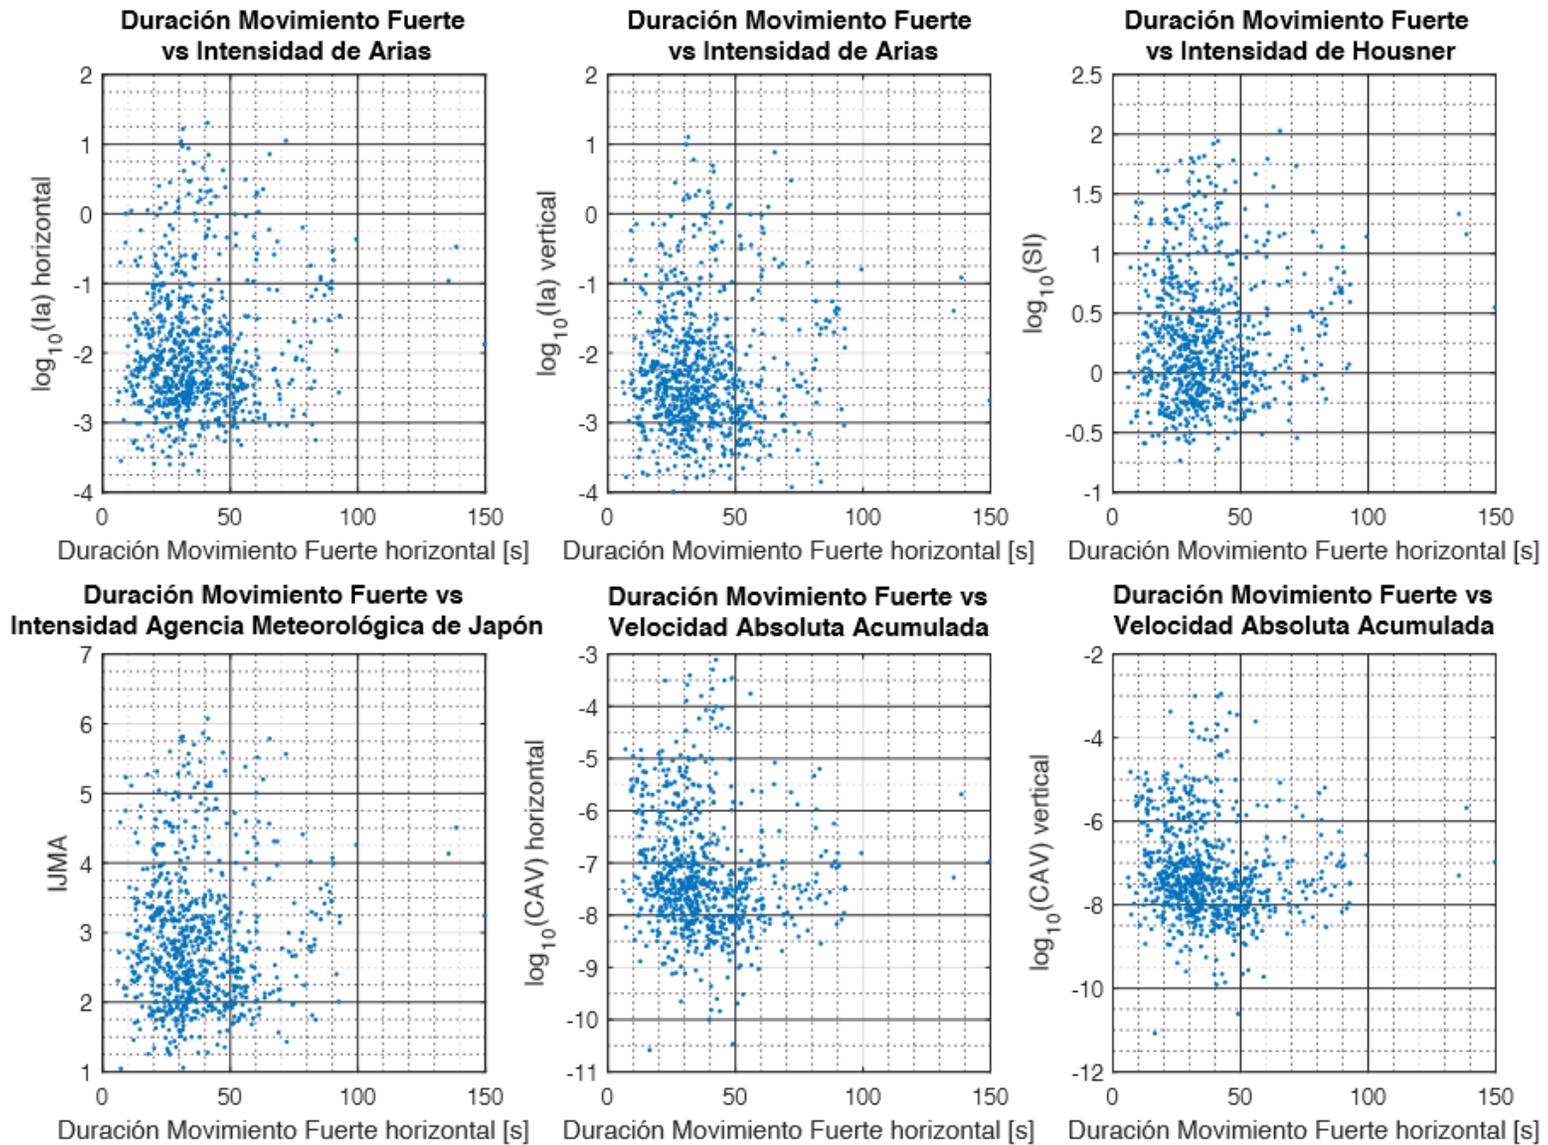


Figura C. 41: Relación entre Duración Mov. Fuerte Horizontal y (a) $\log(I_a)$ Horizontal, (b) $\log(I_a)$ Vertical, (c) $\log(SI)$, (d) IJMA, (e) $\log(CAV)$ Horizontal, (f) $\log(CAV)$ Vertical

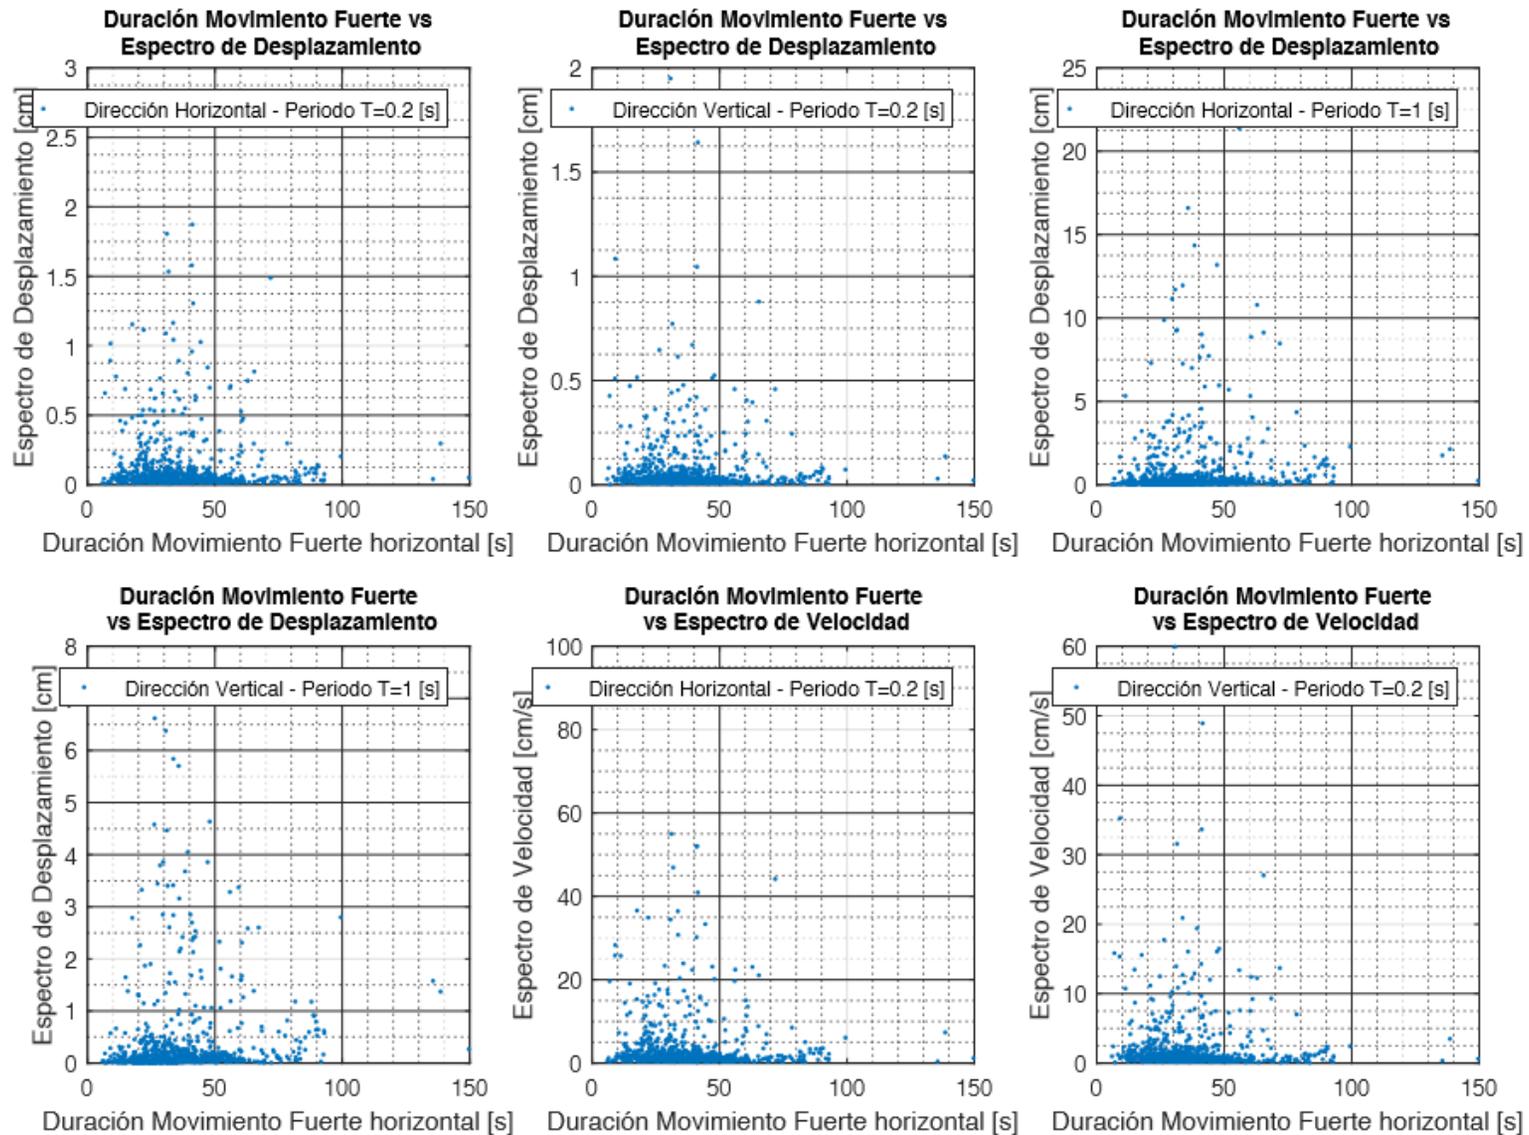


Figura C. 42: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s],

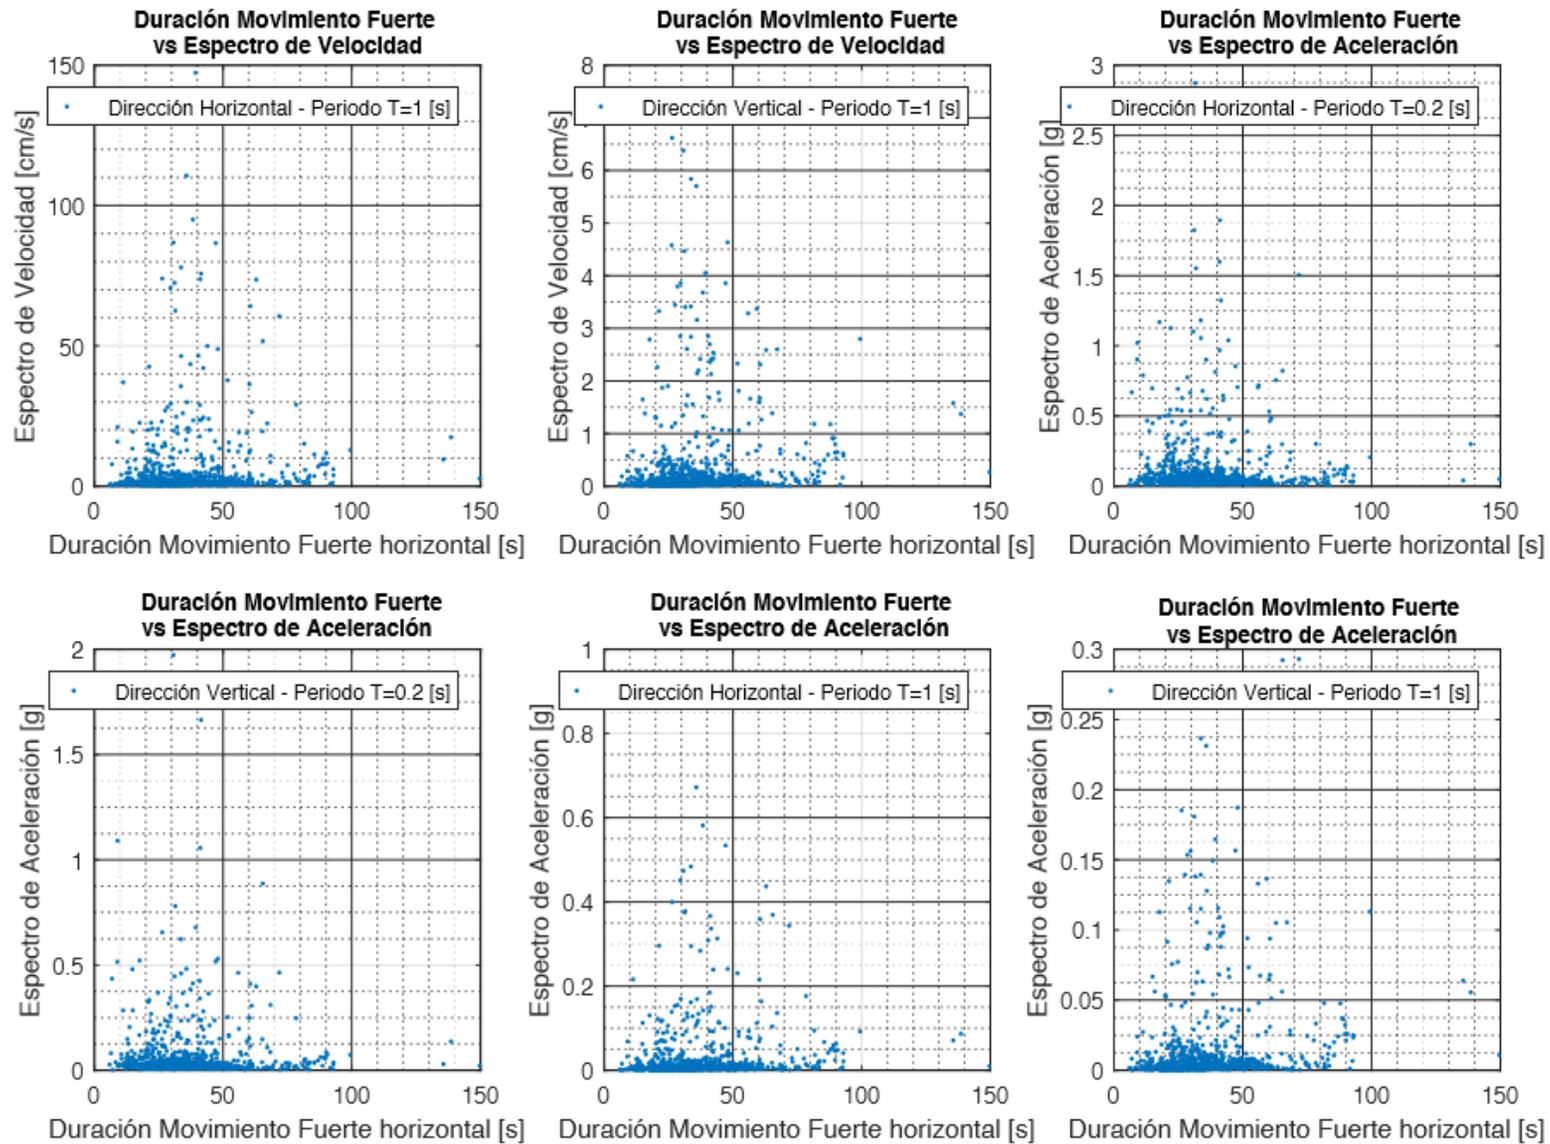


Figura C. 43: Relación entre Duración Mov. Fuerte Horizontal y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

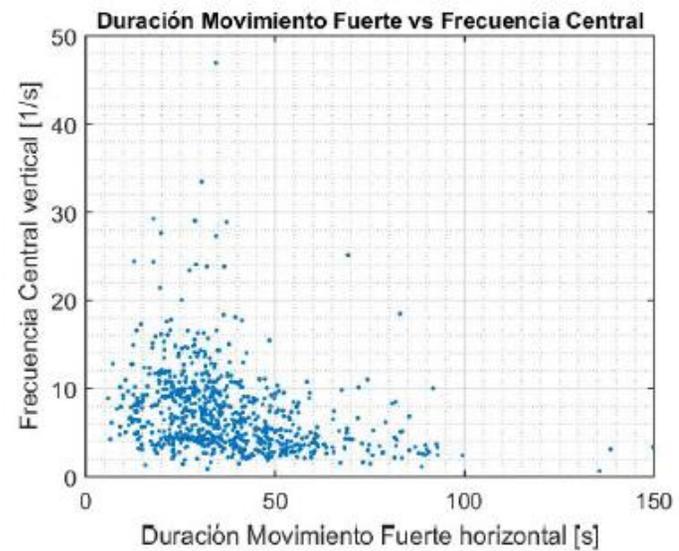
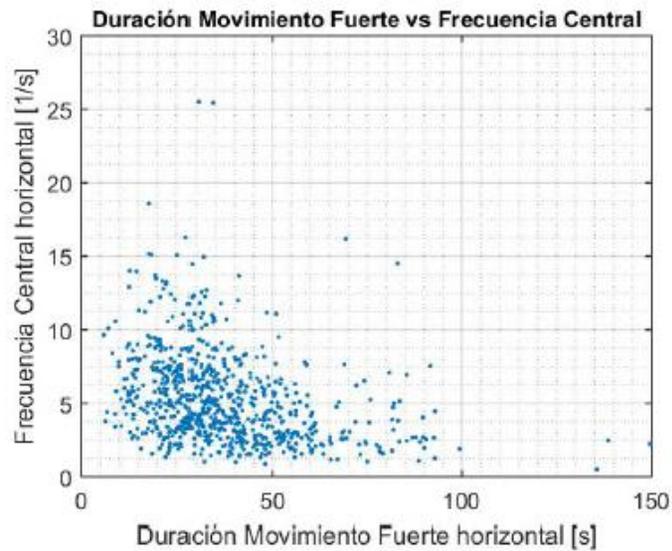
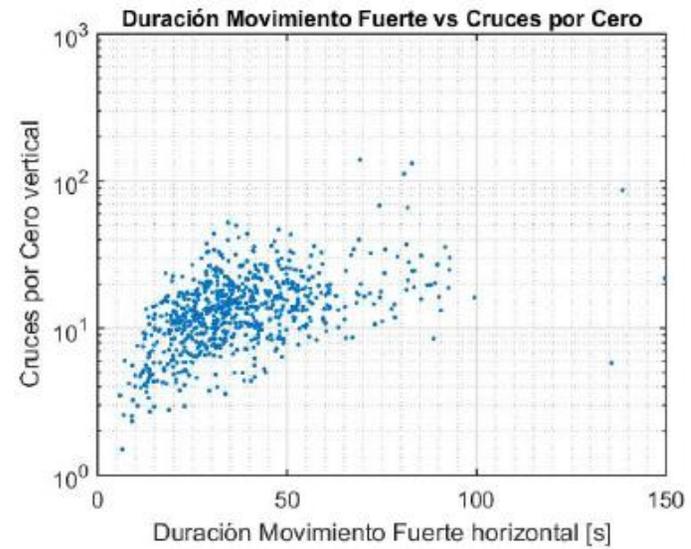
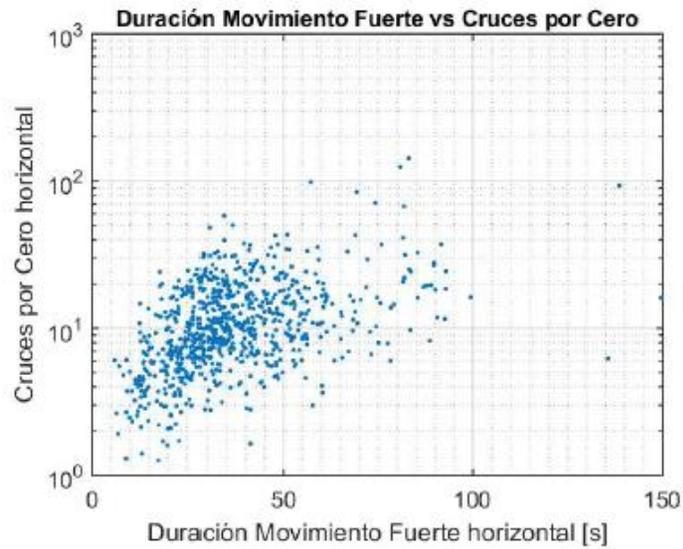
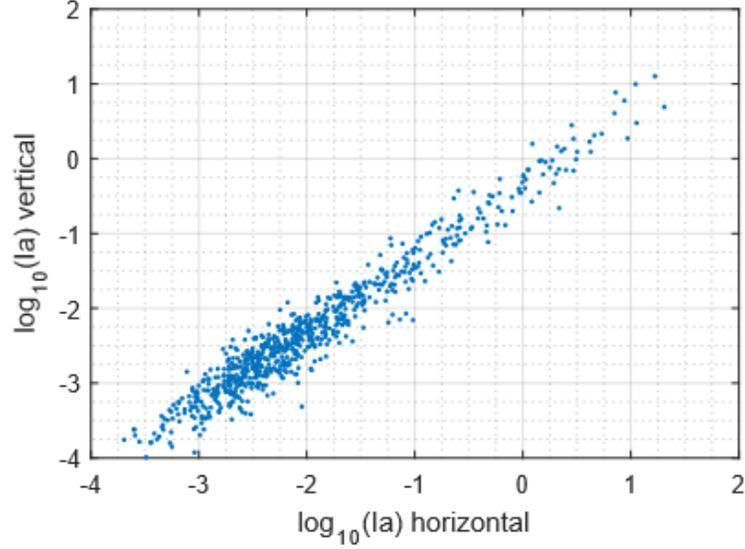
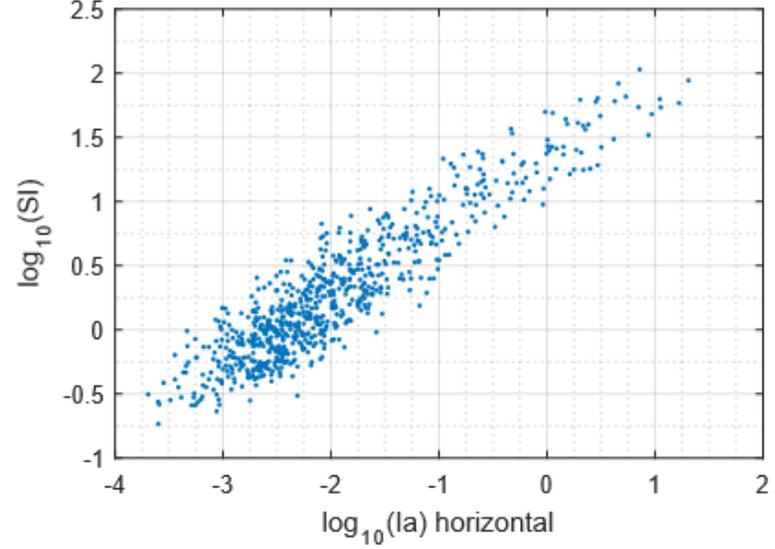


Figura C. 44: Relación entre Duración Mov. Fuerte Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

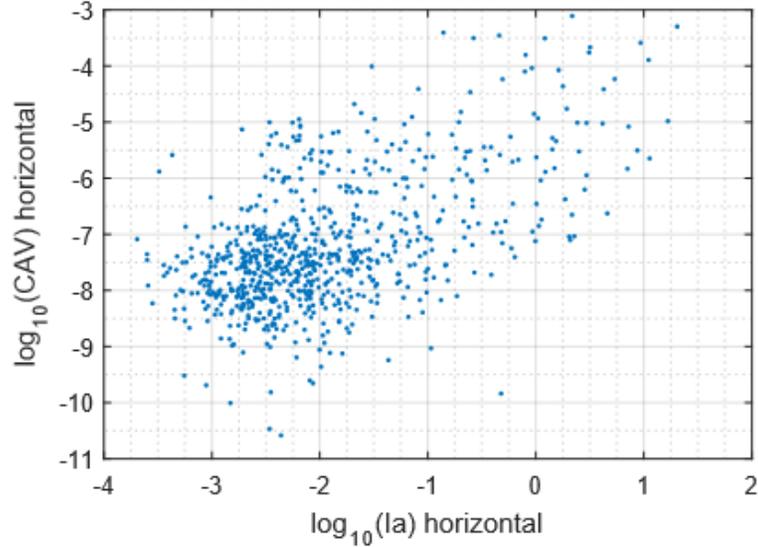
Intensidad de Arias Horizontal vs Intensidad de Arias Vertical



Intensidad de Arias vs Intensidad de Housner



Intensidad de Arias vs Velocidad Absoluta Acumulada



Intensidad de Arias vs Velocidad Absoluta Acumulada

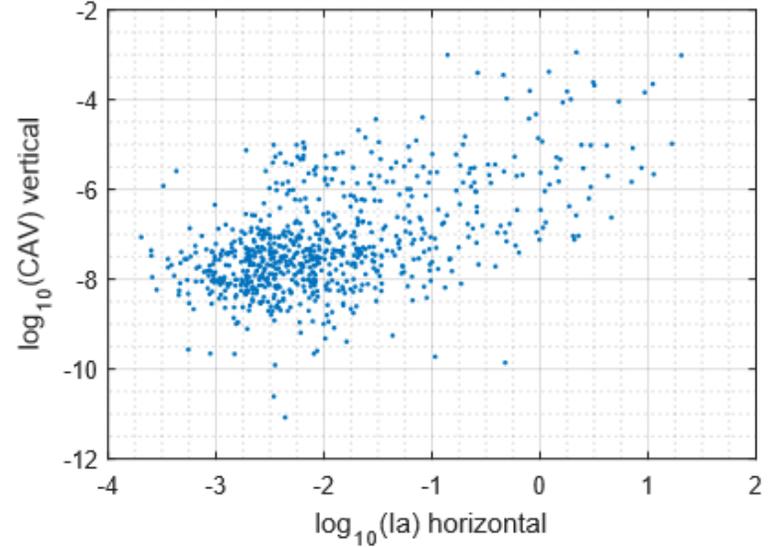
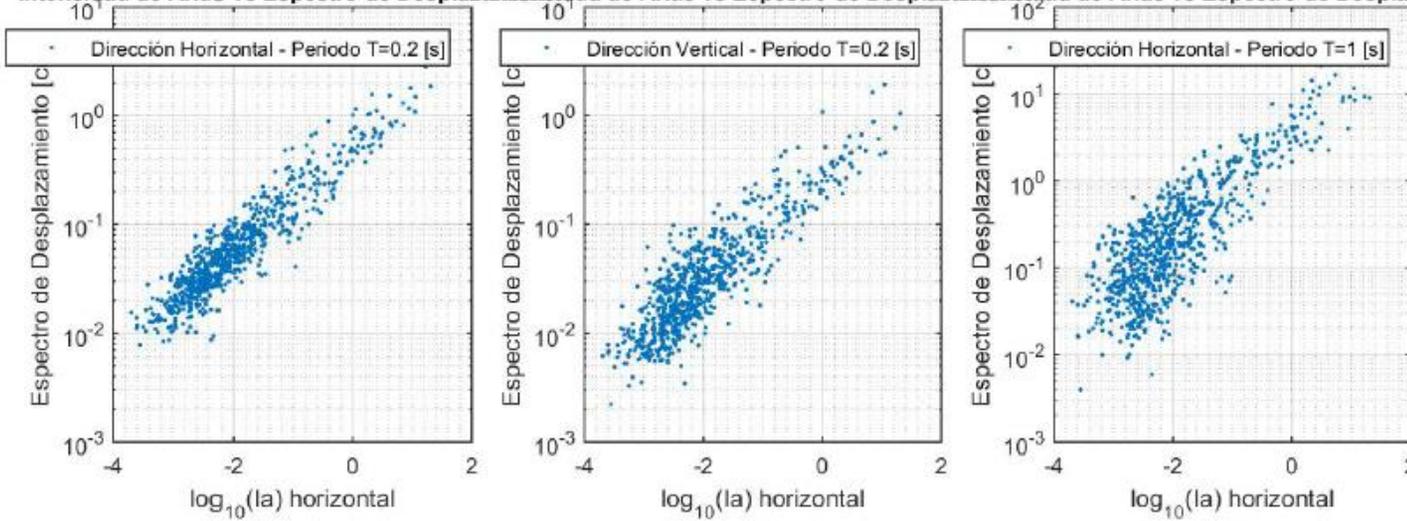


Figura C. 45: Relación entre log(la) Horizontal y (a) log(la) Vertical, (b) log(SI), log(CAV) Horizontal, (d) log(CAV) Vertical

Intensidad de Arias vs Espectro de Desplazamiento



Intensidad de Arias vs Espectro de Velocidad

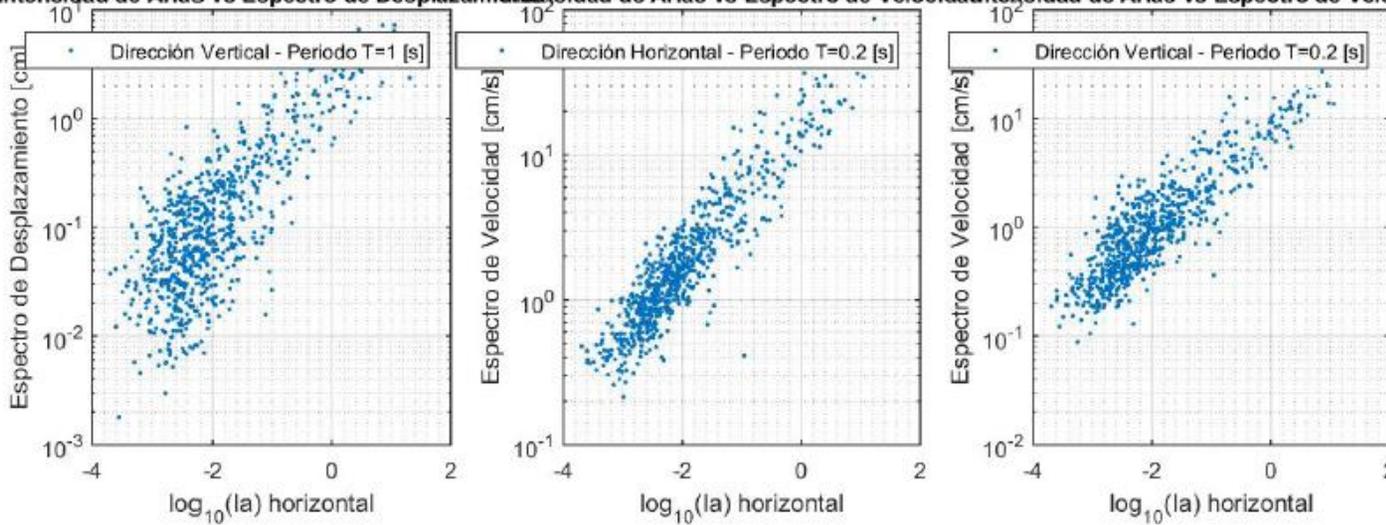


Figura C. 46: Relación entre $\log(I_a)$ Horizontal y (a) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (b) Espectro de Desplazamiento Vertical $T=0.2$ [s], (c) Espectro de Desplazamiento Horizontal $T=1$ [s], (d) Espectro de Desplazamiento Vertical $T=1$ [s], (e) Espectro de Velocidad Horizontal $T=0.2$ [s], (f) Espectro de Velocidad Vertical $T=0.2$ [s]

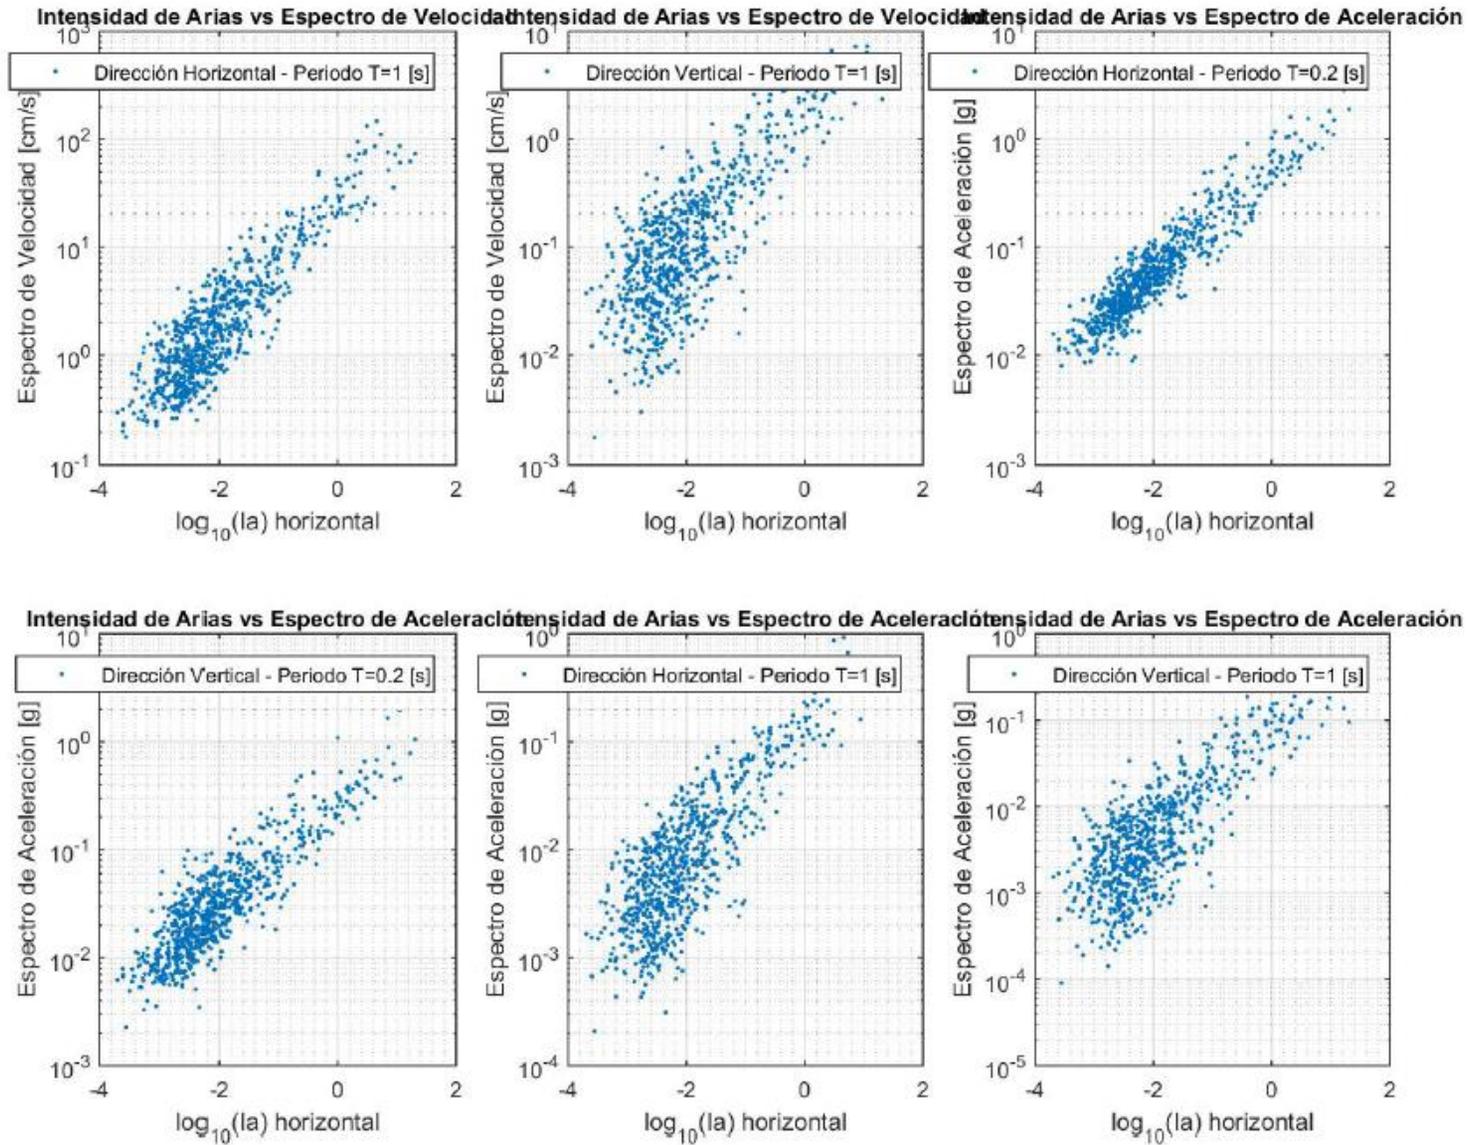


Figura C. 47: Relación entre $\log(Ia)$ Horizontal y (a) Espectro de Velocidad Horizontal $T=1$ [s], (b) Espectro de Velocidad Vertical $T=1$ [s], (c) Espectro de Aceleración Horizontal $T=0.2$ [s], (d) Espectro de Aceleración Vertical $T=0.2$ [s], (e) Espectro de Aceleración Horizontal $T=1$ [s], (f) Espectro de Aceleración Vertical $T=1$ [s]

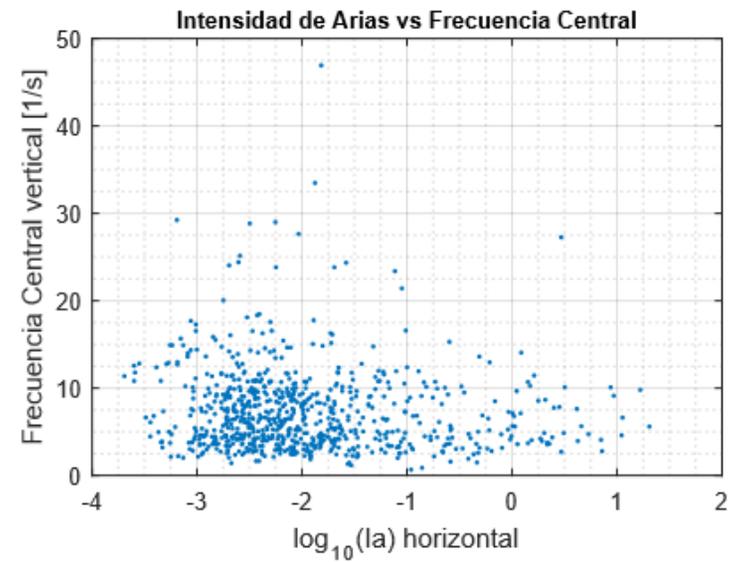
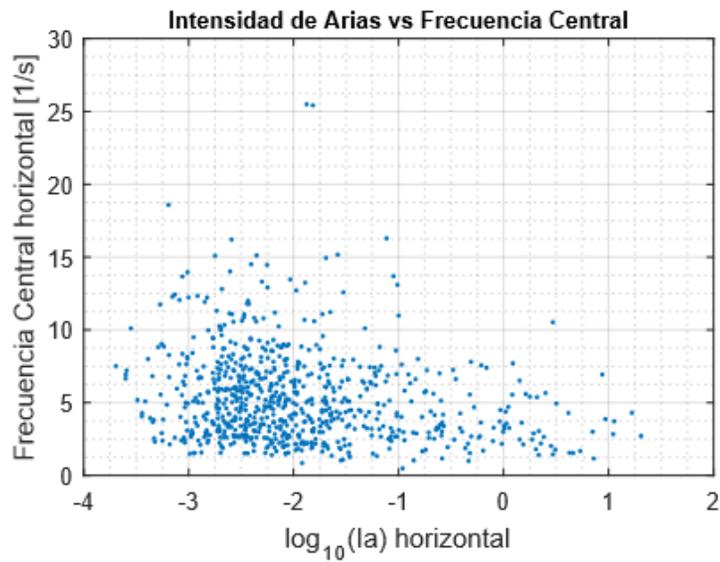
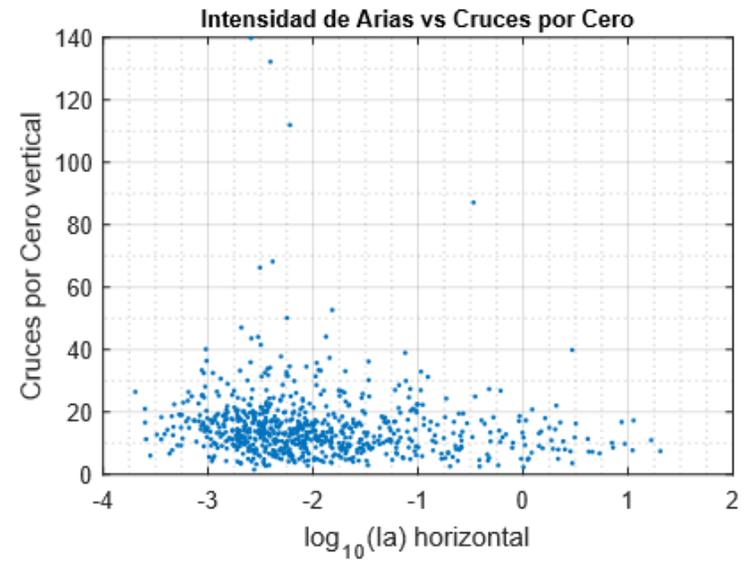
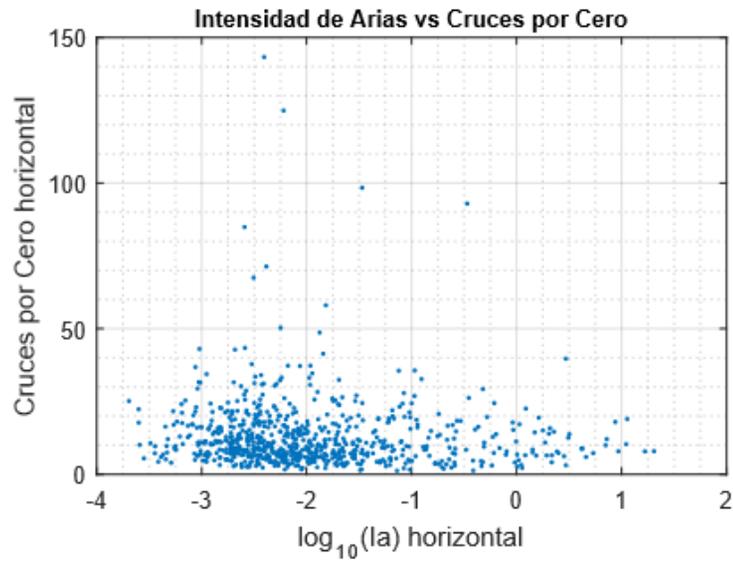


Figura C. 48: Relación entre $\log(I_a)$ Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

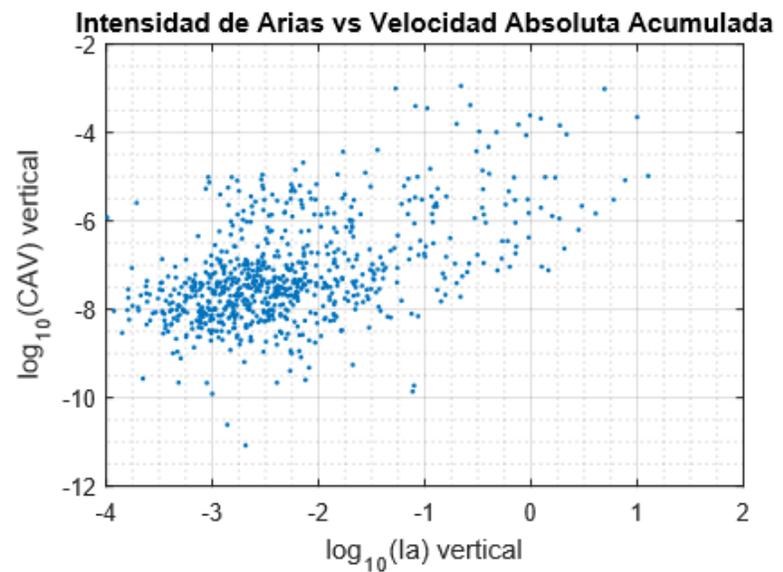
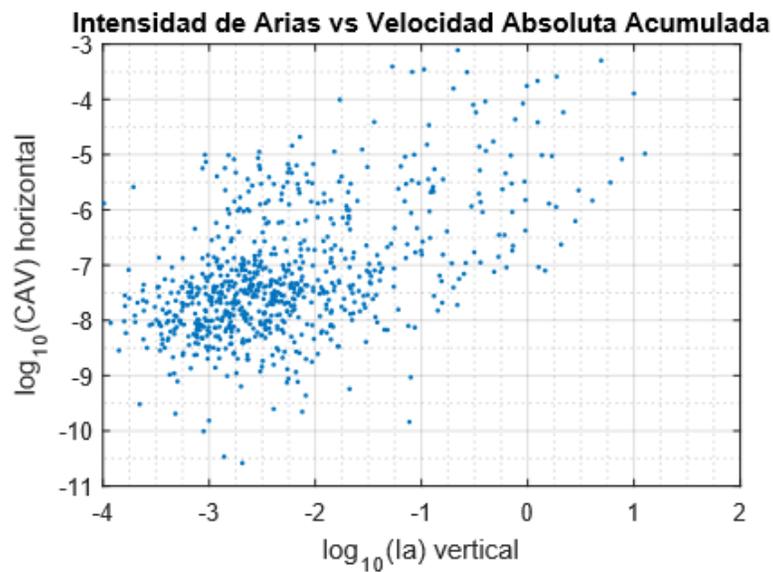
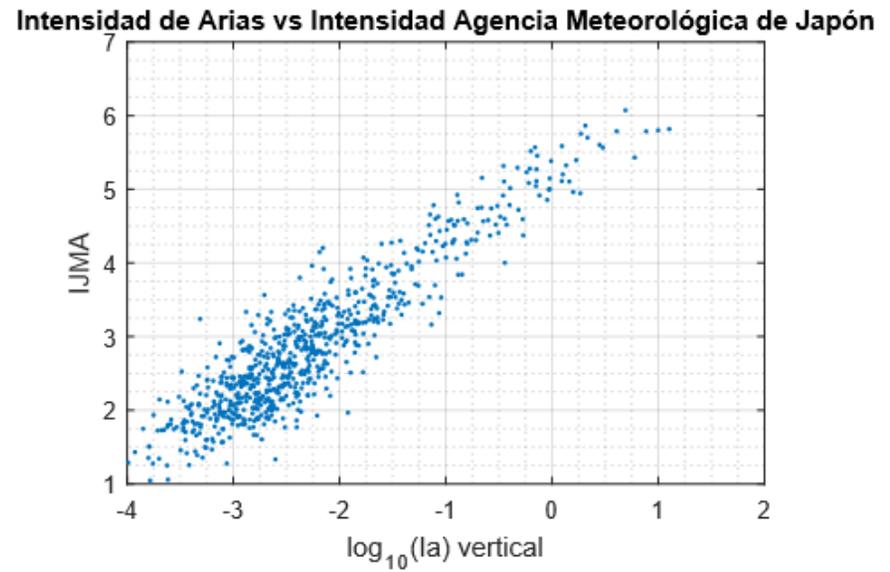
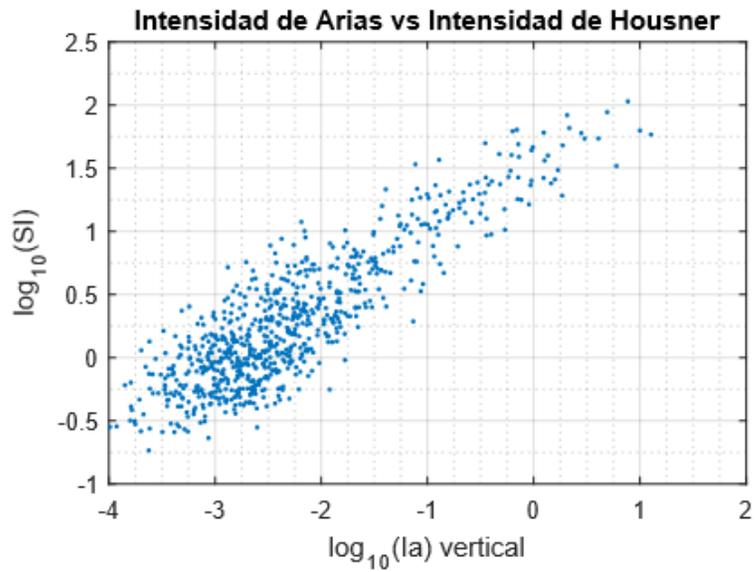


Figura C. 49: Relación entre $\log(la)$ Vertical y (a) $\log(SI)$, (b) IJMA, (c) $\log(CAV)$ Horizontal, (d) $\log(CAV)$ Vertical.

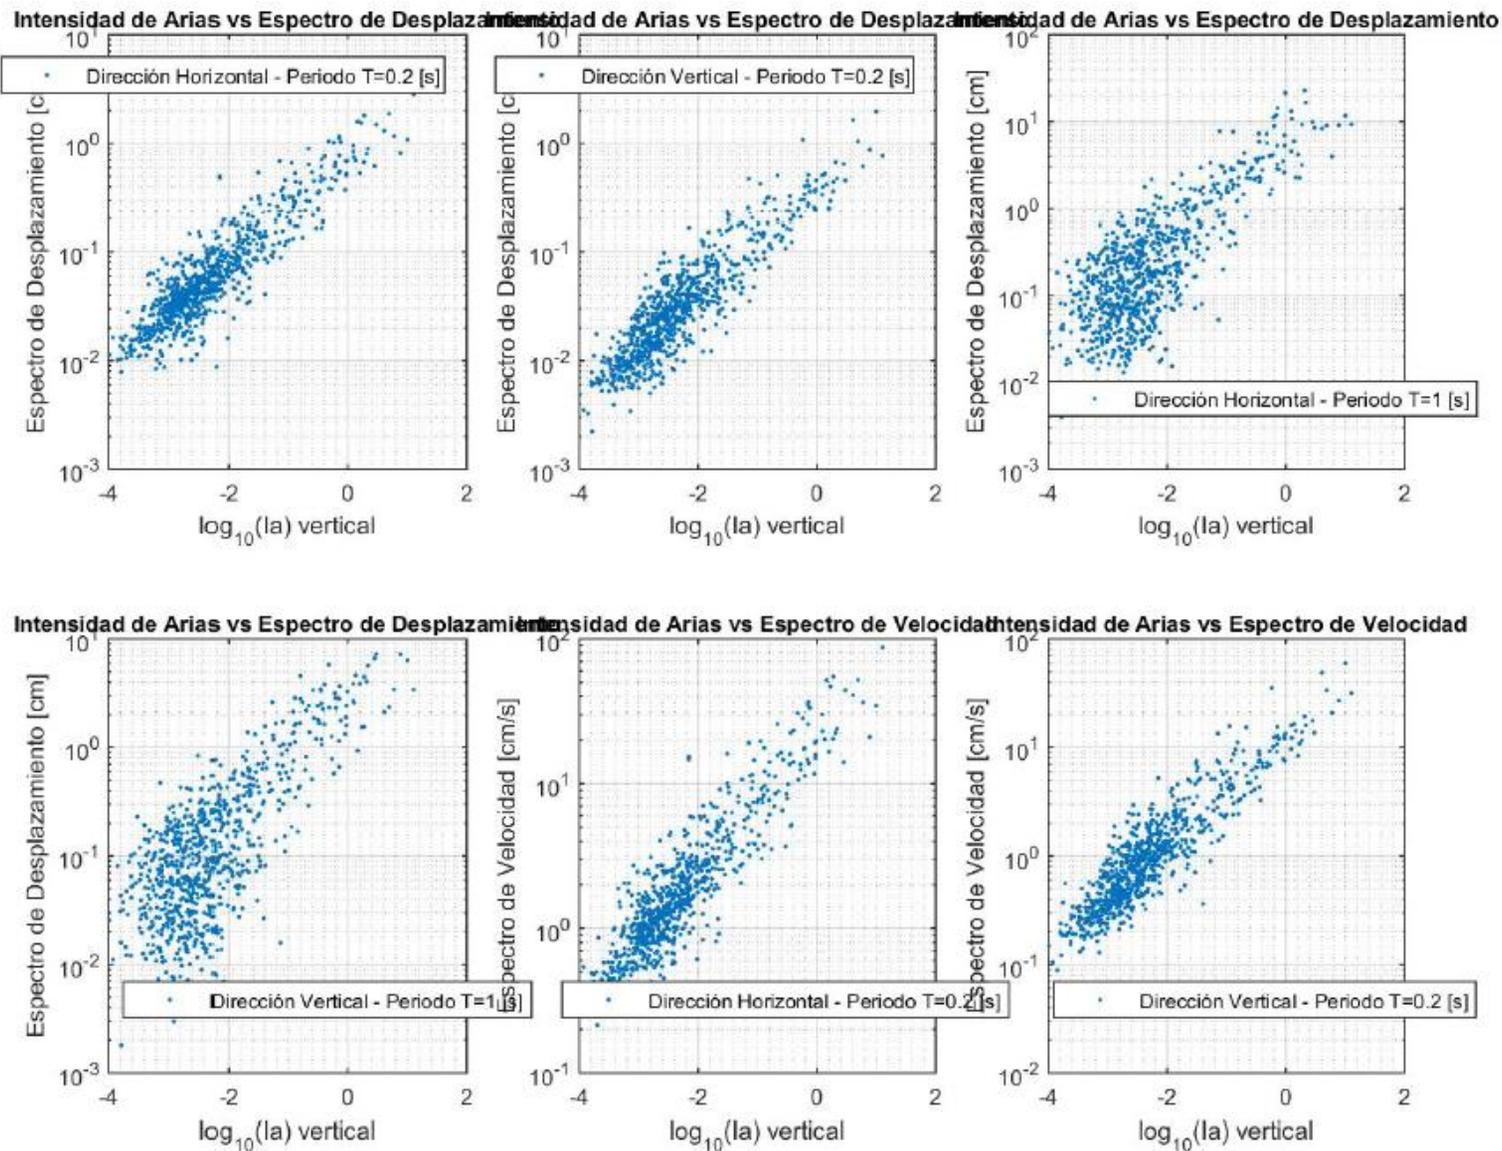


Figura C. 50: Relación entre $\log(I_a)$ Vertical y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s]

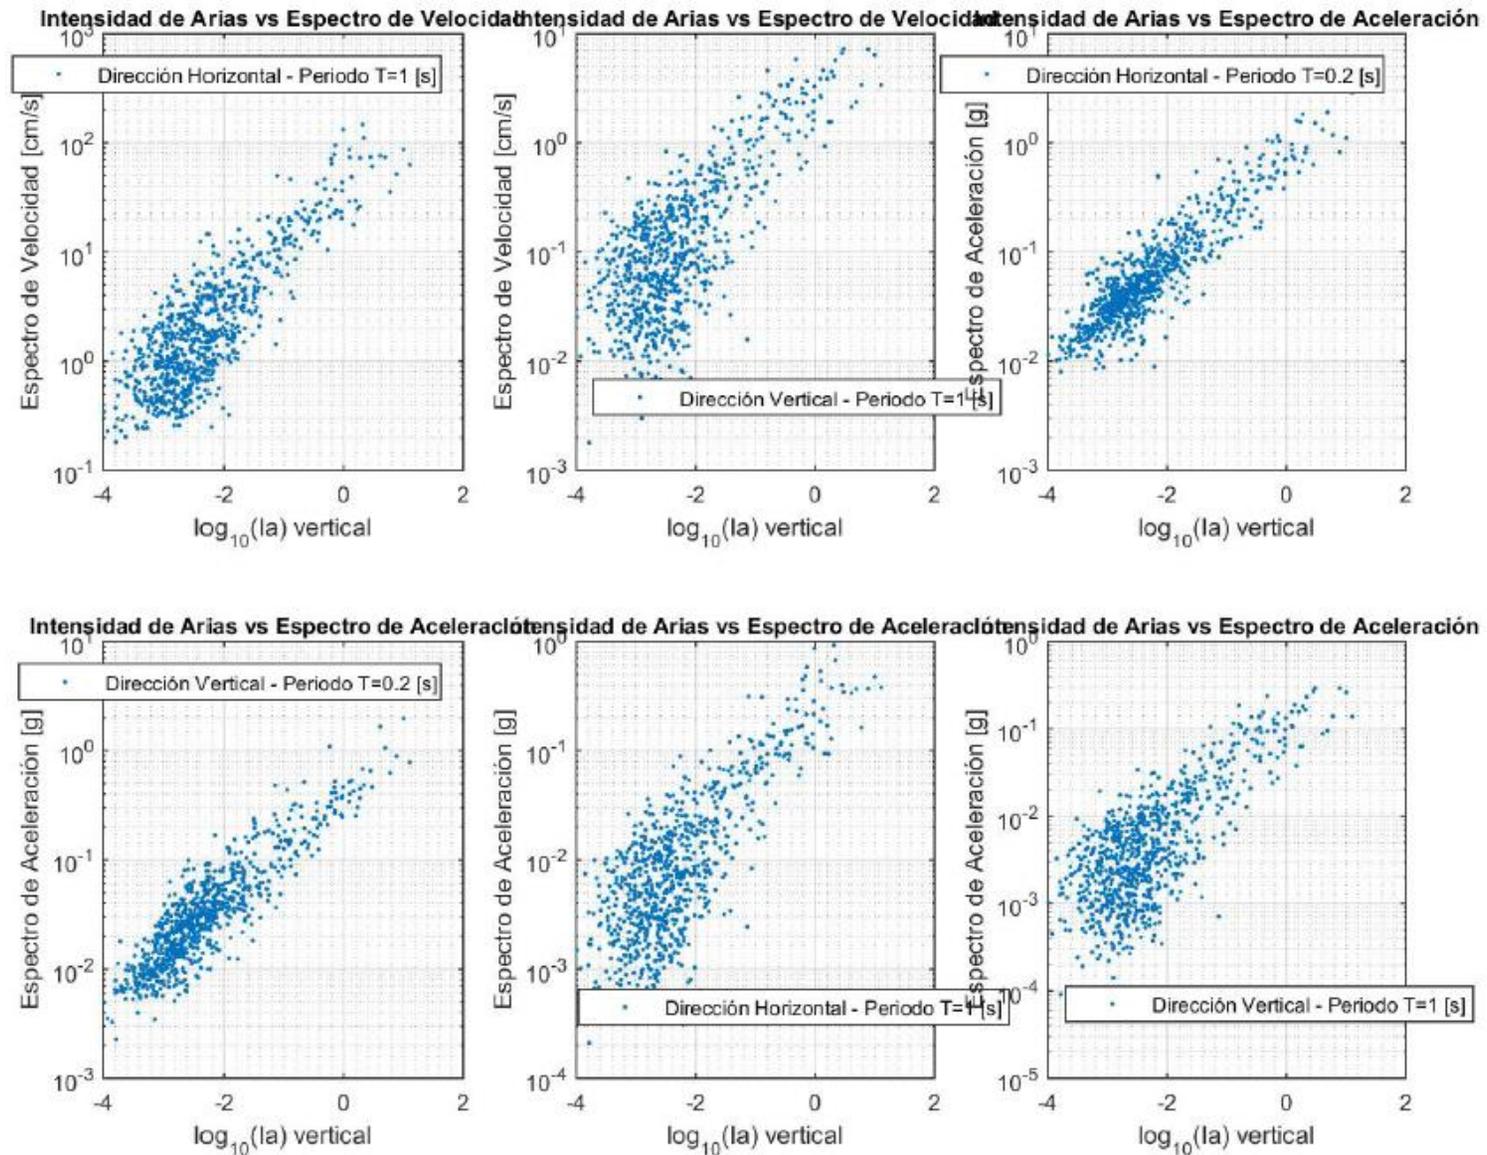


Figura C. 51: Relación entre $\log(Ia)$ Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s]

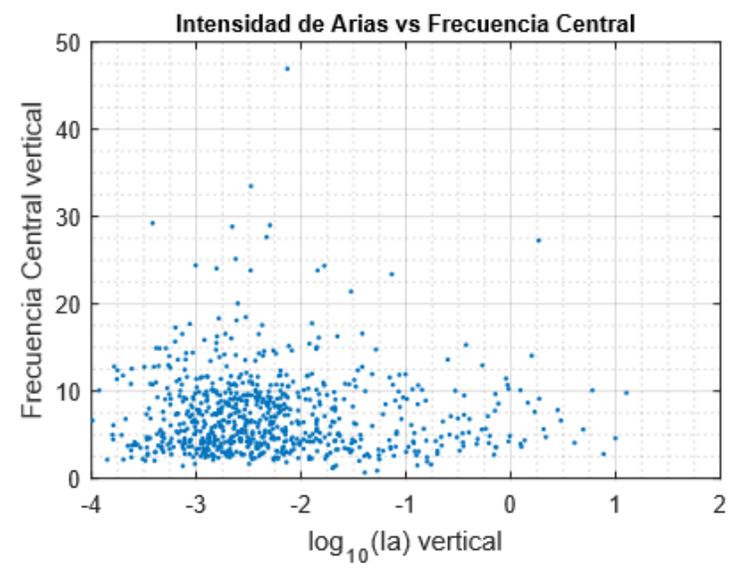
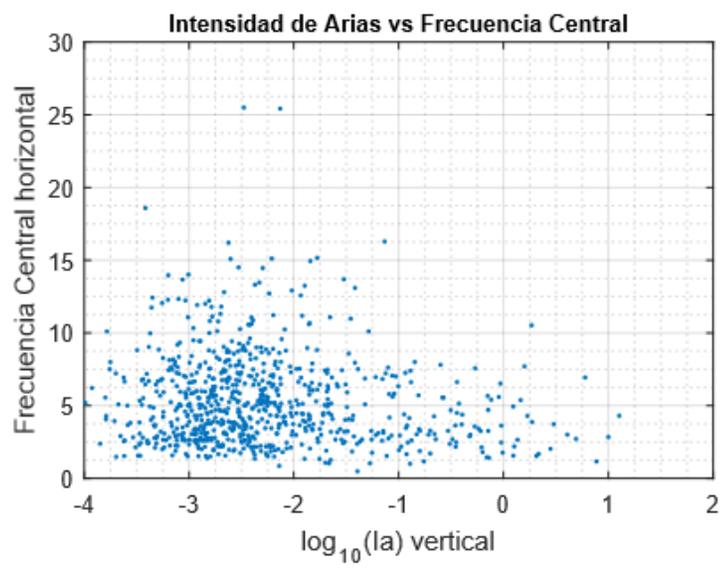
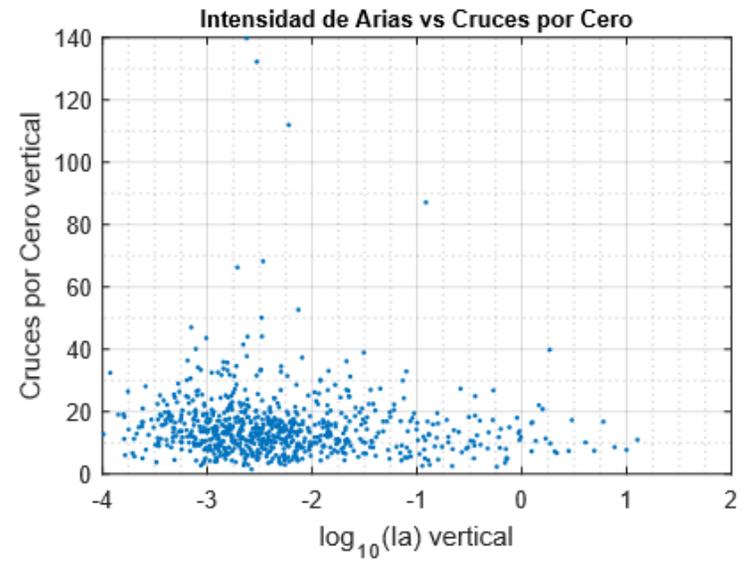
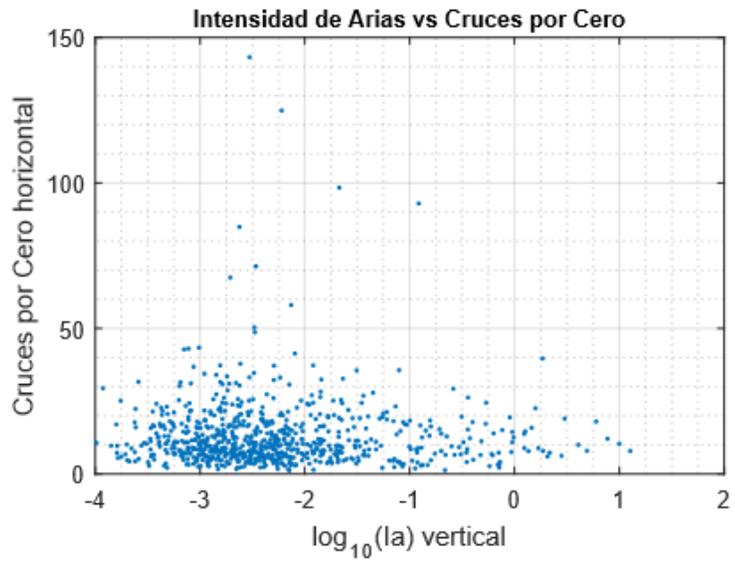


Figura C. 52: Relación entre $\log(I_a)$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical

Intensidad de Housner vs Intensidad Agencia Meteorológica de Japan vs Velocidad Absoluta Acumulada vs Intensidad de Housner vs Velocidad Absoluta Acumulada

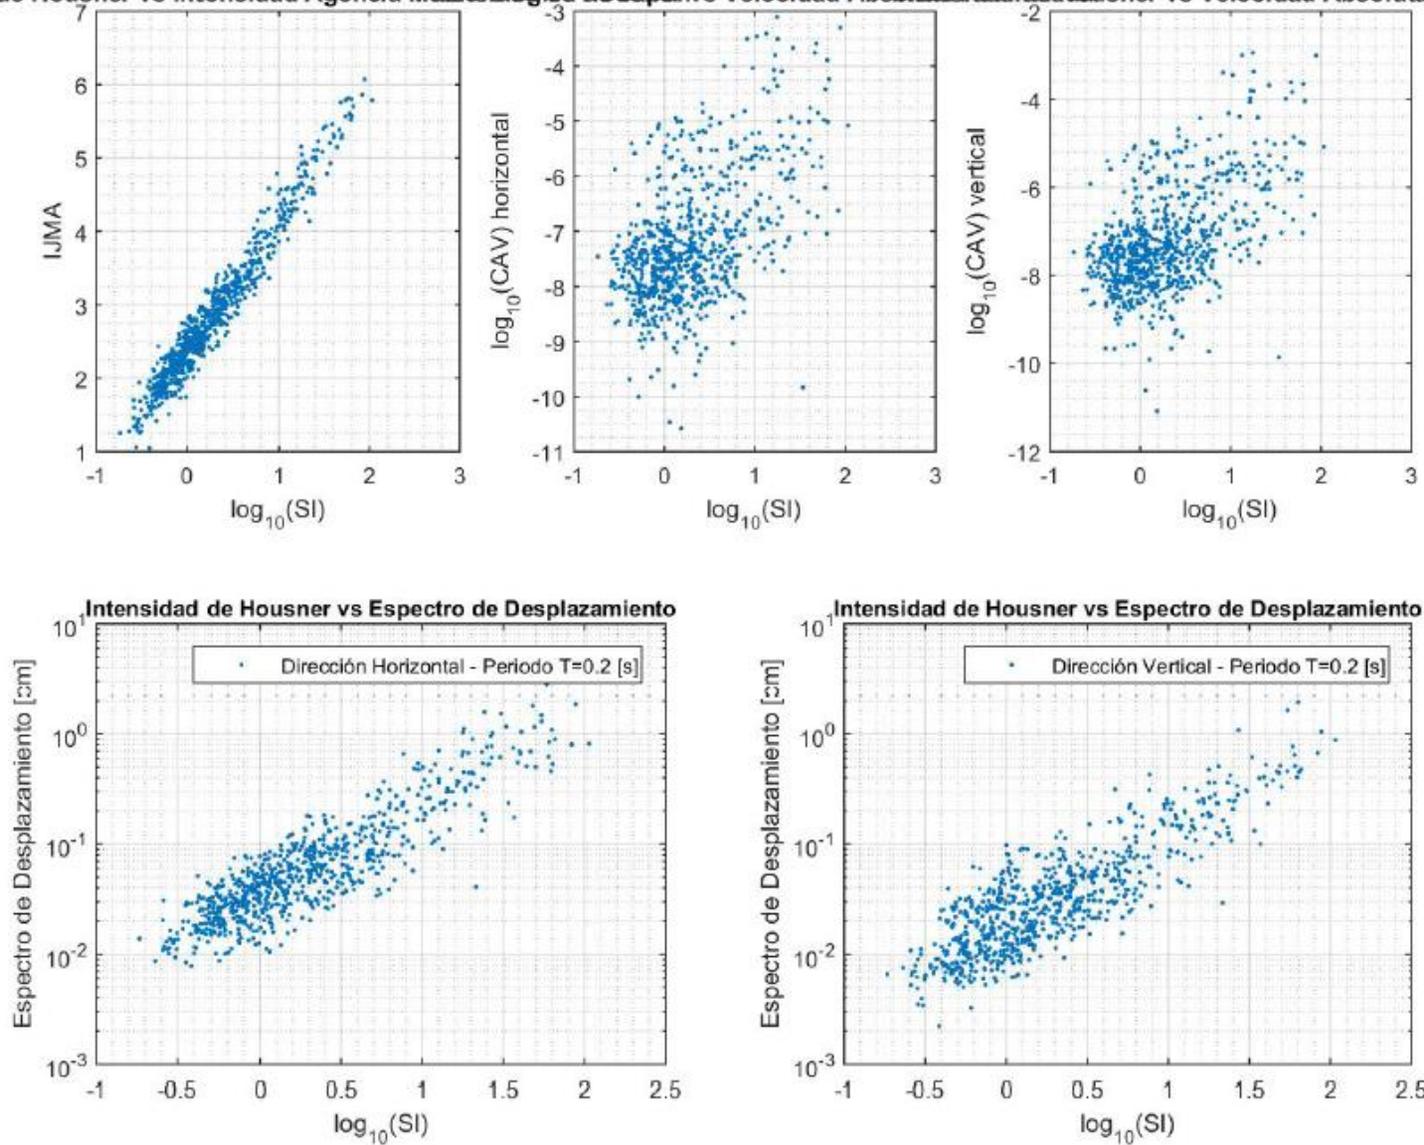


Figura C. 53: Relación entre $\log(SI)$ y (a) IJMA, (b) $\log(CAV)$ Horizontal, (c) $\log(CAV)$ Vertical, (d) Espectro de Desplazamiento Horizontal T=0.2 [s], (e) Espectro de Desplazamiento Vertical T=0.2 [s].

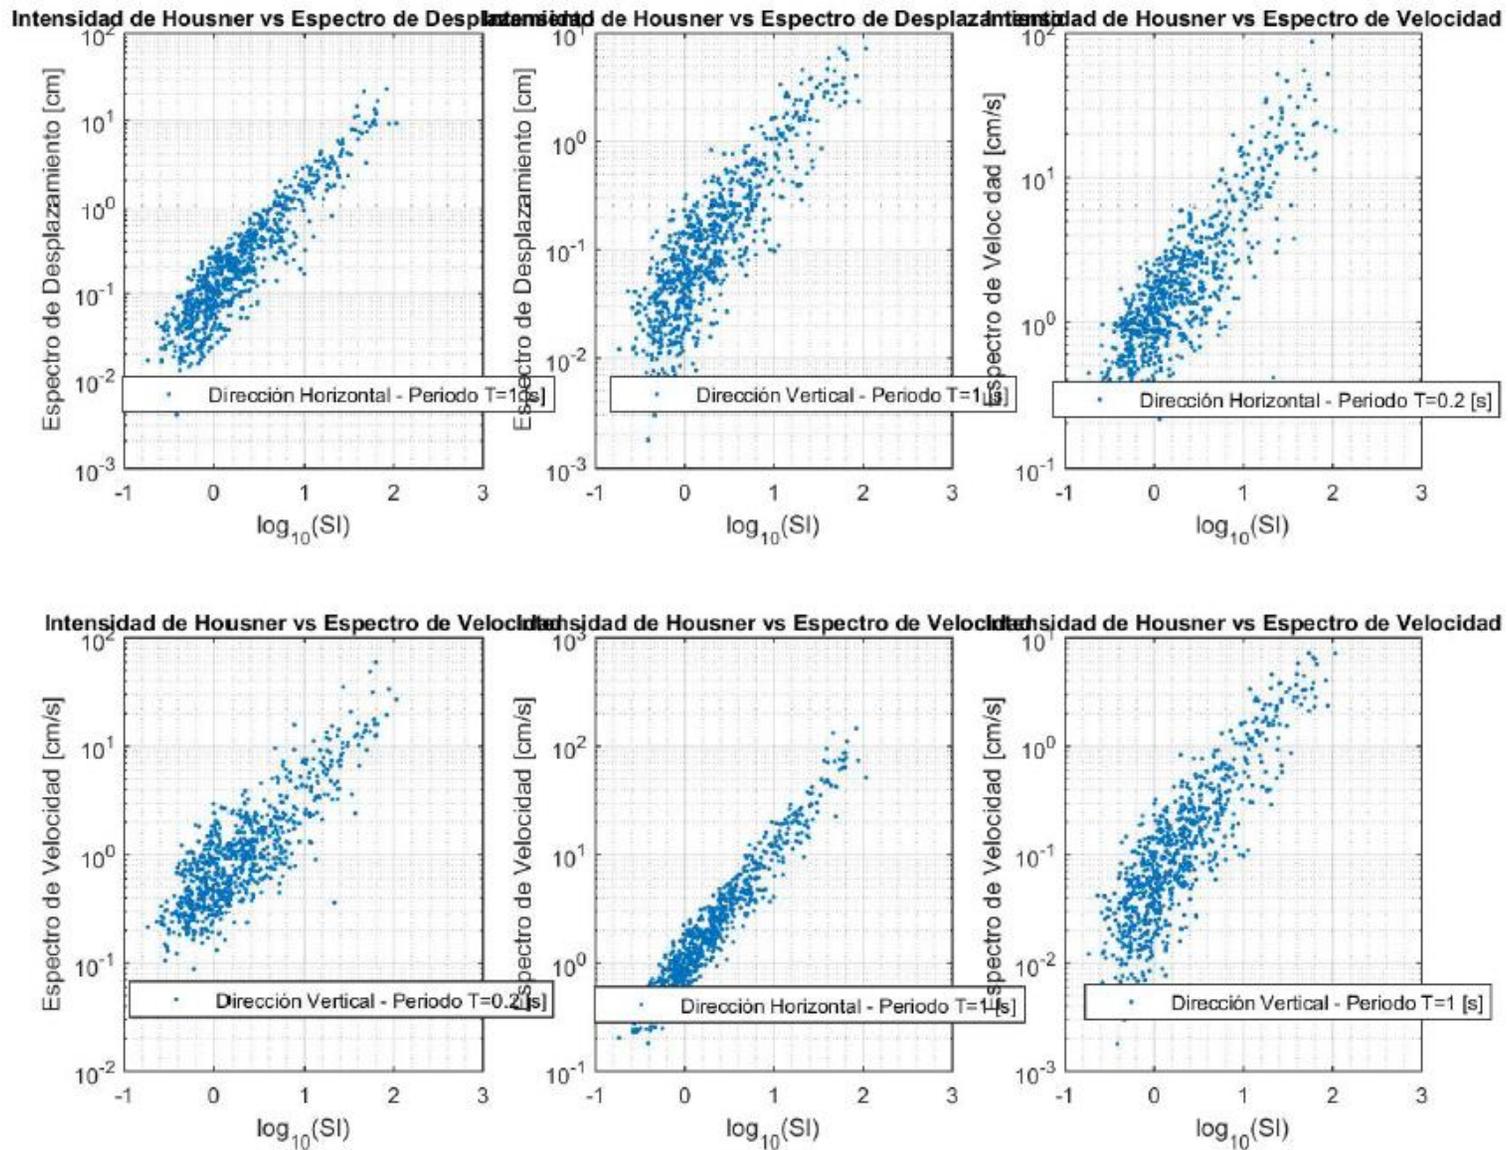


Figura C. 54: Relación entre $\log(SI)$ y (a) Espectro de Desplazamiento Horizontal $T=1$ [s], (b) Espectro de Desplazamiento Vertical $T=1$ [s], (c) Espectro de Velocidad Horizontal $T=0.2$ [s], (d) Espectro de Velocidad Vertical $T=0.2$ [s], (e) Espectro de Velocidad Horizontal $T=1$ [s], (f) Espectro de Velocidad Vertical $T=1$ [s]

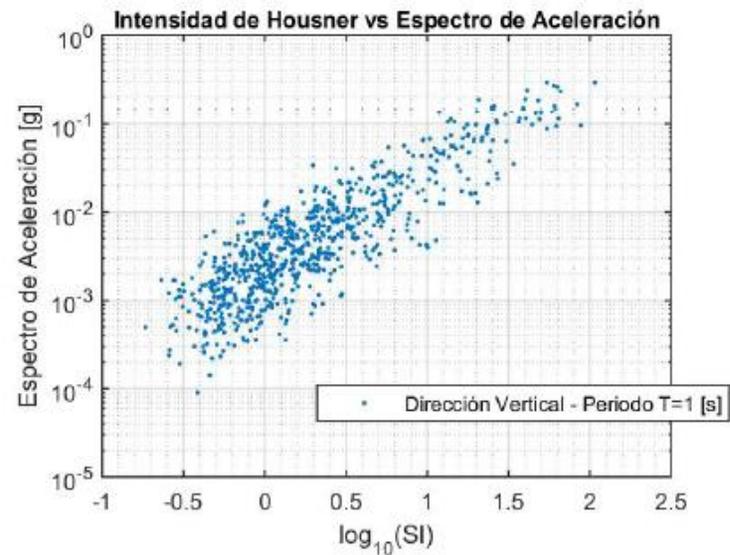
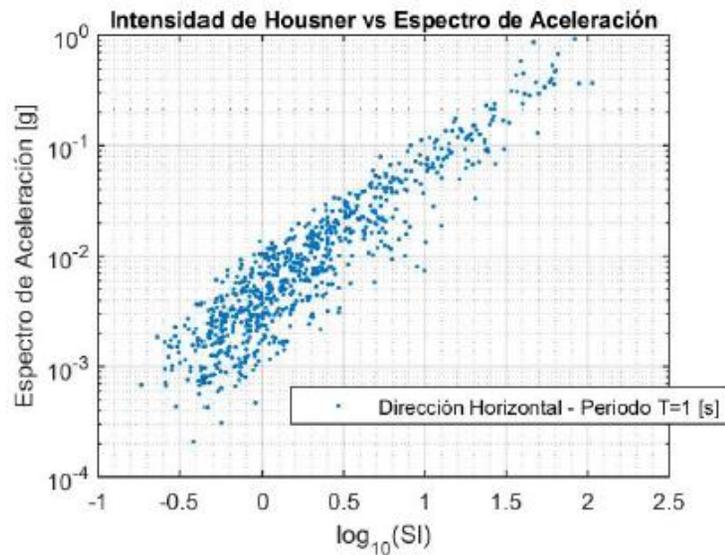
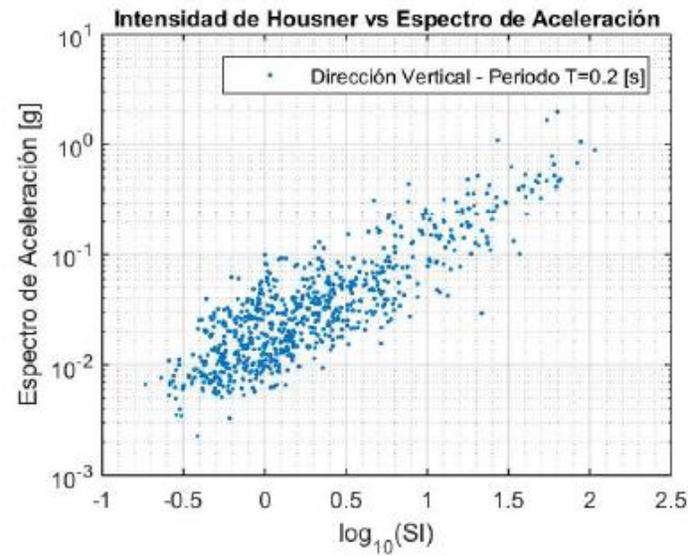
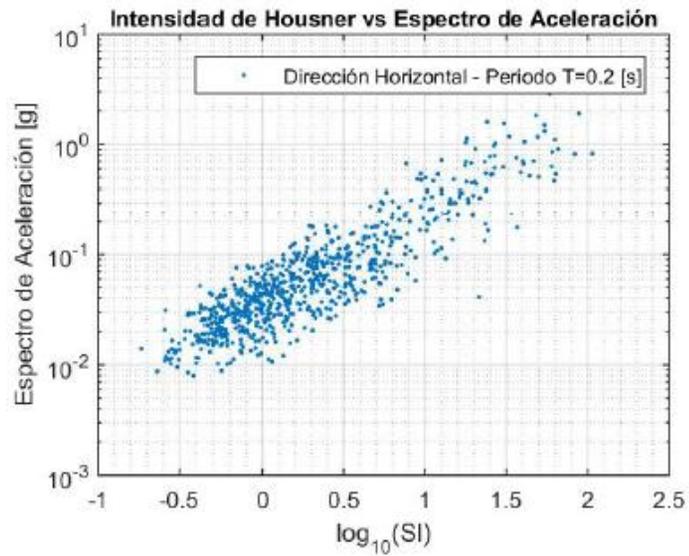


Figura C. 55: Relación entre $\log(SI)$ y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s]

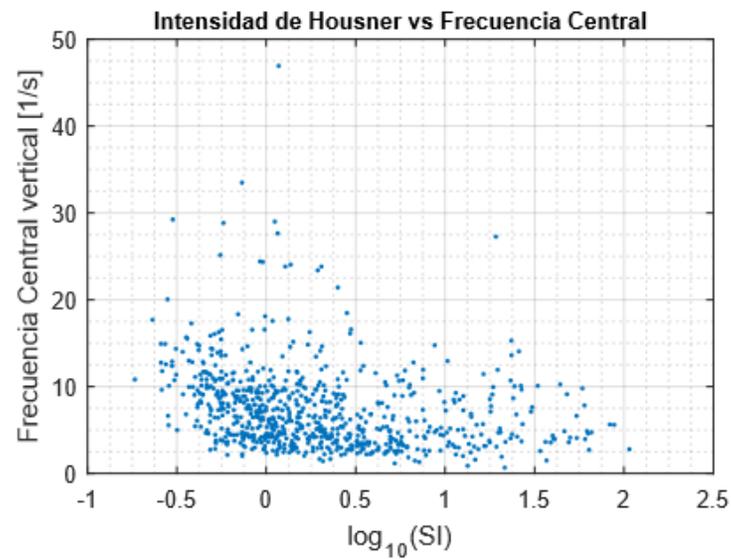
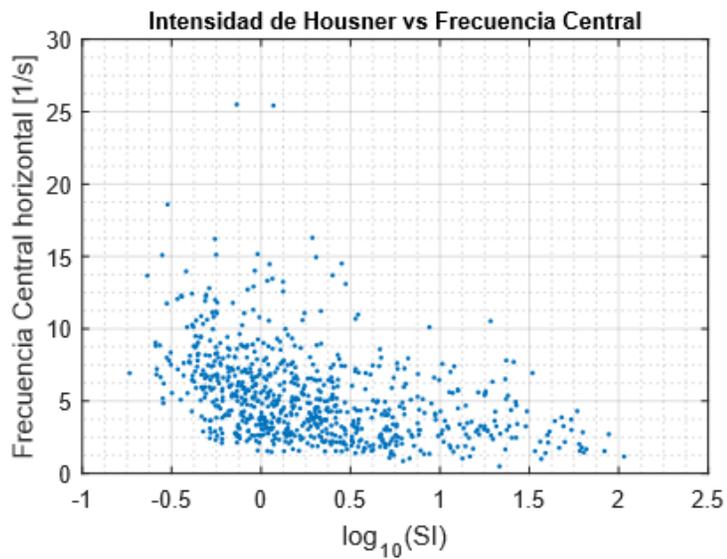
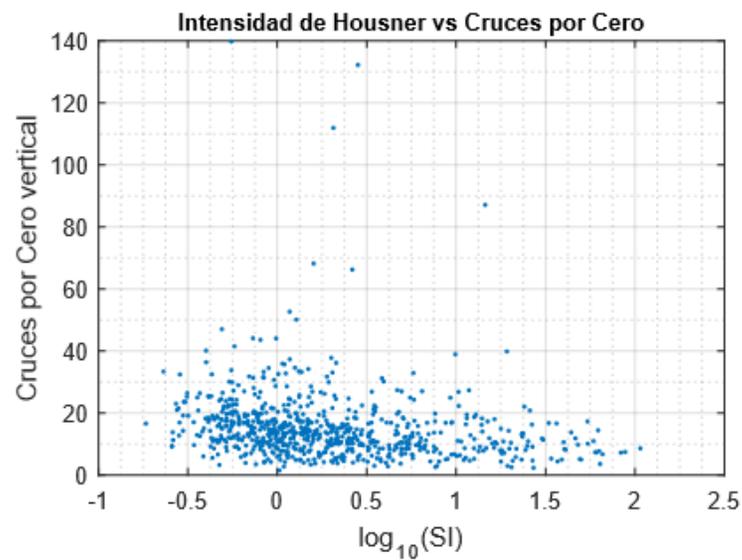
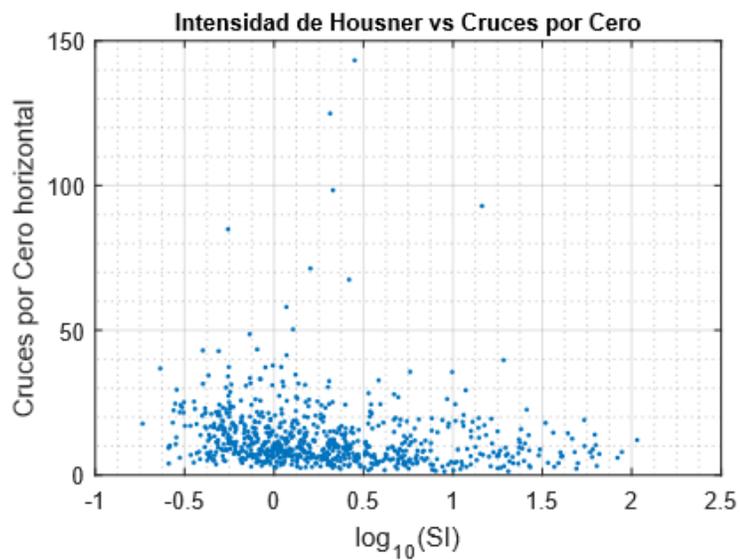


Figura C. 56: Relación entre $\log(SI)$ y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

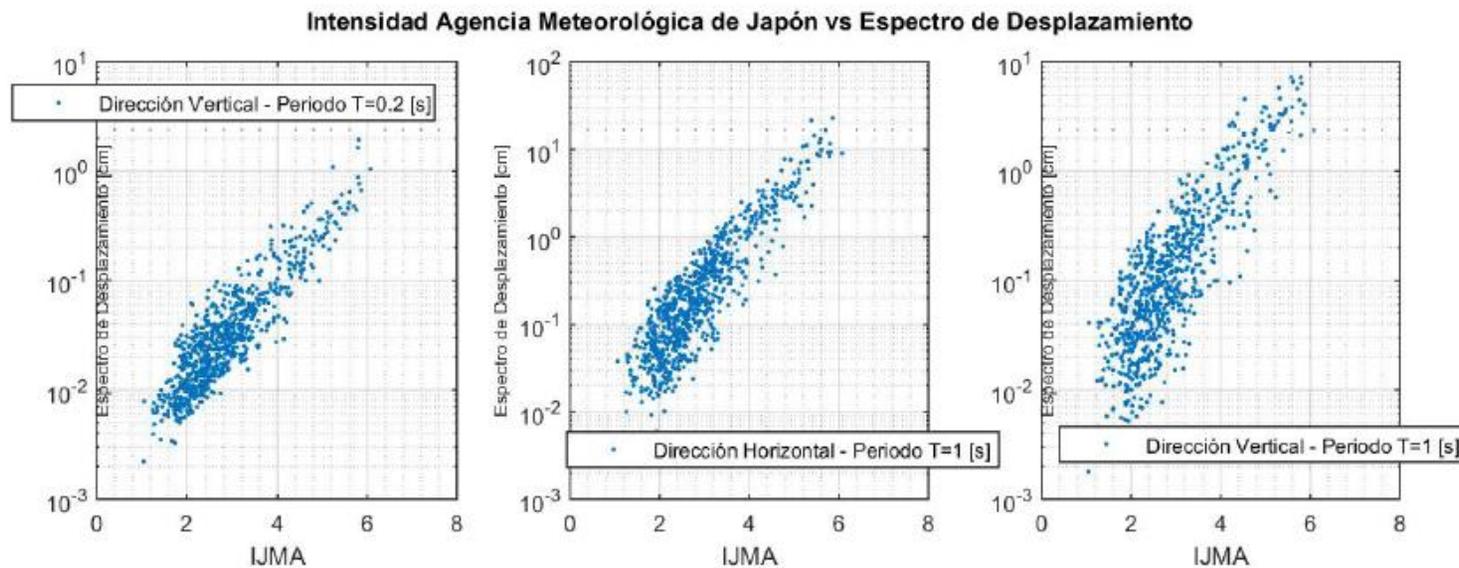
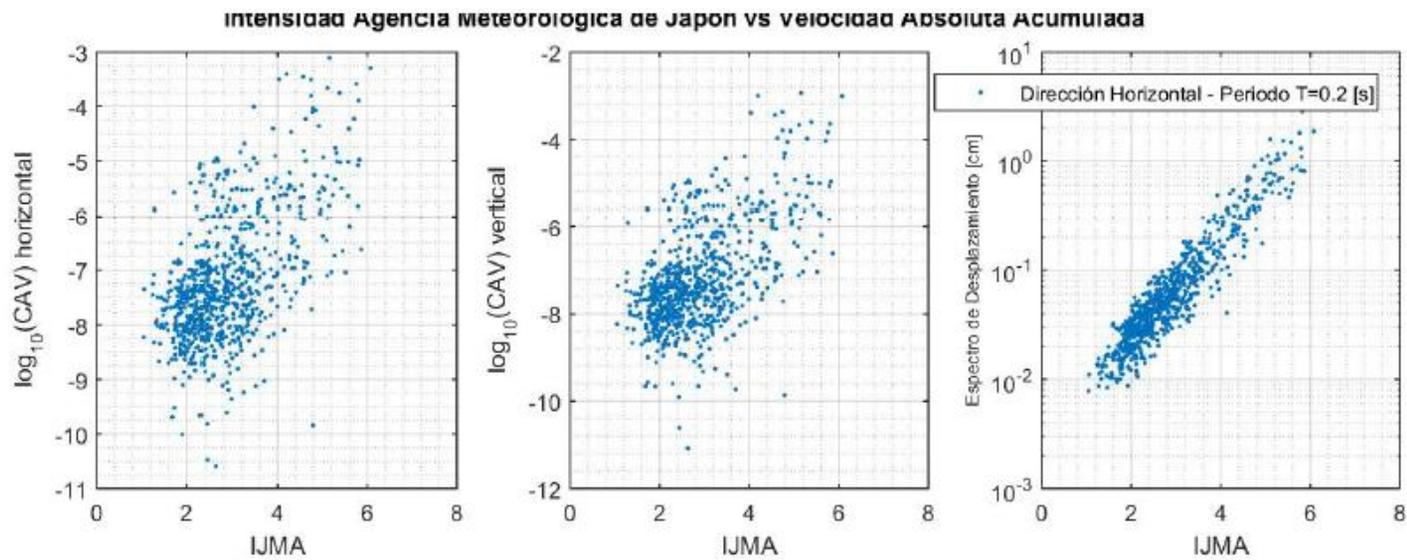


Figura C. 57: Relación entre IJMA y (a) $\log(\text{CAV})$ Horizontal, (b) $\log(\text{CAV})$ Vertical, (c) Espectro de Desplazamiento Horizontal T=0.2 [s], (d) Espectro de Desplazamiento Vertical T=0.2 [s], (e) Espectro de Desplazamiento Horizontal T=1 [s], (f) Espectro de Desplazamiento Vertical T=1 [s].

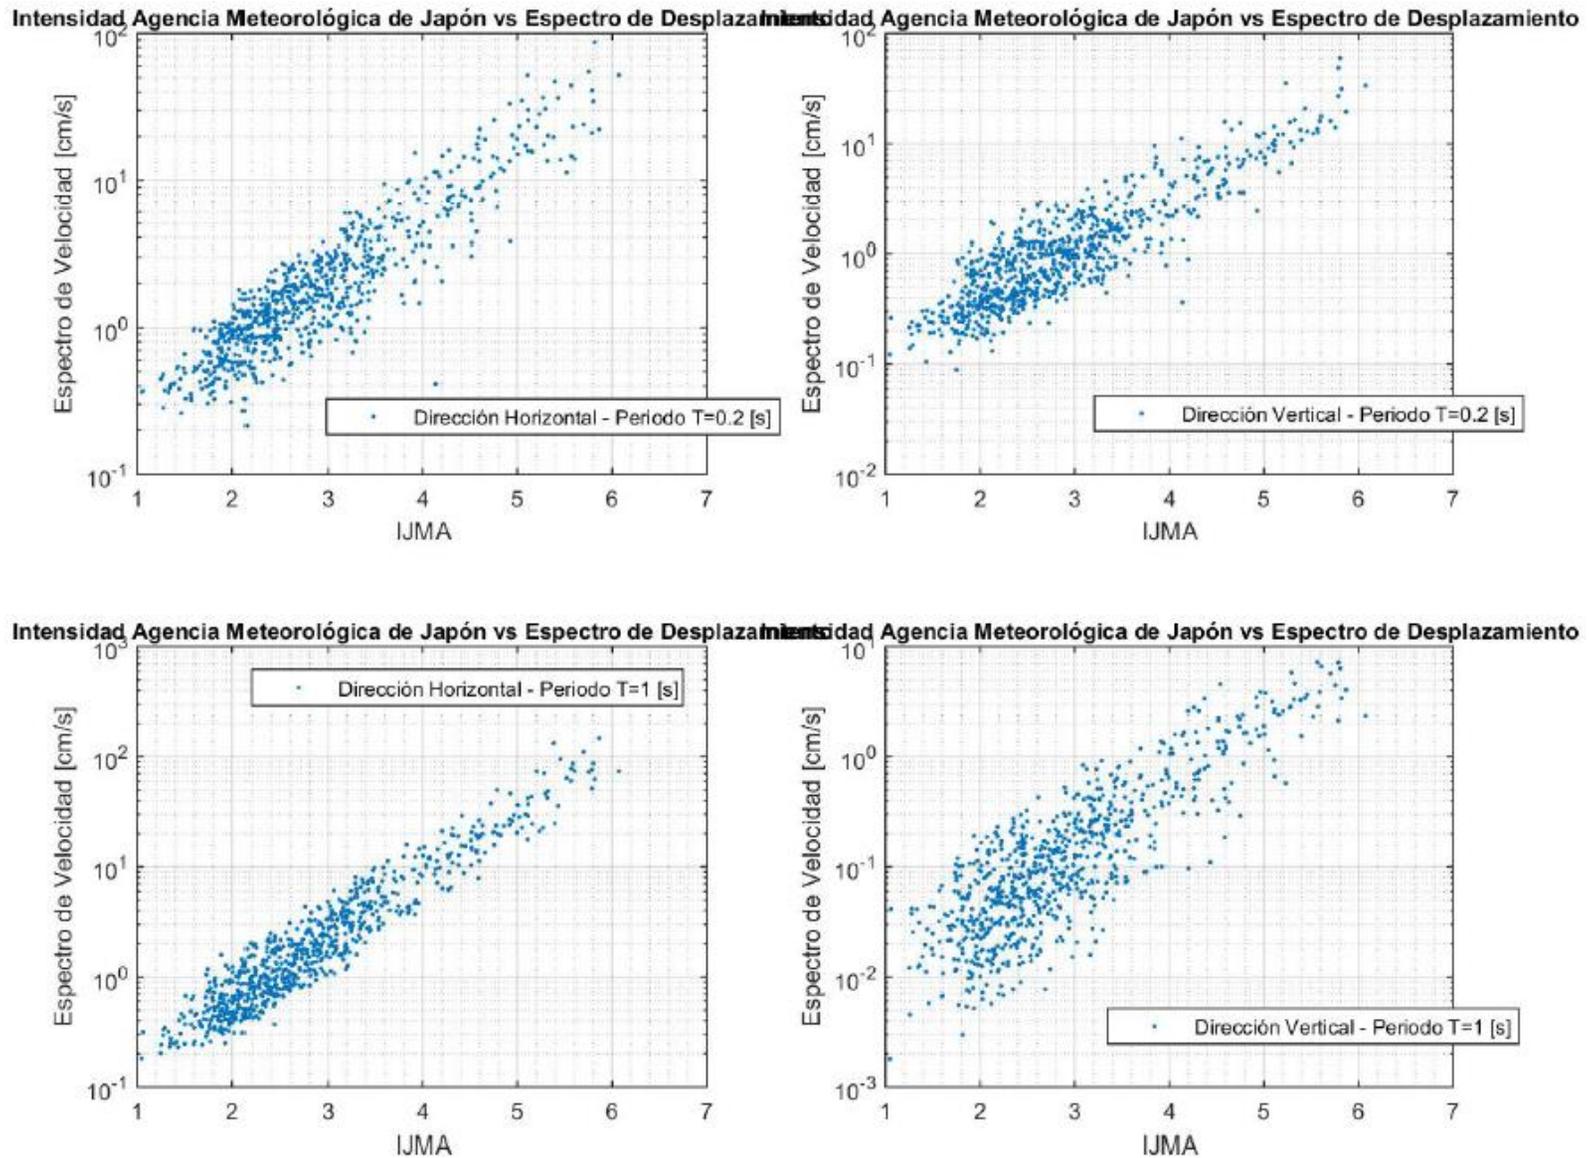


Figura C. 58: Relación entre IJMA y (a) Espectro de Velocidad Horizontal T=0.2 [s], (b) Espectro de Velocidad Vertical T=0.2 [s], (c) Espectro de Velocidad Horizontal T=1 [s], (d) Espectro de Velocidad Vertical T=1 [s].

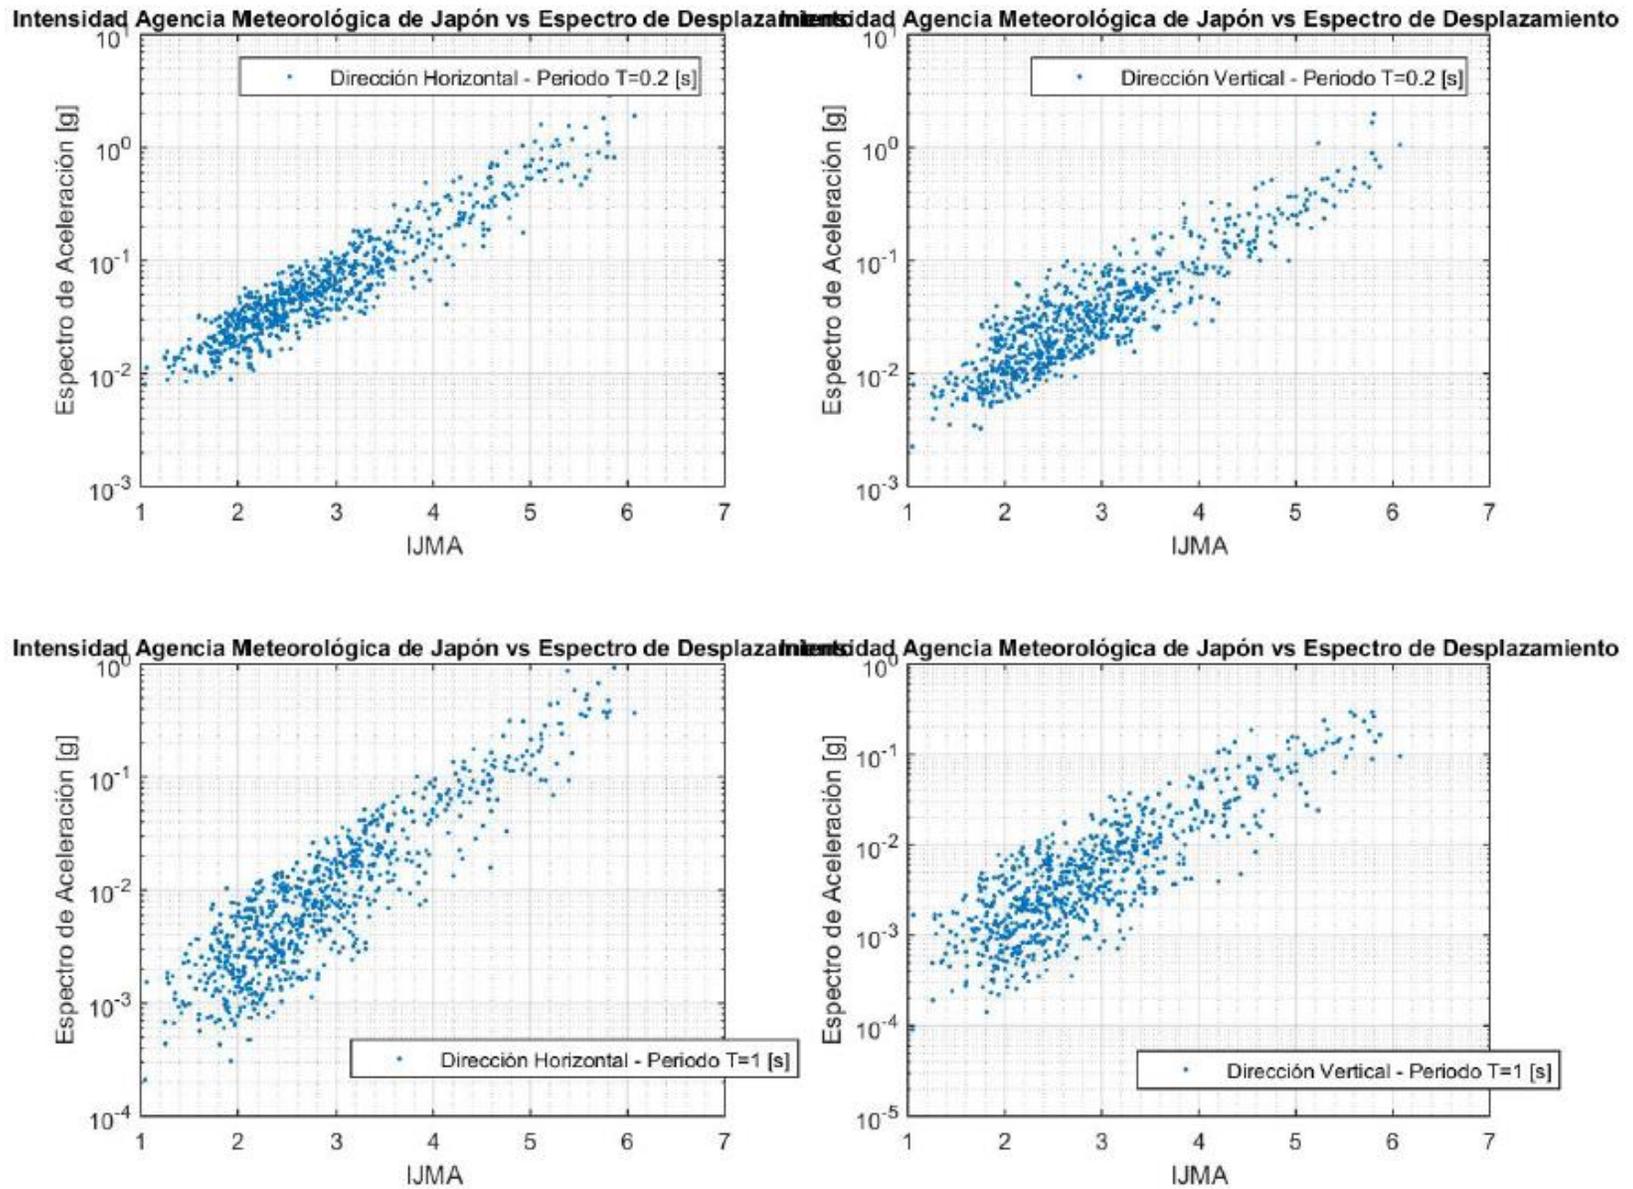


Figura C. 59: Relación entre IJMA y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].

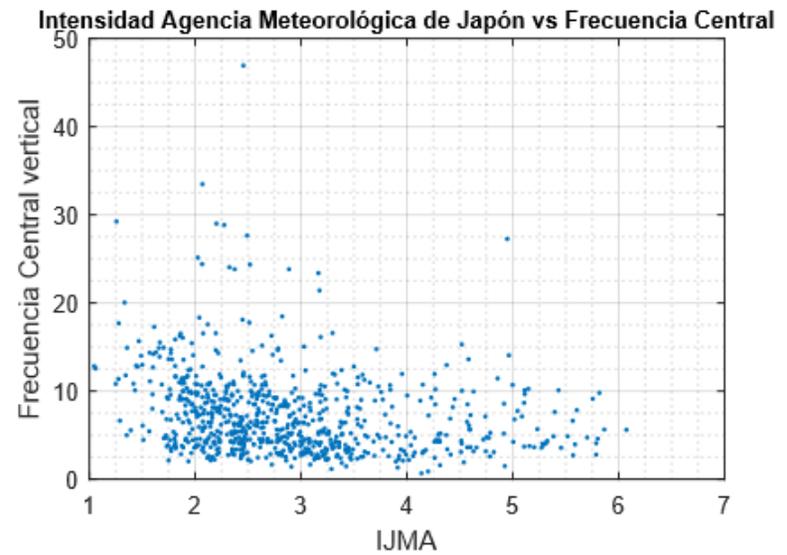
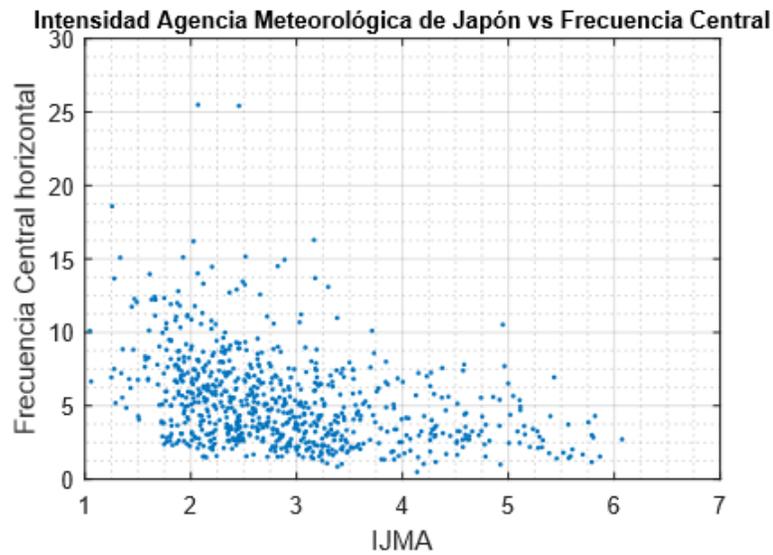
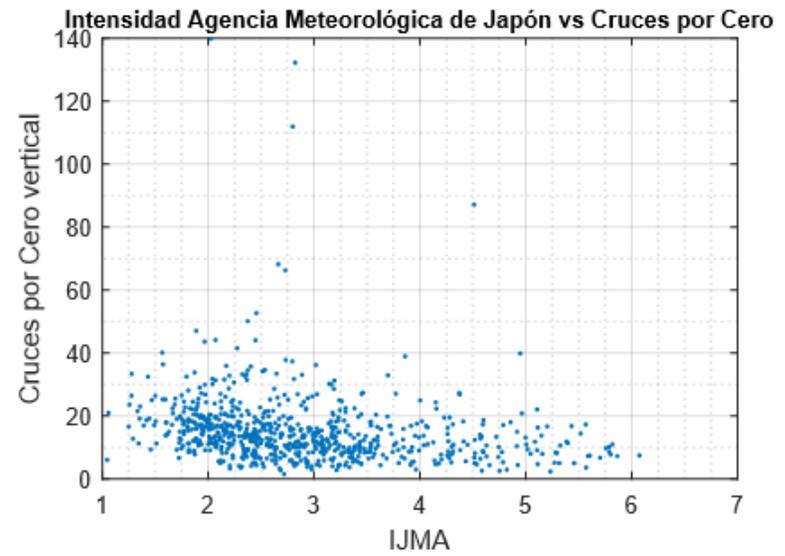
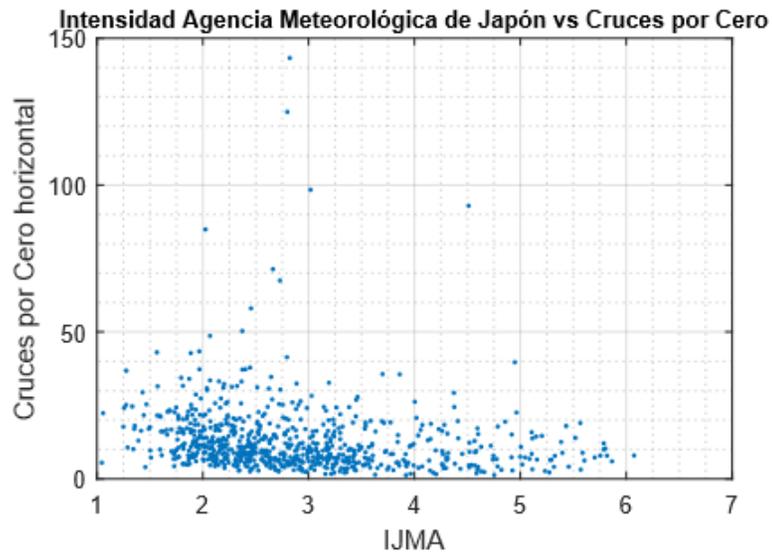


Figura C. 60: Relación entre IJMA y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical

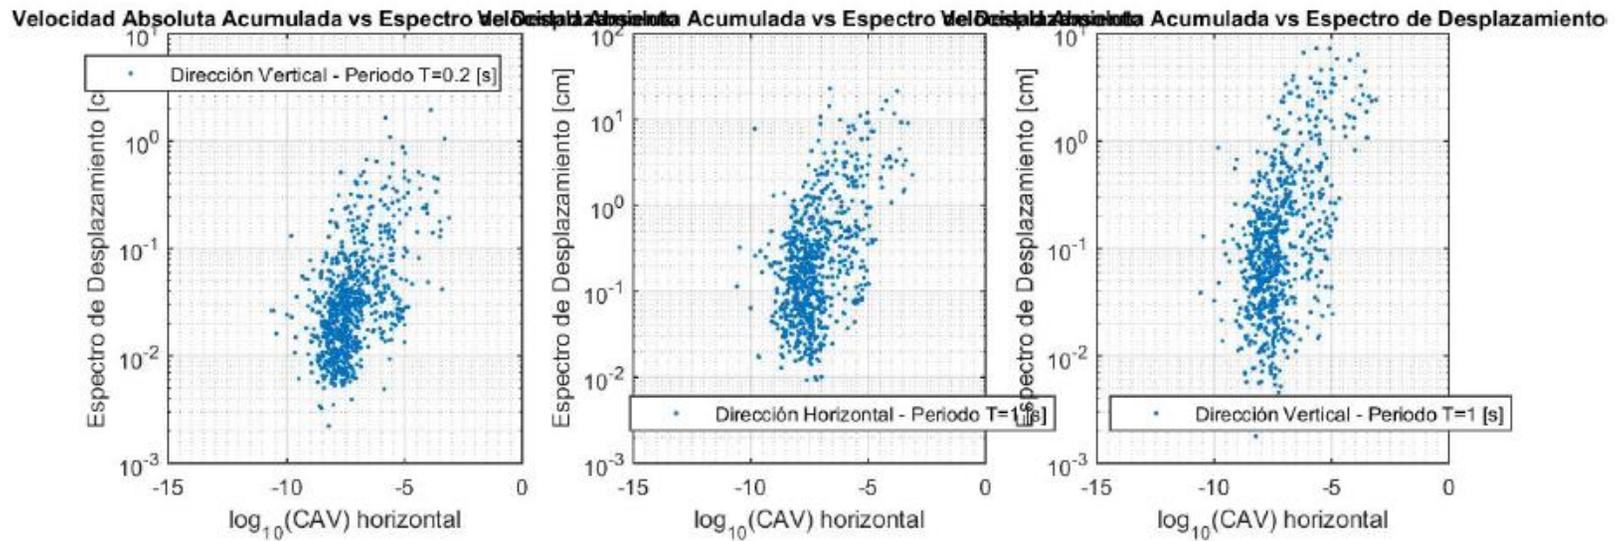
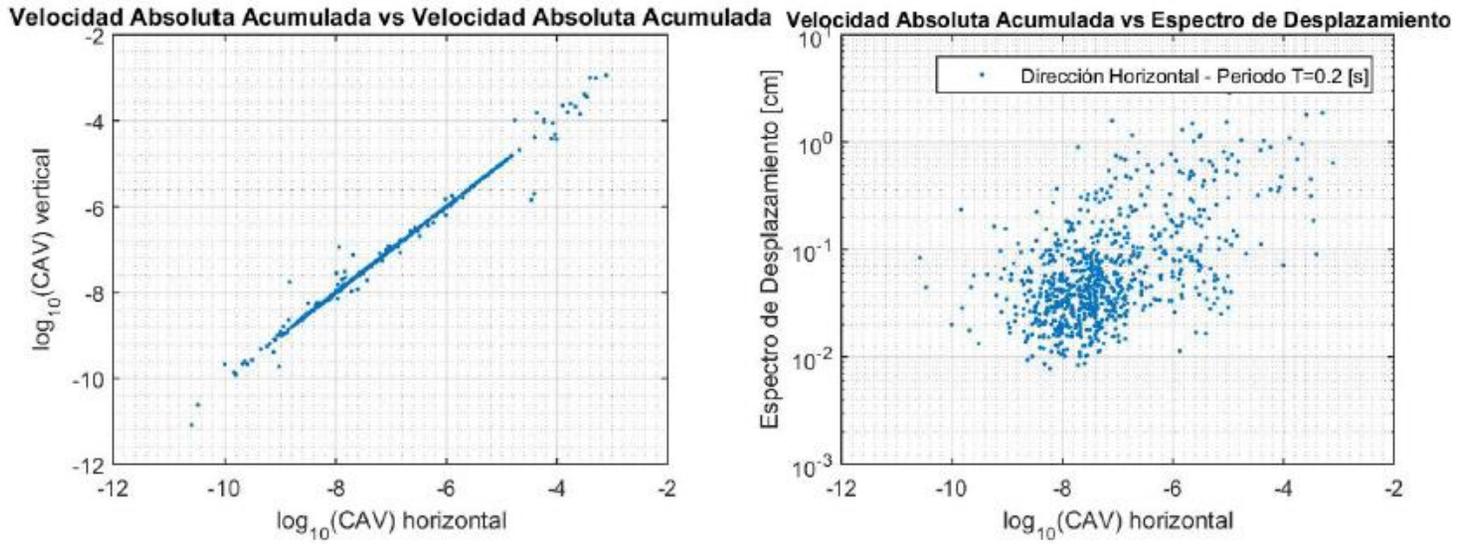


Figura C. 61: Relación entre $\log(\text{CAV})$ Horizontal y (a) $\log(\text{CAV})$ Vertical, (b) Espectro de Desplazamiento Horizontal $T=0.2$ [s], (c) Espectro de Desplazamiento Vertical $T=0.2$ [s], (d) Espectro de Desplazamiento Horizontal $T=1$ [s], (e) Espectro de Desplazamiento Vertical $T=1$ [s].

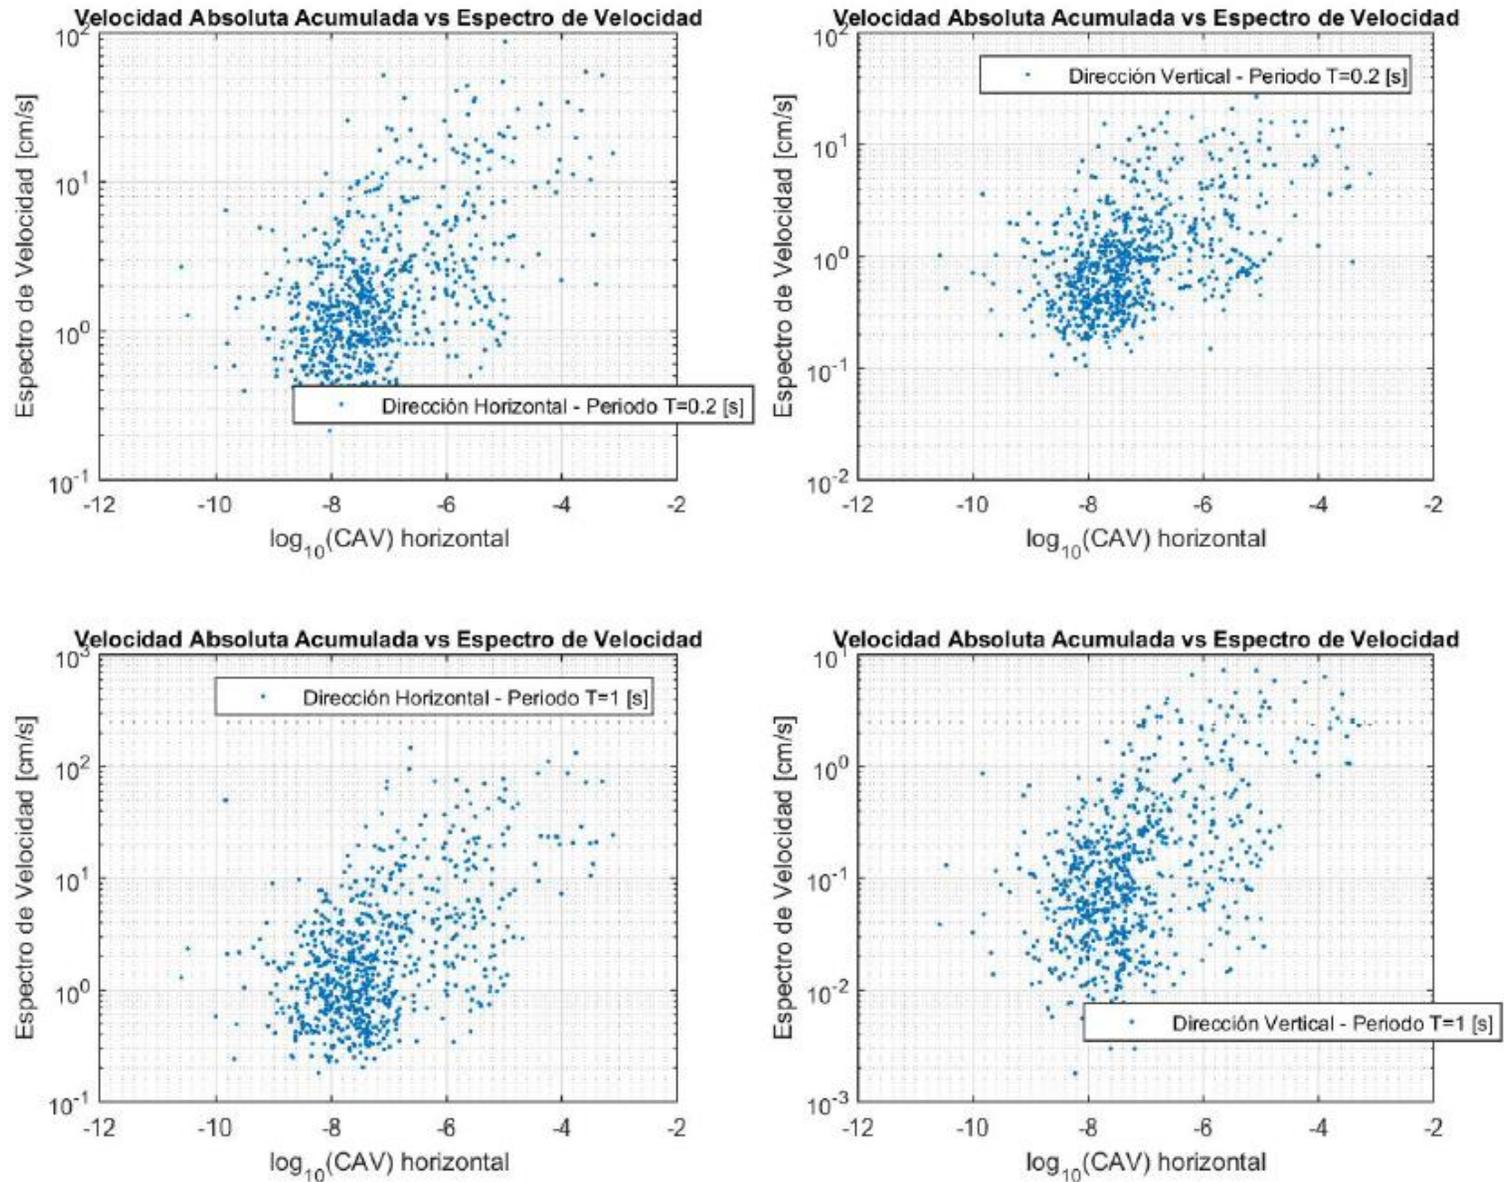


Figura C. 62: Relación entre $\log(\text{CAV})$ Horizontal y (a) Espectro de Velocidad Horizontal T=0.2 [s], (b) Espectro de Velocidad Vertical T=0.2 [s], (c) Espectro de Velocidad Horizontal T=1 [s], (d) Espectro de Velocidad Vertical T=1 [s].

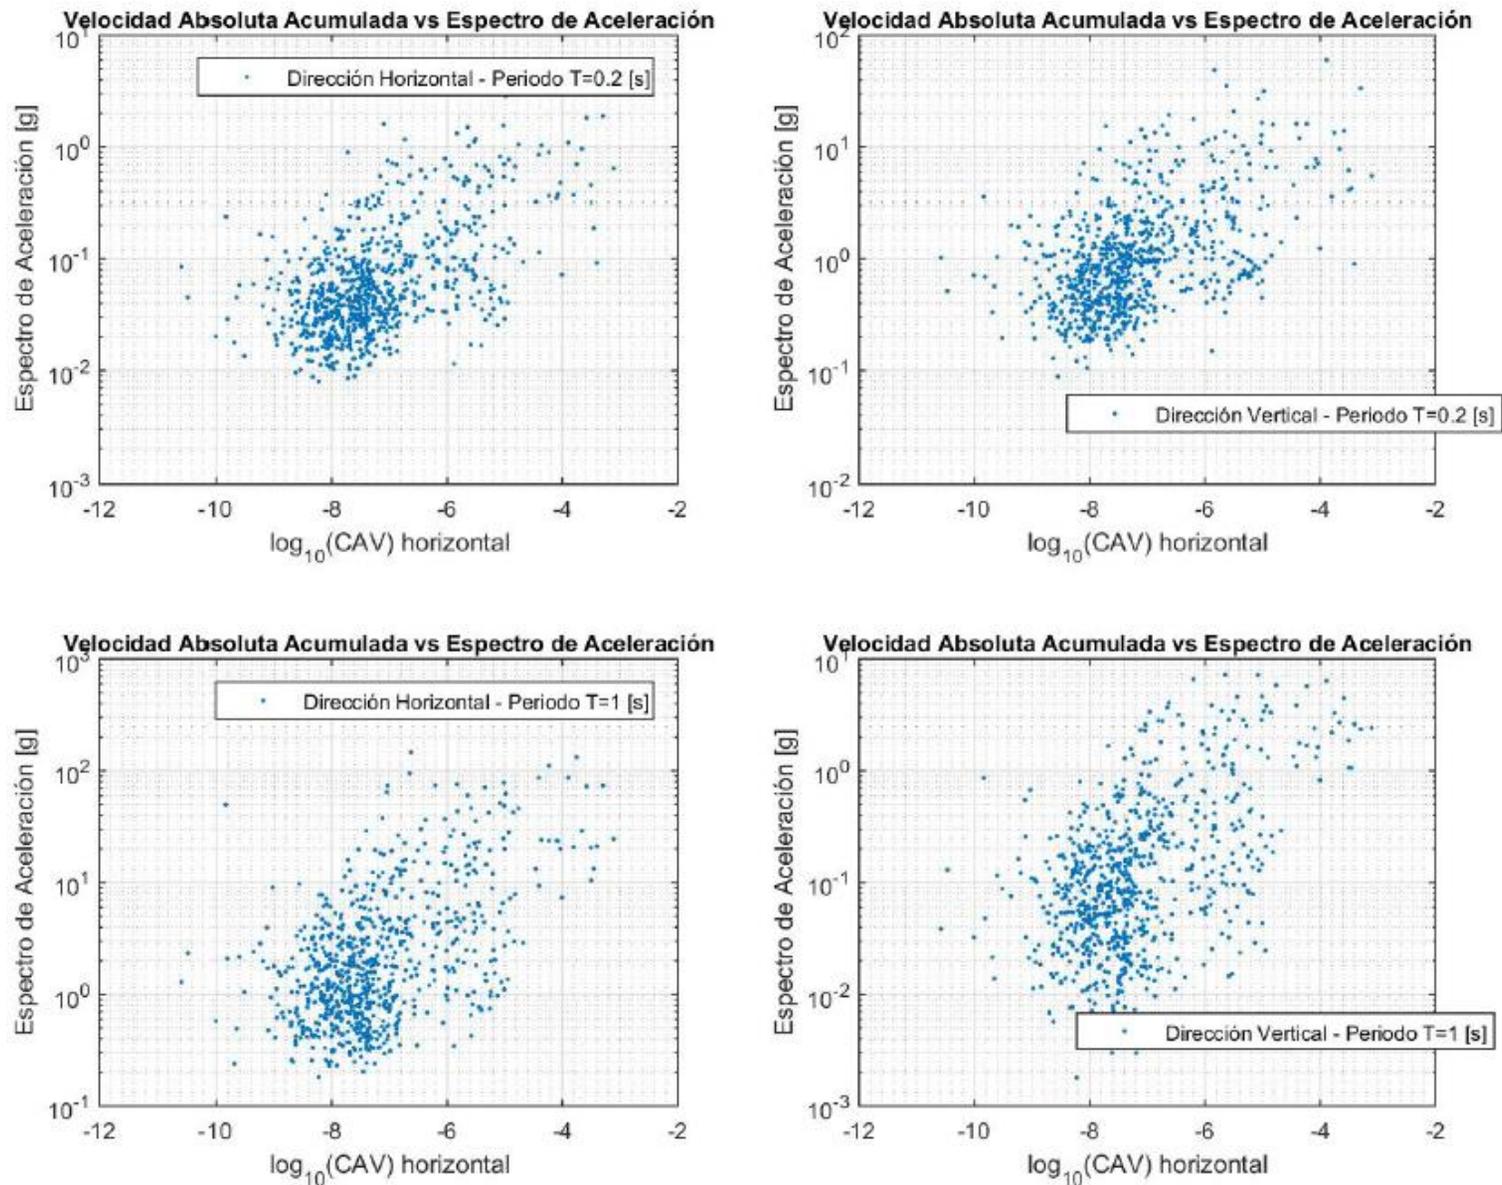


Figura C. 63: Relación entre $\log(\text{CAV})$ Horizontal y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].

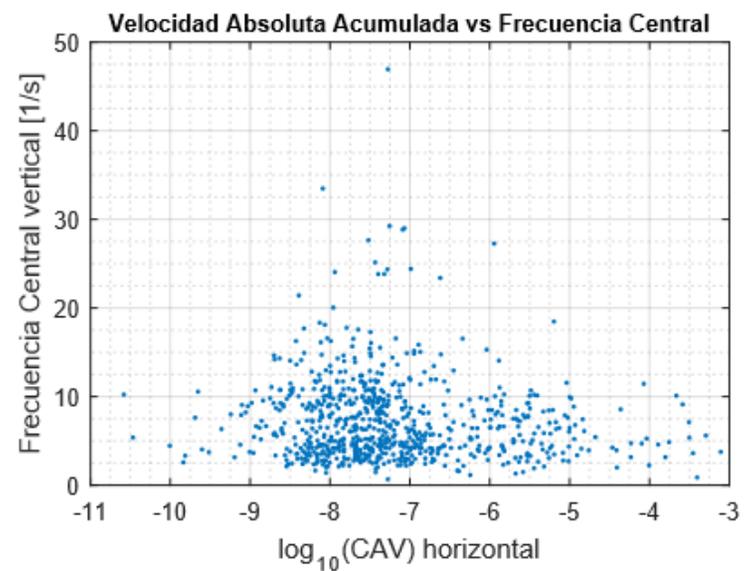
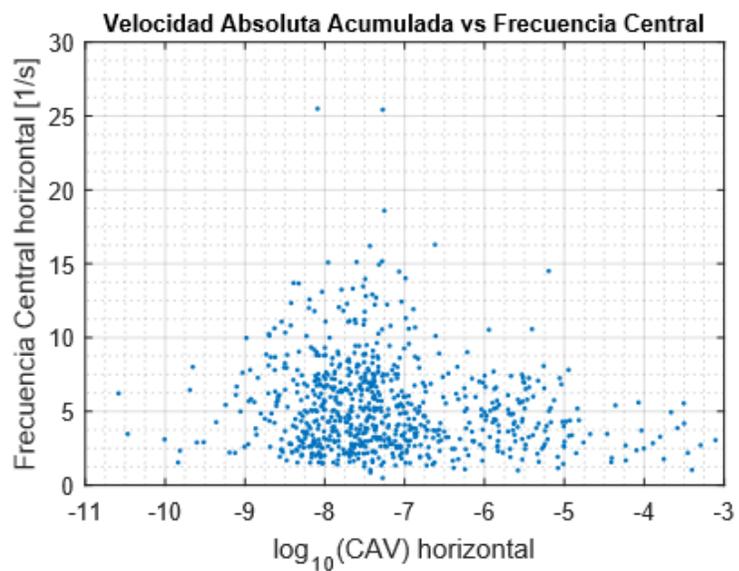
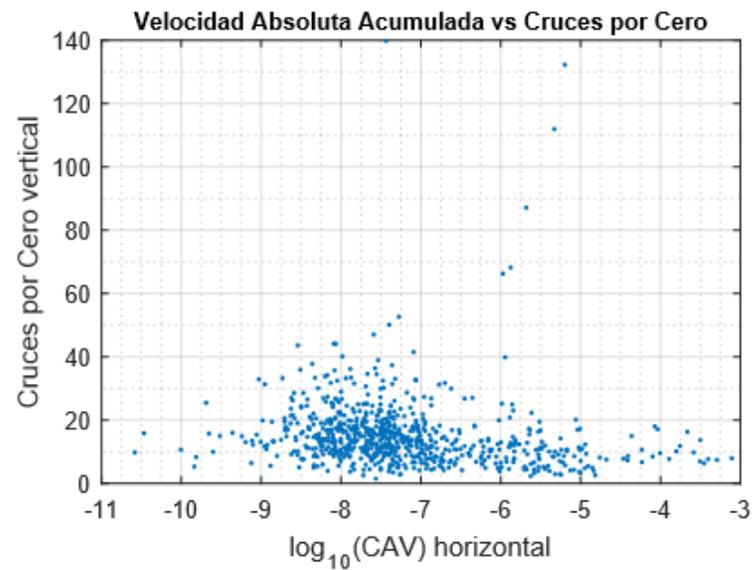
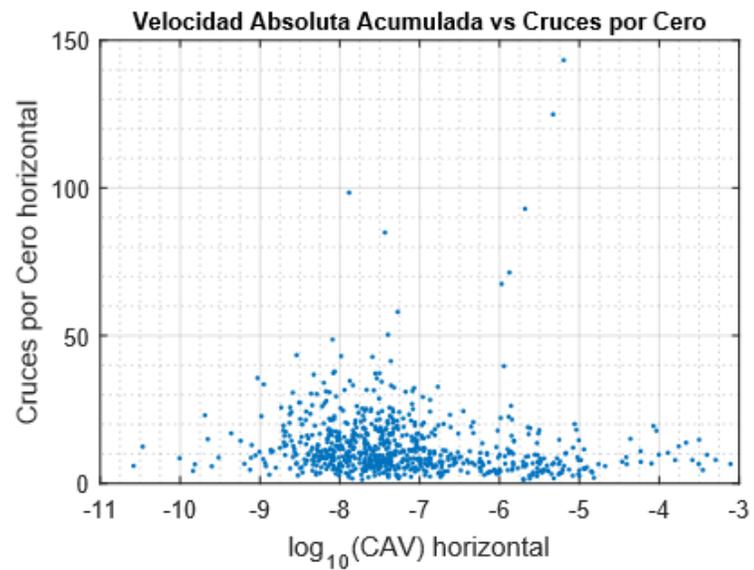
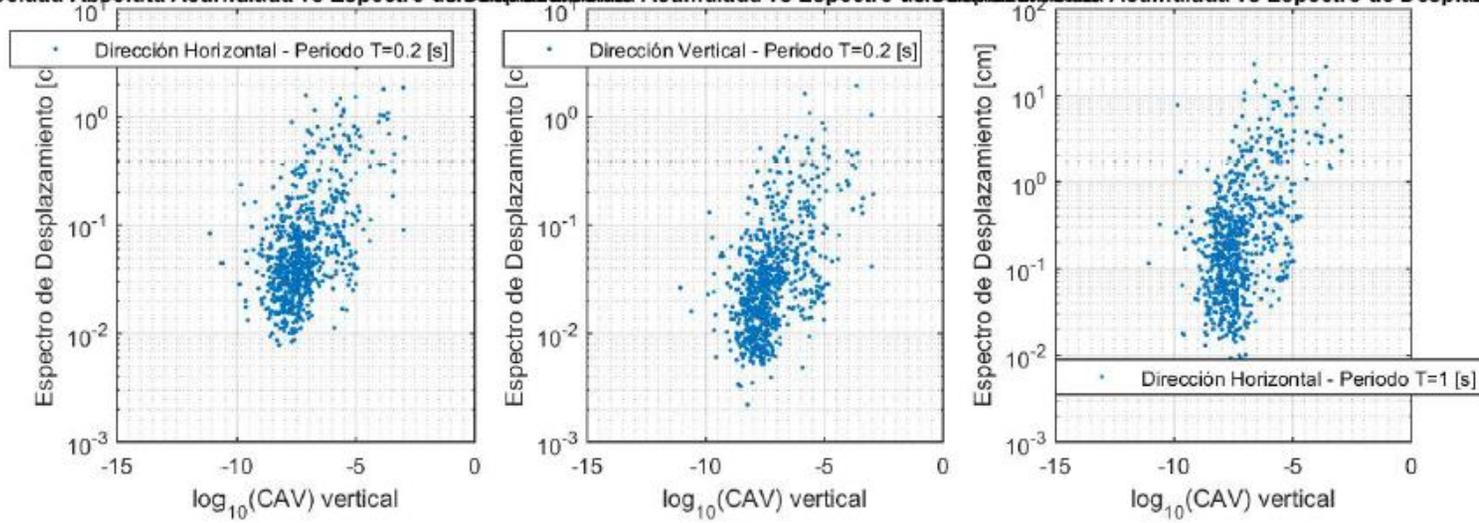


Figura C. 64: Relación entre $\log(\text{CAV})$ Horizontal y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

Velocidad Absoluta Acumulada vs Espectro de Desplazamiento Horizontal T=0.2 [s] Velocidad Absoluta Acumulada vs Espectro de Desplazamiento Vertical T=0.2 [s] Velocidad Absoluta Acumulada vs Espectro de Desplazamiento Horizontal T=1 [s]



Velocidad Absoluta Acumulada vs Espectro de Desplazamiento Horizontal T=0.2 [s] Velocidad Absoluta Acumulada vs Espectro de Desplazamiento Vertical T=1 [s] Velocidad Absoluta Acumulada vs Espectro de Velocidad Horizontal T=0.2 [s]

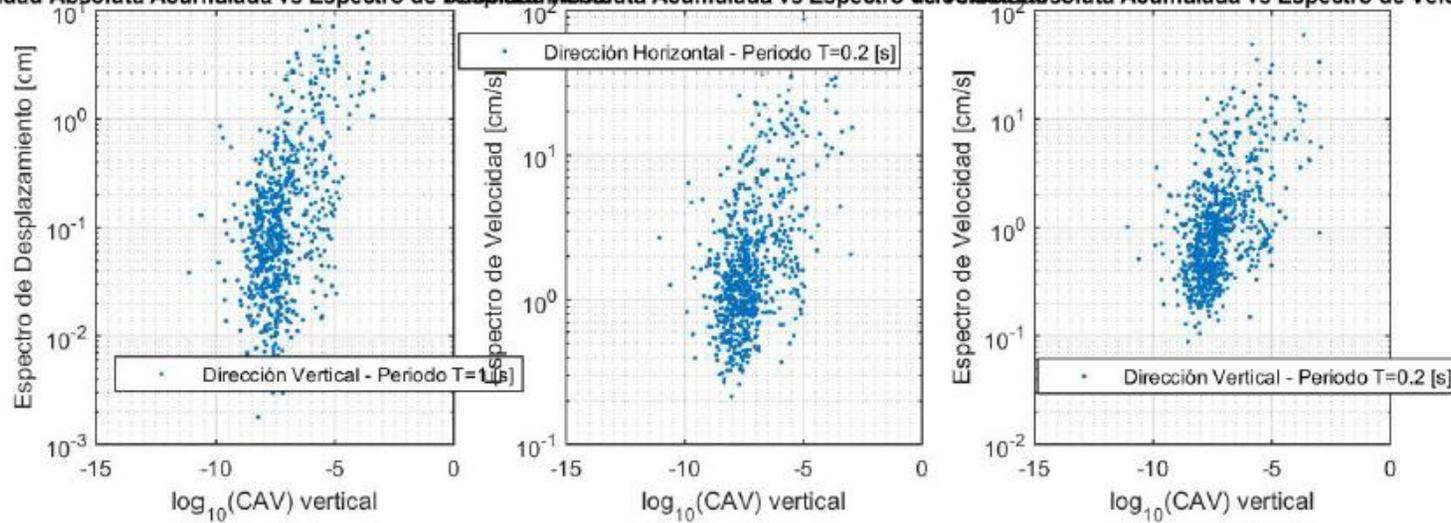
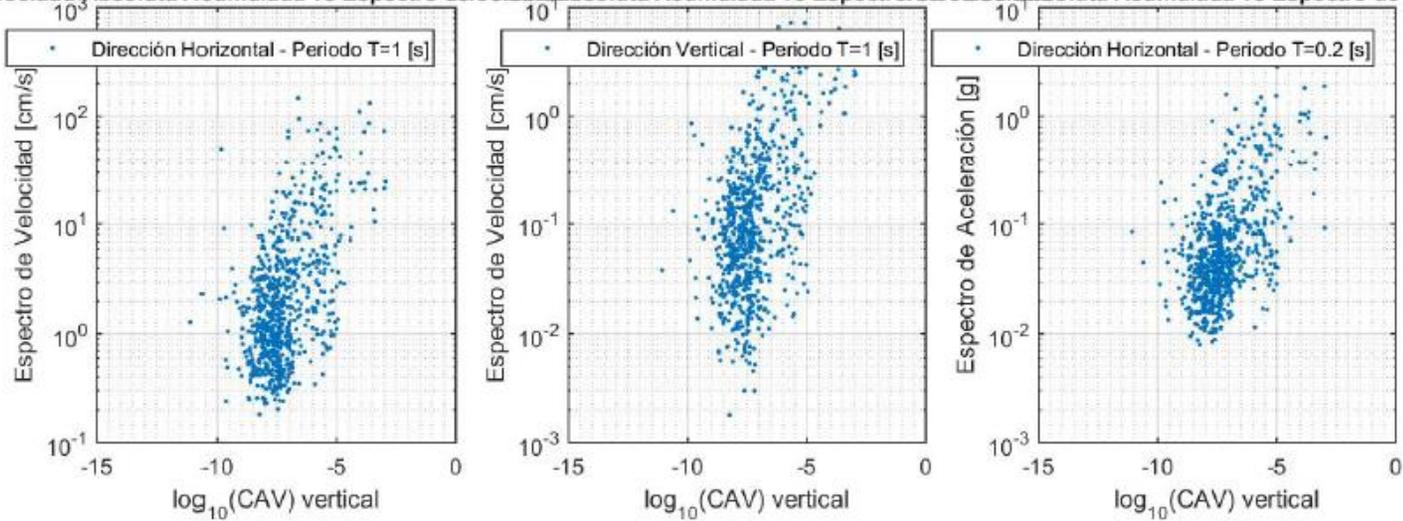


Figura C. 65: Relación entre $\log(\text{CAV})$ Vertical y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s], (e) Espectro de Velocidad Horizontal T=0.2 [s], (f) Espectro de Velocidad Vertical T=0.2 [s]

Velocidad Absoluta Acumulada vs Espectro de Velocidad Horizontal - Periodo T=1 [s] Velocidad Absoluta Acumulada vs Espectro de Velocidad Vertical - Periodo T=1 [s] Velocidad Absoluta Acumulada vs Espectro de Aceleración Horizontal - Periodo T=0.2 [s]



Velocidad Absoluta Acumulada vs Espectro de Aceleración Vertical - Periodo T=0.2 [s] Velocidad Absoluta Acumulada vs Espectro de Aceleración Horizontal - Periodo T=1 [s] Velocidad Absoluta Acumulada vs Espectro de Aceleración Vertical - Periodo T=1 [s]

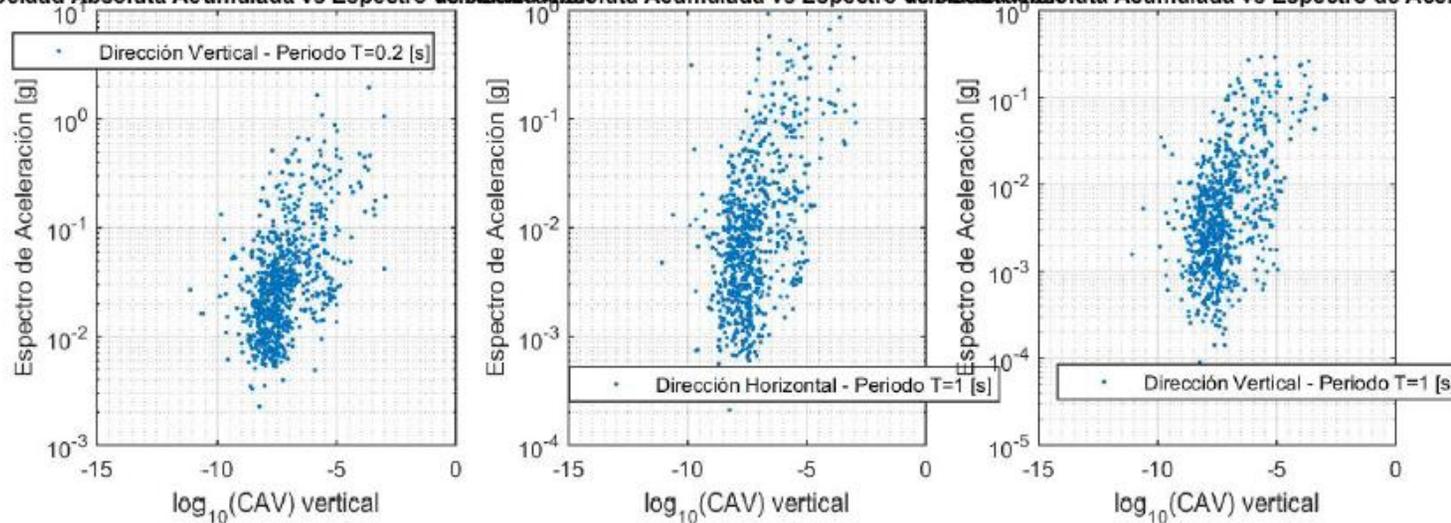


Figura C. 66: Relación entre $\log(\text{CAV})$ Vertical y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

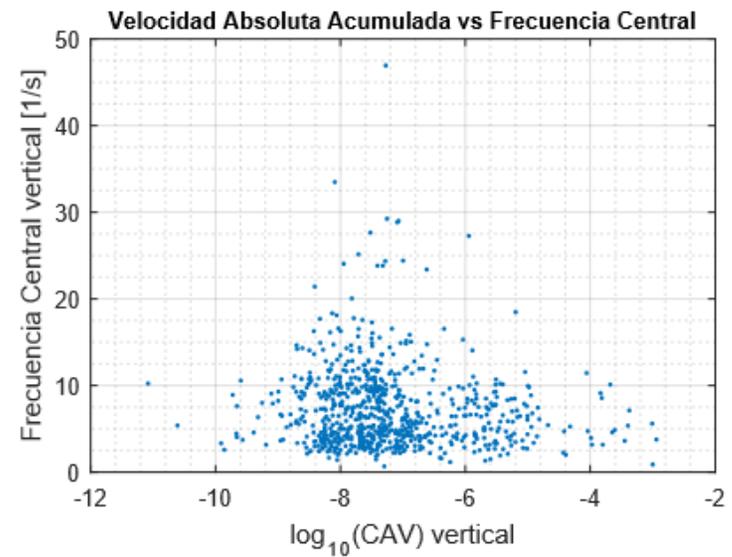
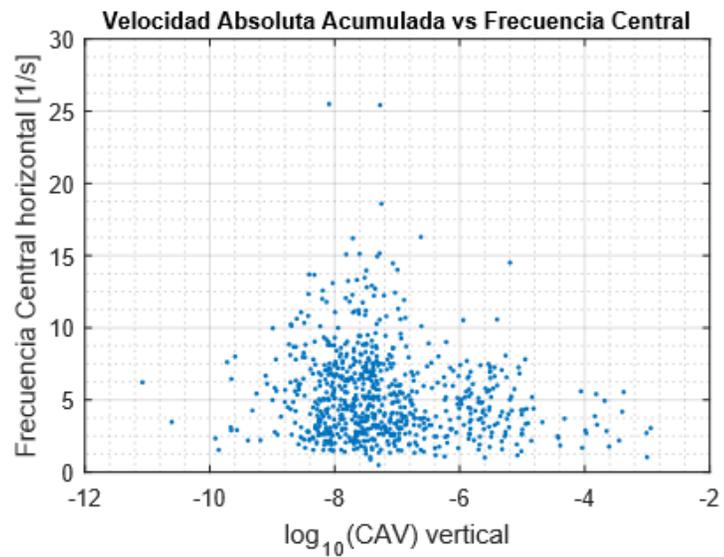
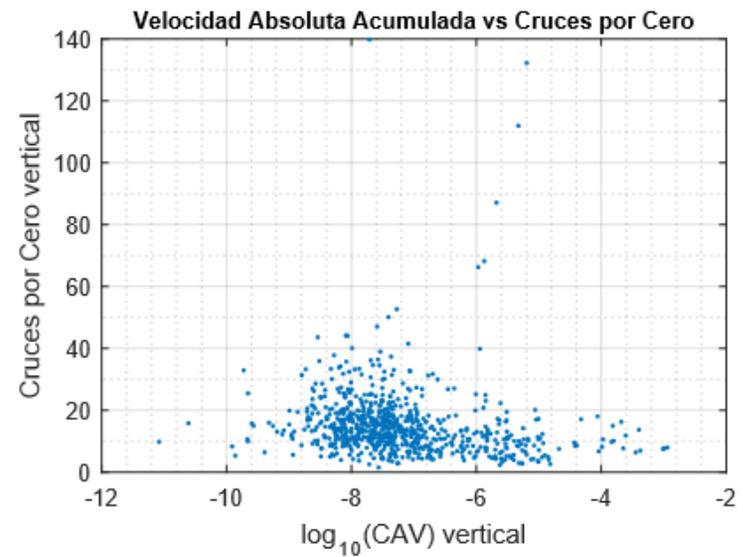
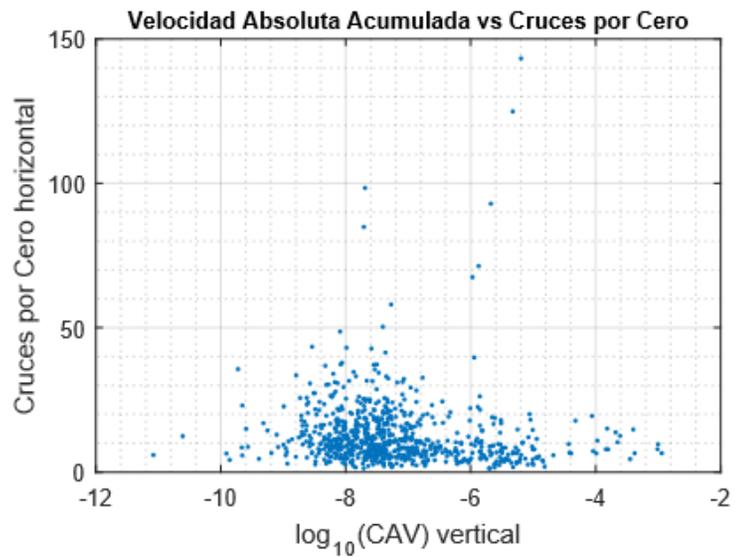


Figura C. 67: Relación entre $\log(\text{CAV})$ Vertical y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

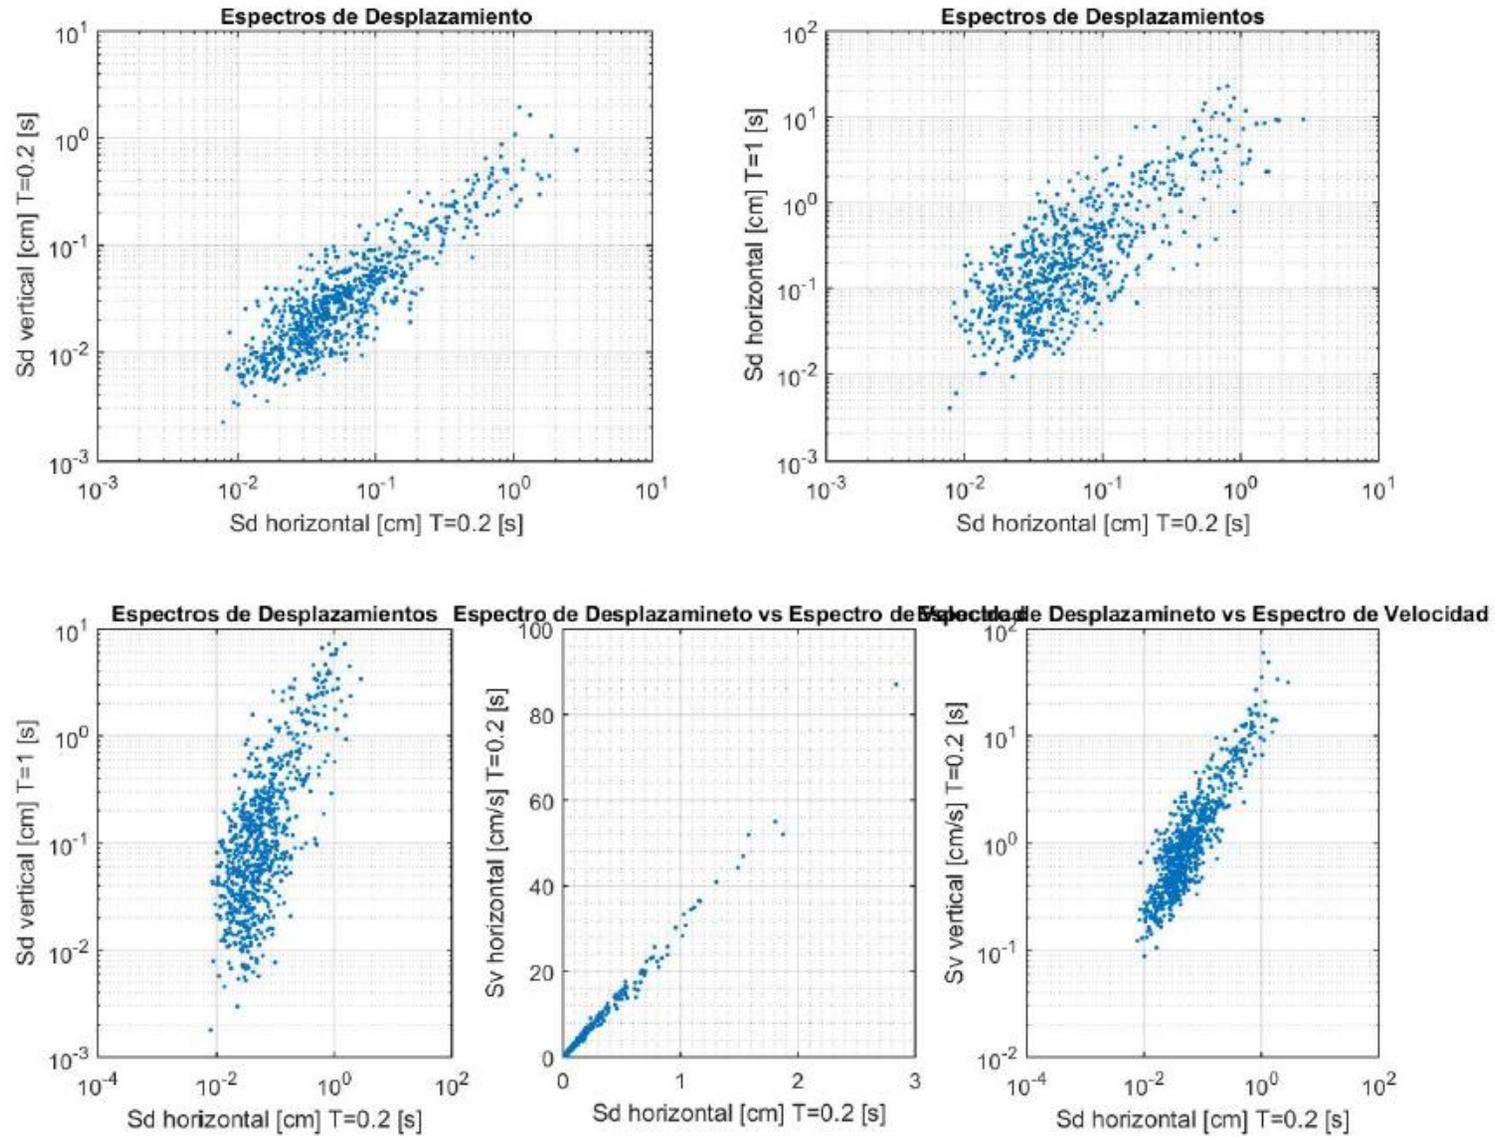
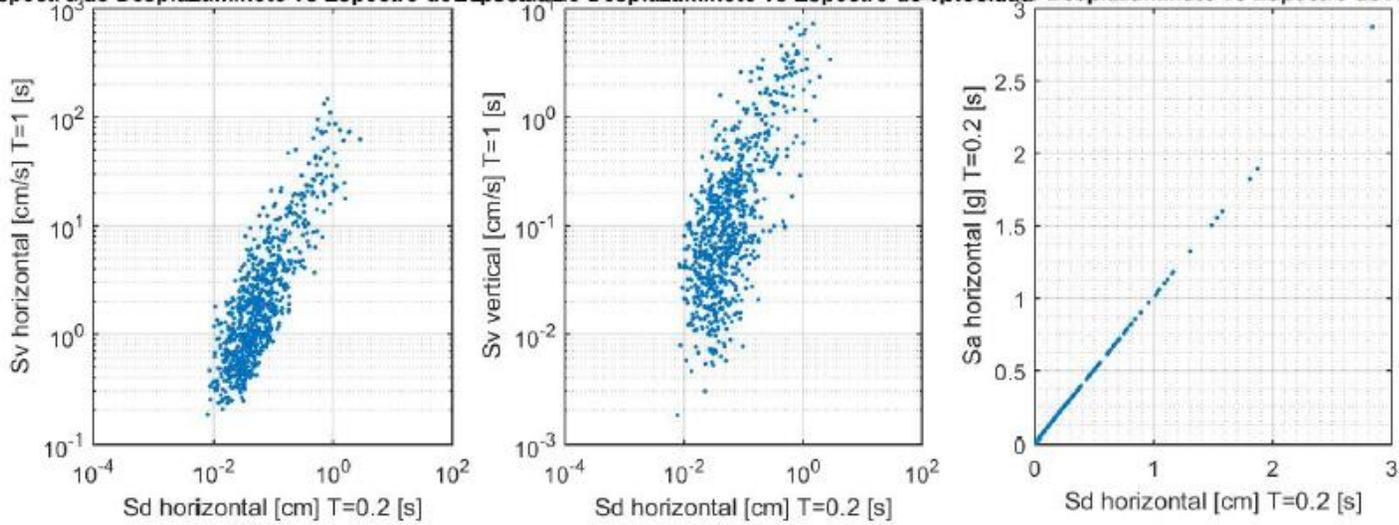


Figura C. 68: Relación entre Espectro de Desplazamiento Horizontal T=0.2 [s] y (a) Espectro de Desplazamiento Vertical T=0.2 [s], (b) Espectro de Desplazamiento Horizontal T=1 [s], (c) Espectro de Desplazamiento Vertical T=1 [s], (d) Espectro de Velocidad Horizontal T=0.2 [s], (e) Espectro de Velocidad Vertical T=0.2 [s].

Espectro de Desplazamiento vs Espectro de Velocidad Horizontal T=1 [s] **Espectro de Desplazamiento vs Espectro de Velocidad Vertical T=1 [s]** **Espectro de Desplazamiento vs Espectro de Aceleración Horizontal T=0.2 [s]**



Espectro de Desplazamiento vs Espectro de Aceleración Vertical T=0.2 [s] **Espectro de Desplazamiento vs Espectro de Aceleración Horizontal T=1 [s]** **Espectro de Desplazamiento vs Espectro de Aceleración Vertical T=1 [s]**

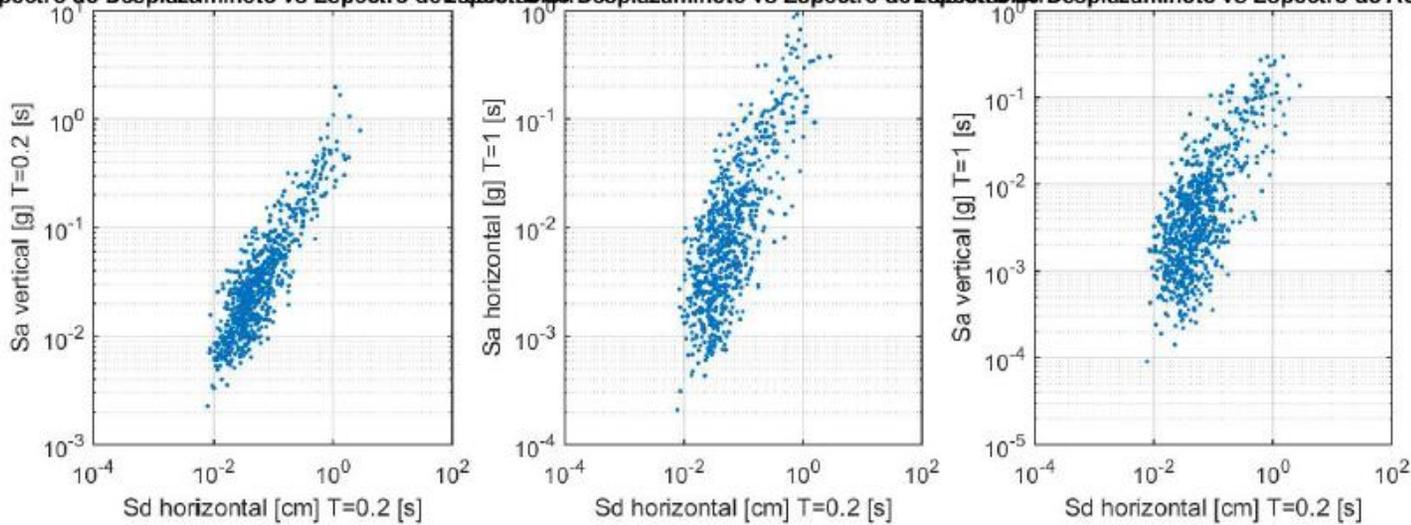


Figura C. 69: Relación entre Espectro de Desplazamiento Horizontal T=0.2 [s] y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s], (e) Espectro de Aceleración Horizontal T=1 [s], (f) Espectro de Aceleración Vertical T=1 [s].

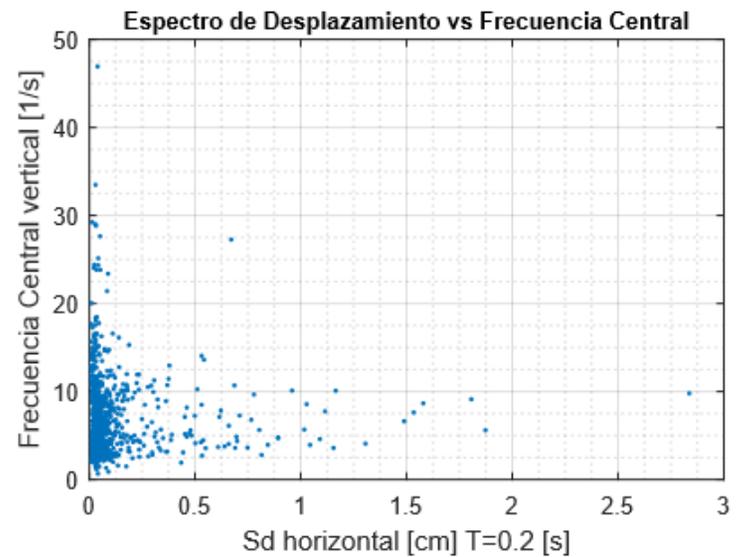
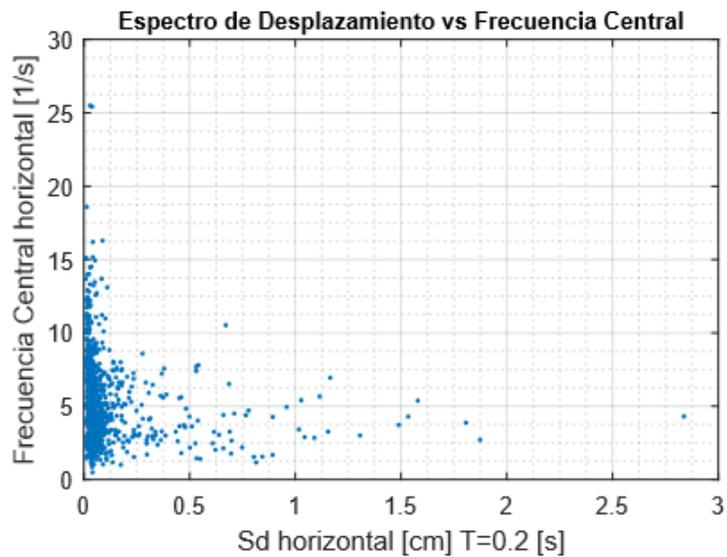
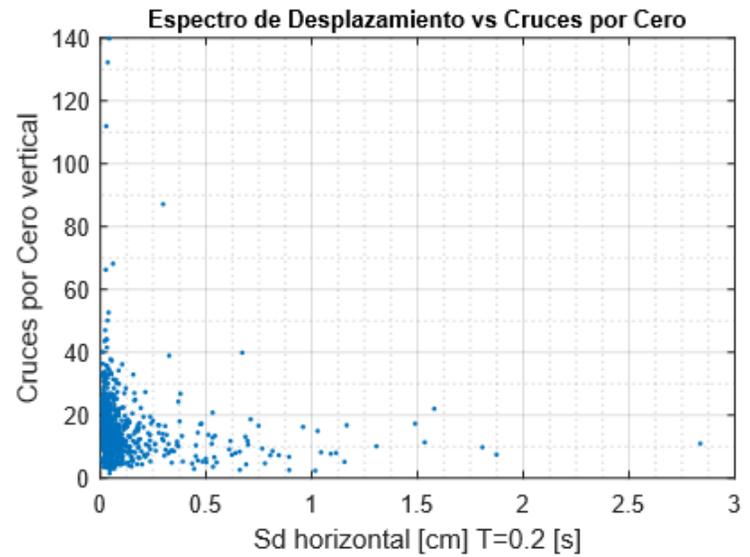
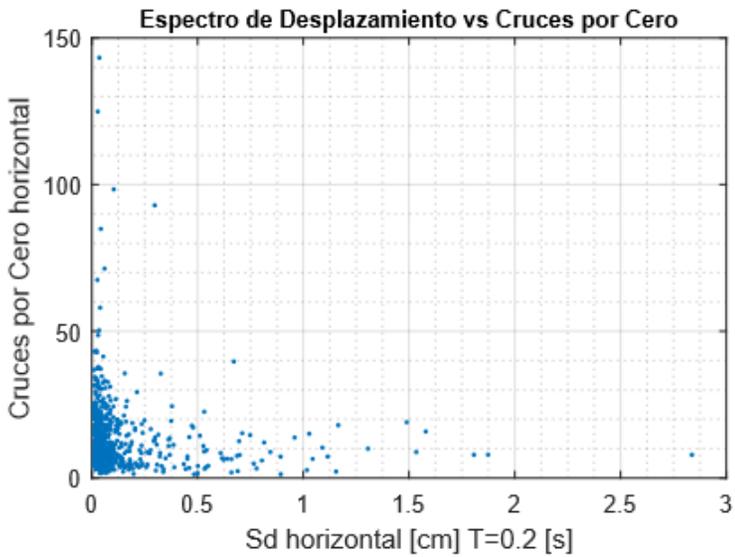


Figura C. 70: Relación entre Espectro de Desplazamiento Horizontal $T=0.2$ [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

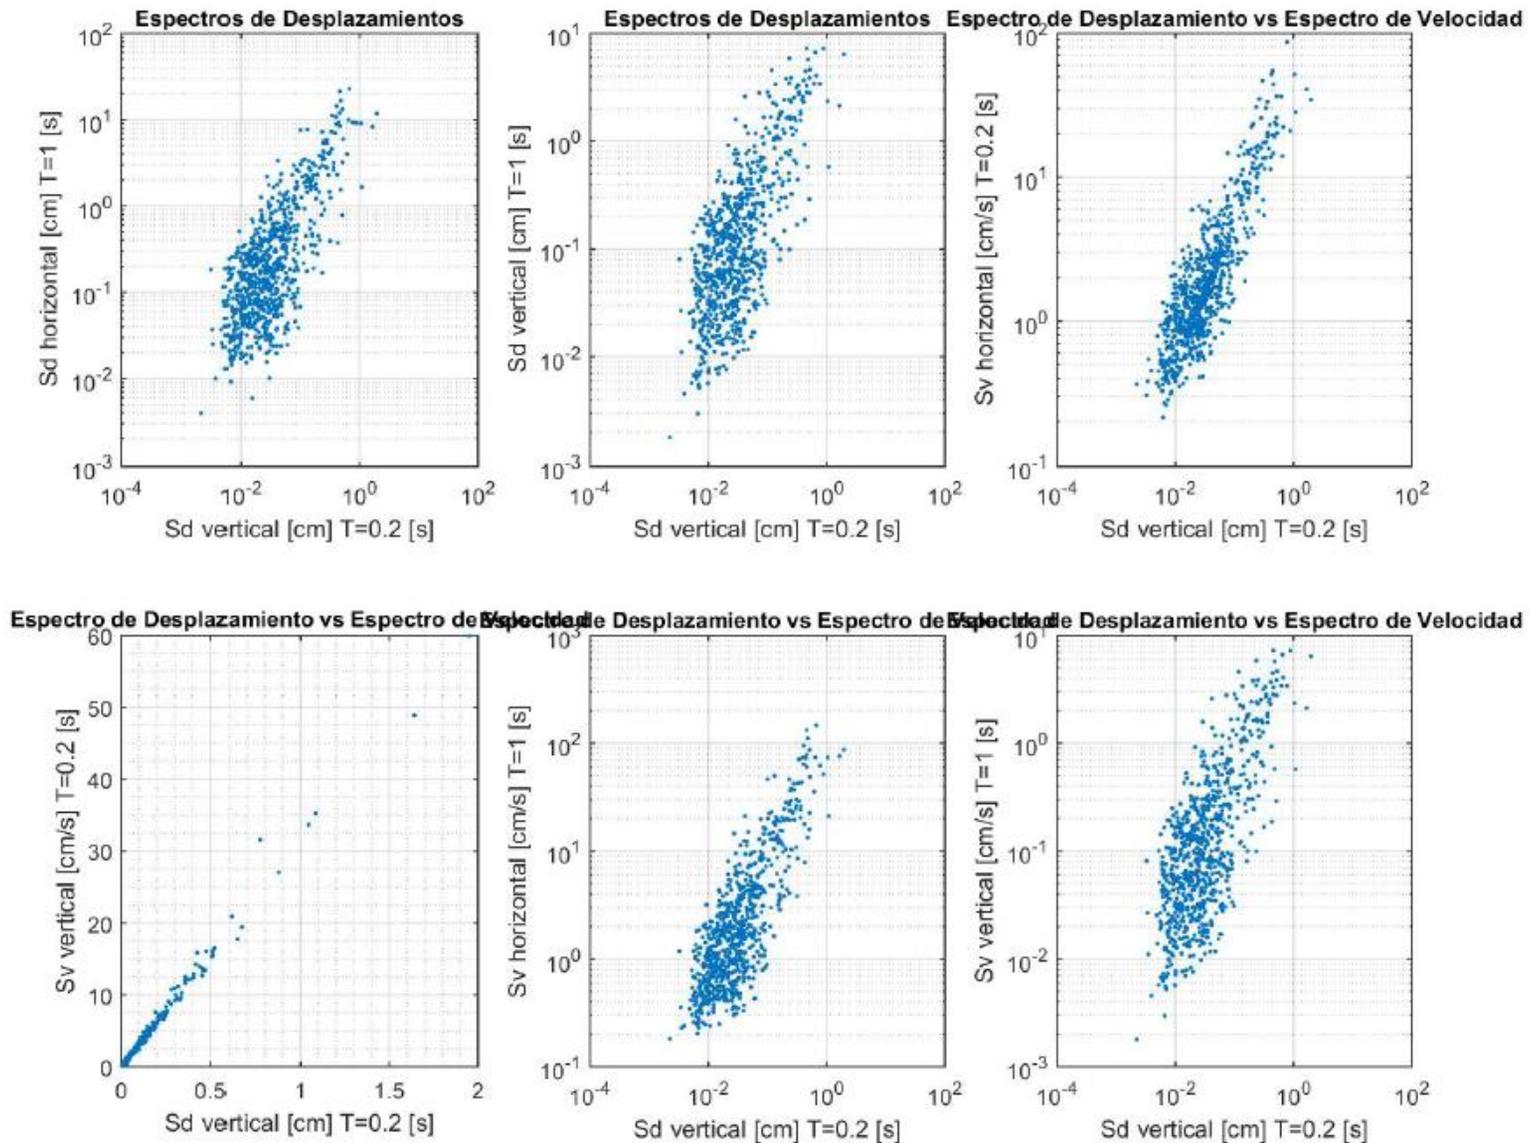


Figura C. 71: Relación entre Espectro de Desplazamiento Vertical $T=0.2$ [s] y (a) Espectro de Desplazamiento Horizontal $T=1$ [s], (b) Espectro de Desplazamiento Vertical $T=1$ [s], (c) Espectro de Velocidad Horizontal $T=0.2$ [s], (d) Espectro de Velocidad Vertical $T=0.2$ [s], (e) Espectro de Velocidad Horizontal $T=1$ [s], (f) Espectro de Velocidad Vertical $T=1$ [s].

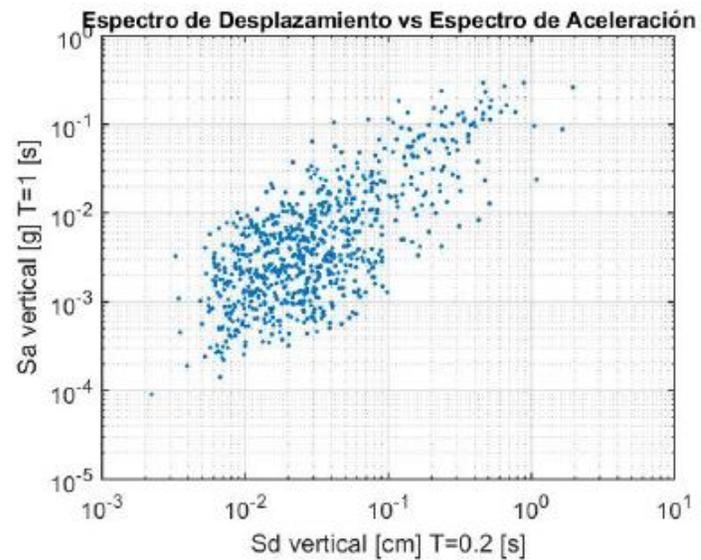
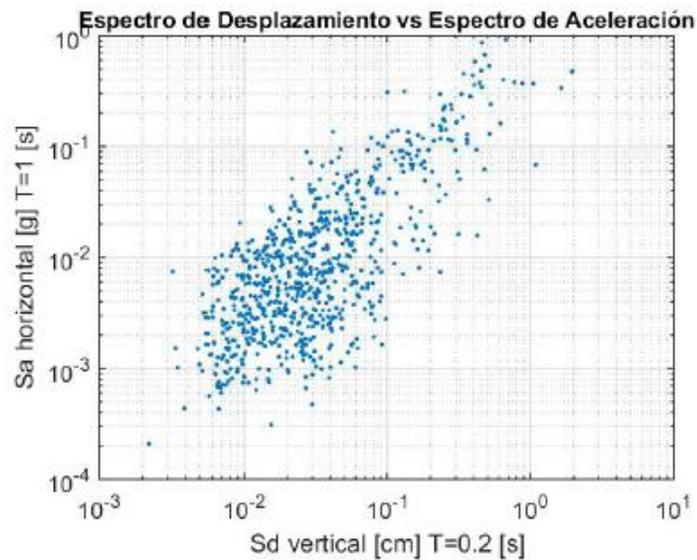
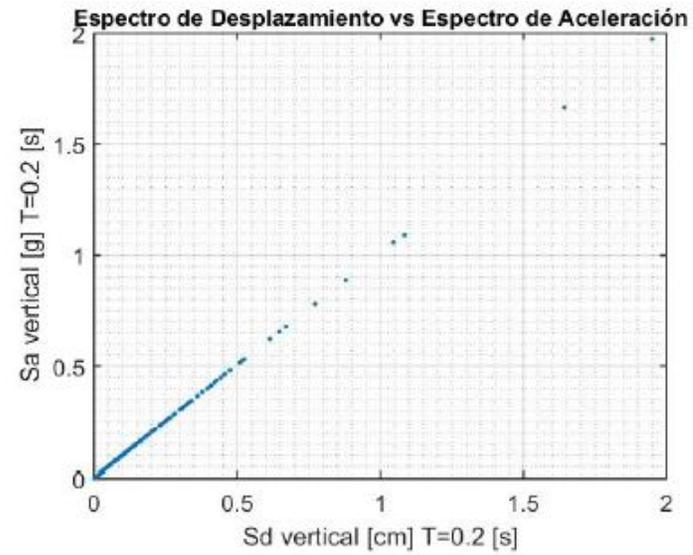
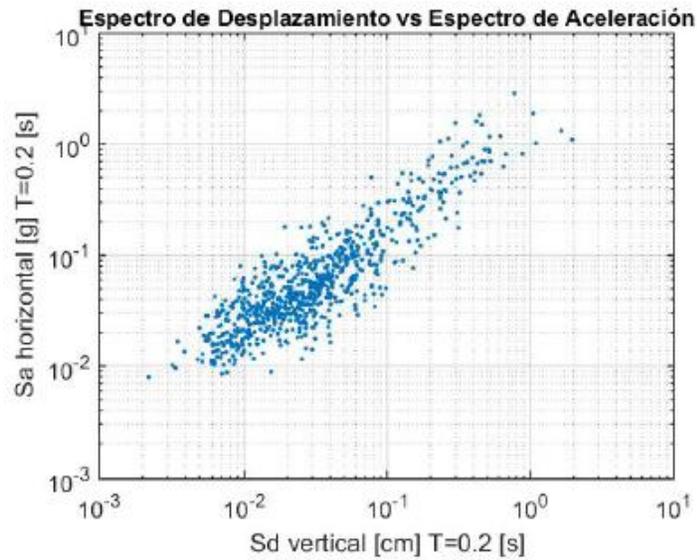


Figura C. 72: Relación entre Espectro de Desplazamiento Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].

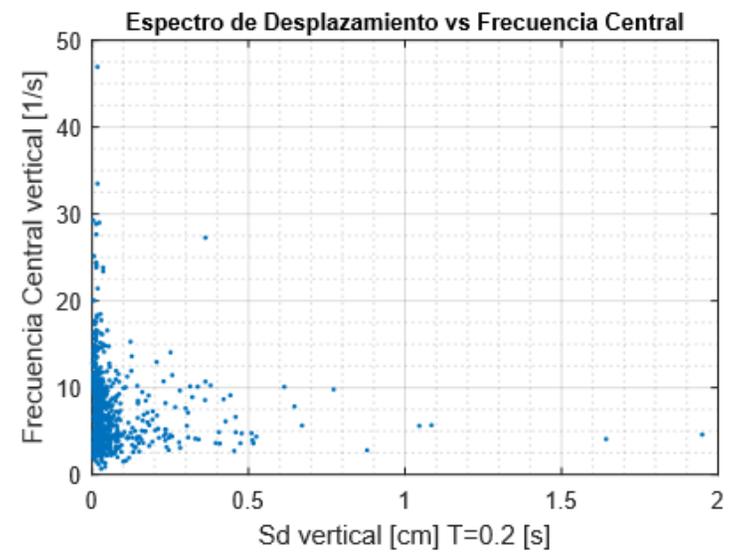
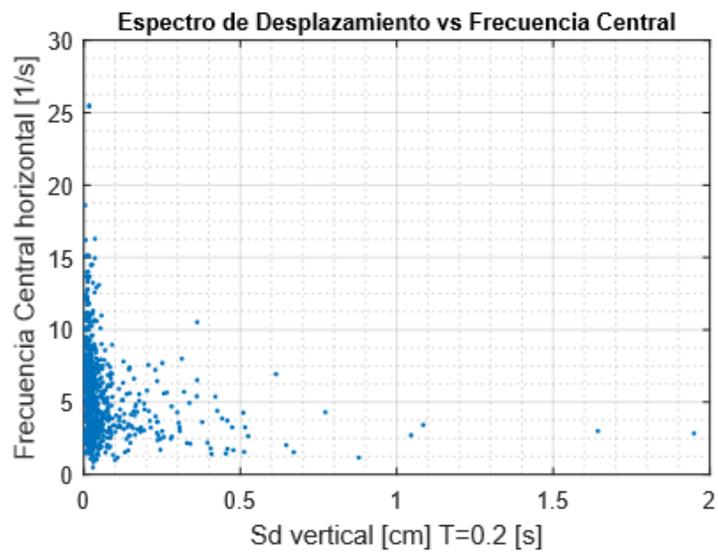
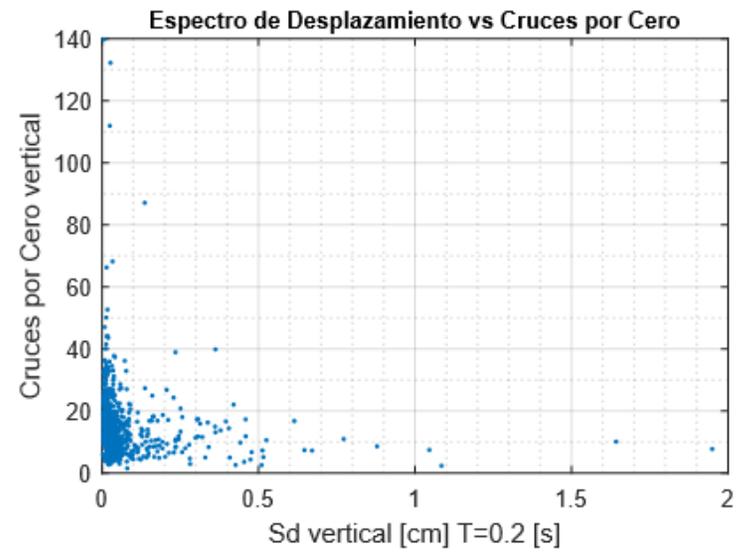
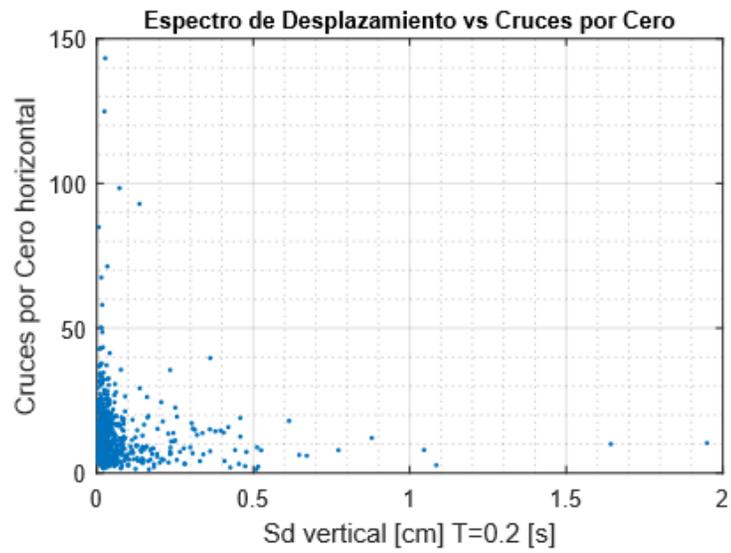


Figura C. 73: Relación entre Espectro de Desplazamiento Vertical T=0.2 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

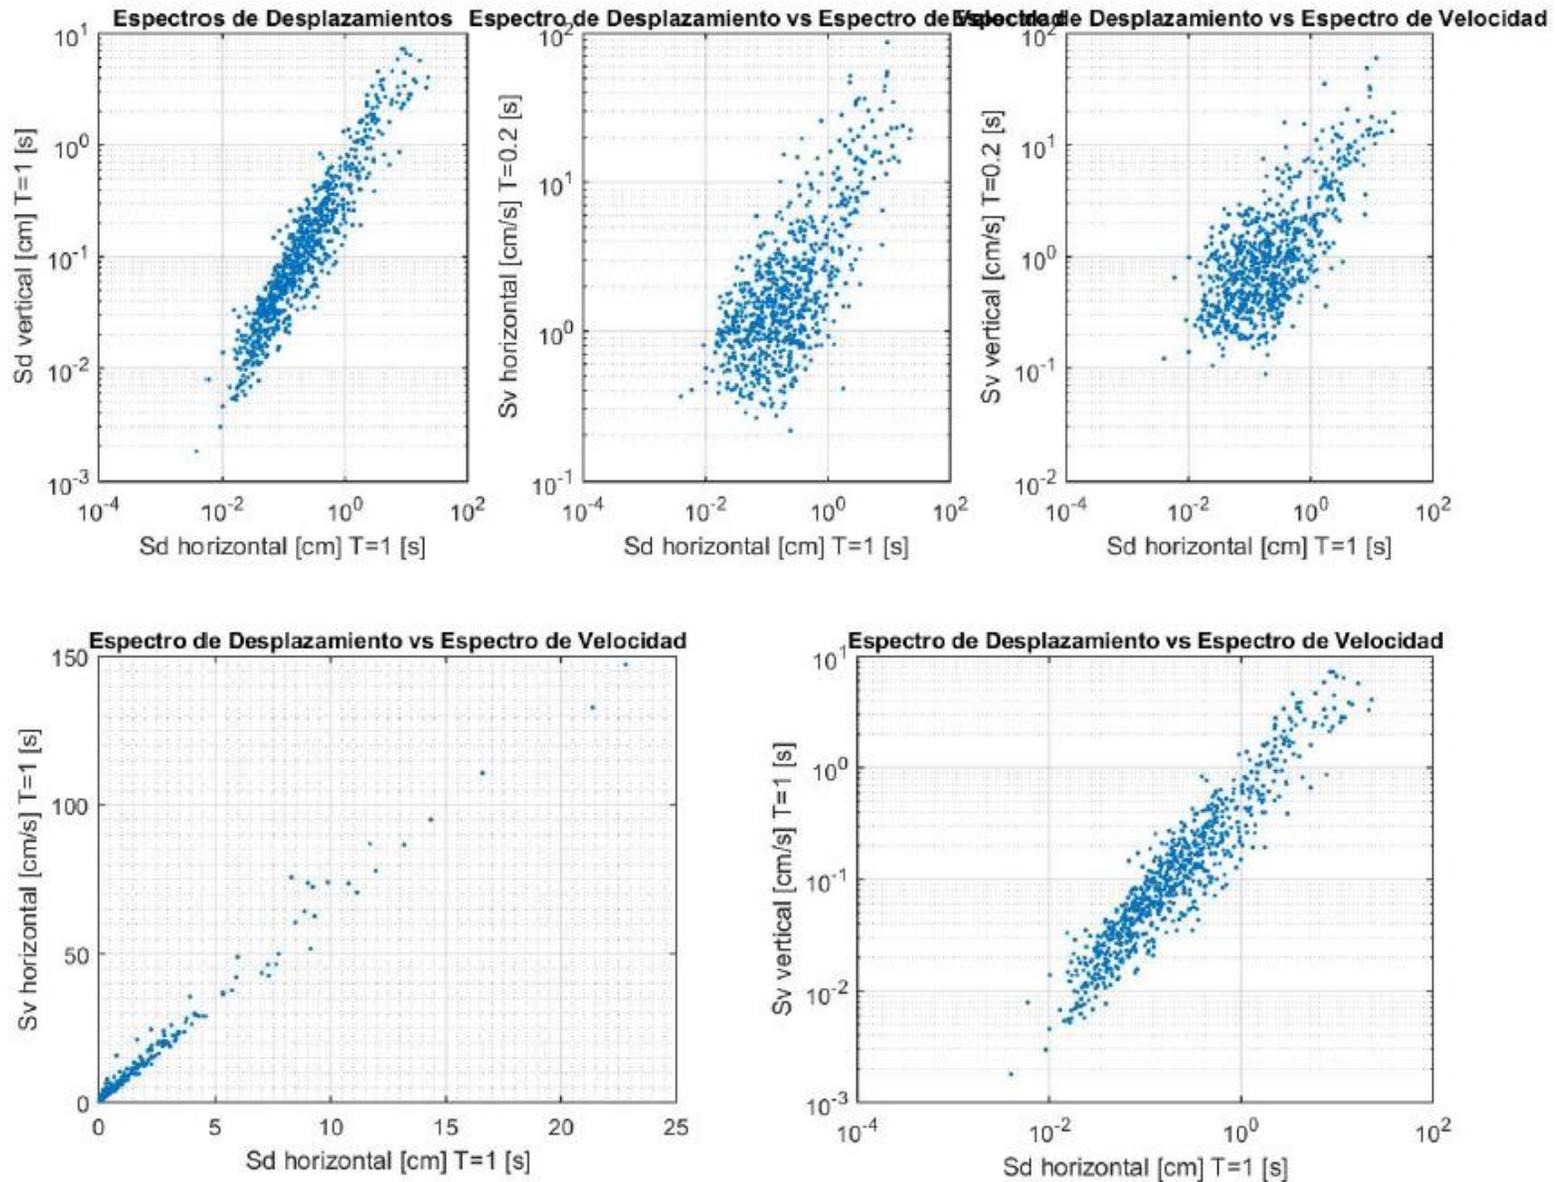


Figura C. 74: Relación entre Espectro de Desplazamiento Horizontal T=1 [s] y (a) Espectro de Desplazamiento Vertical T= [s], (b) Espectro de Velocidad Horizontal T=0.2 [s], (c) Espectro de Velocidad Vertical T=0.2 [s], (d) Espectro de Velocidad Horizontal T=1 [s], (e) Espectro de Velocidad Vertical T=1 [s].

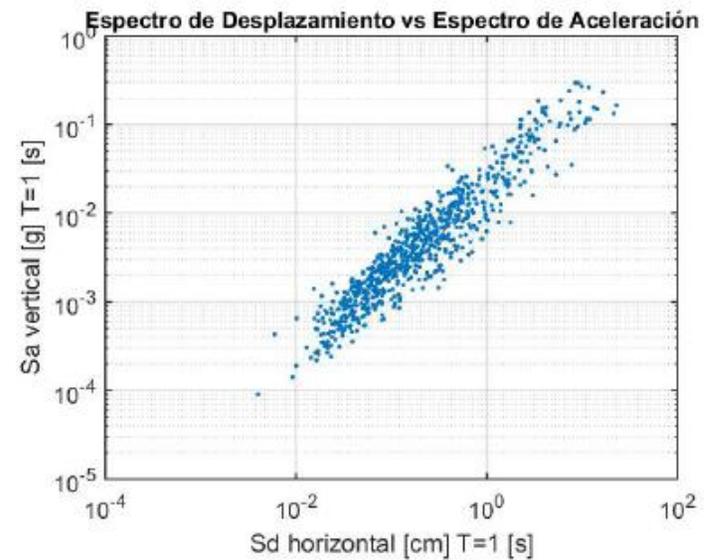
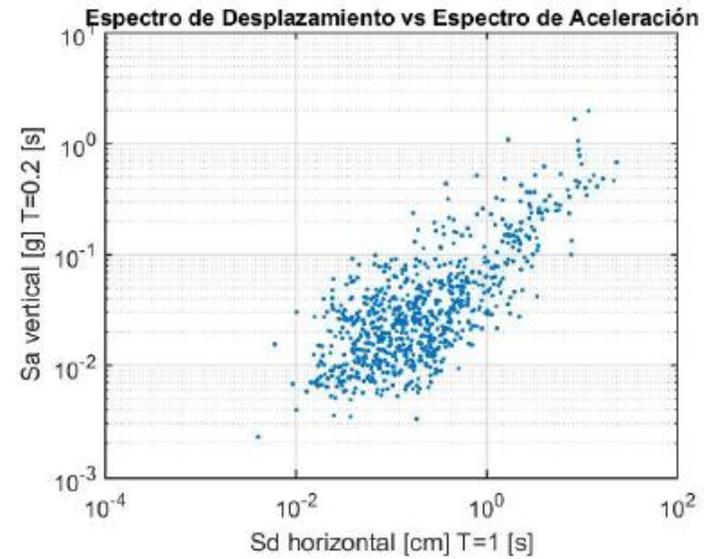
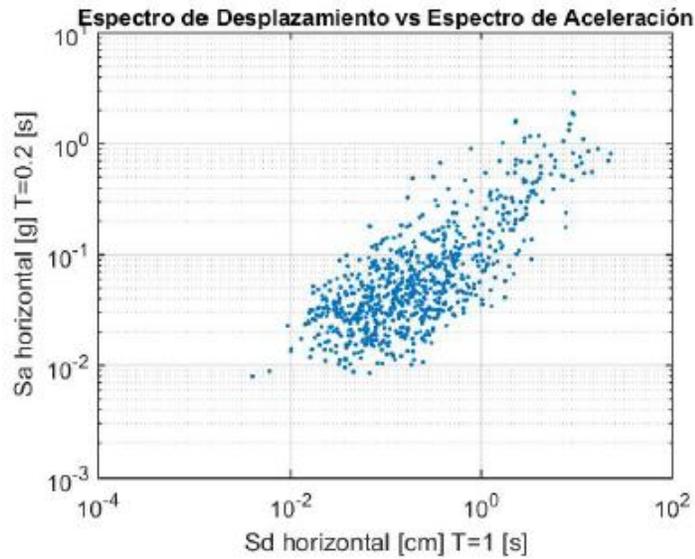


Figura C. 75: Relación entre Espectro de Desplazamiento Horizontal $T=$ [s] y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].

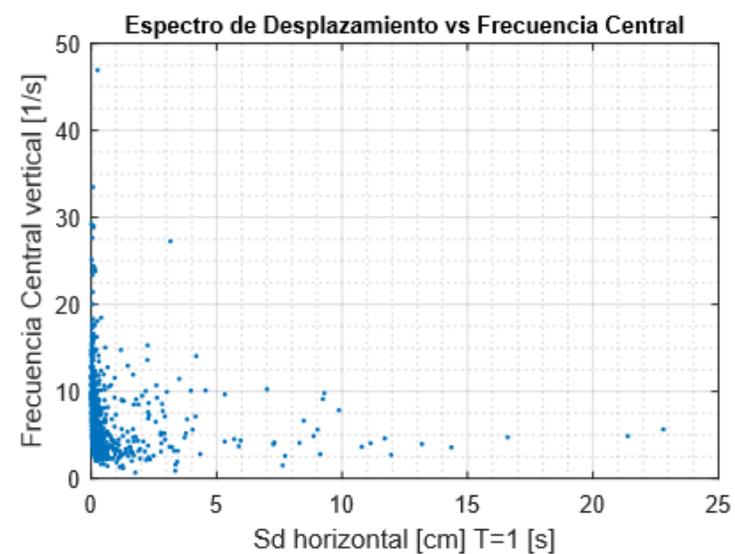
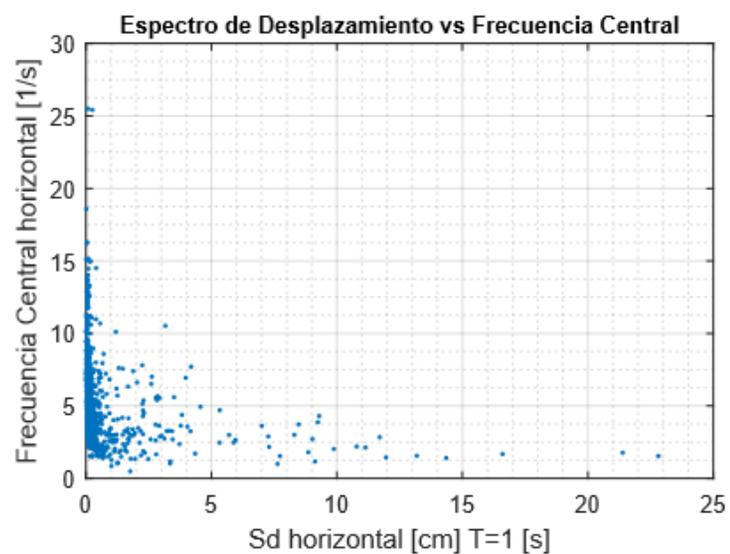
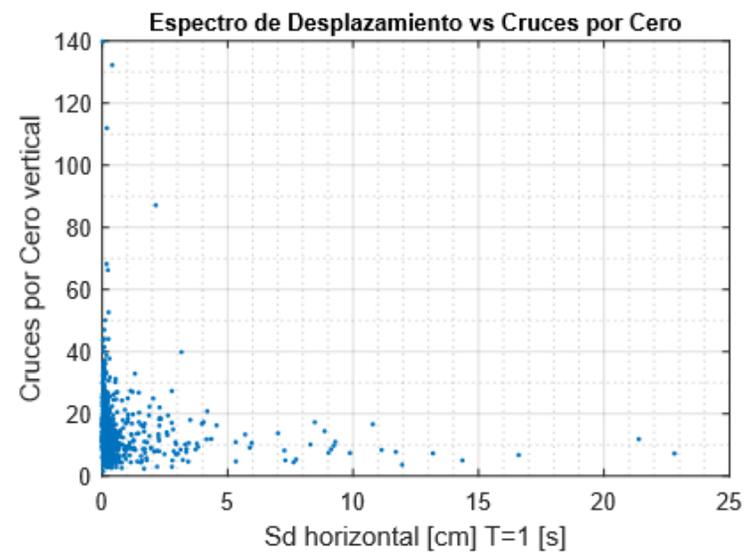
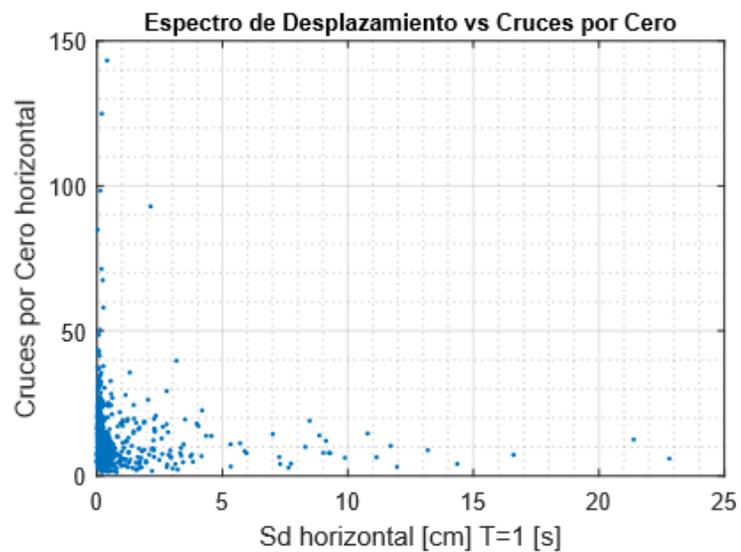
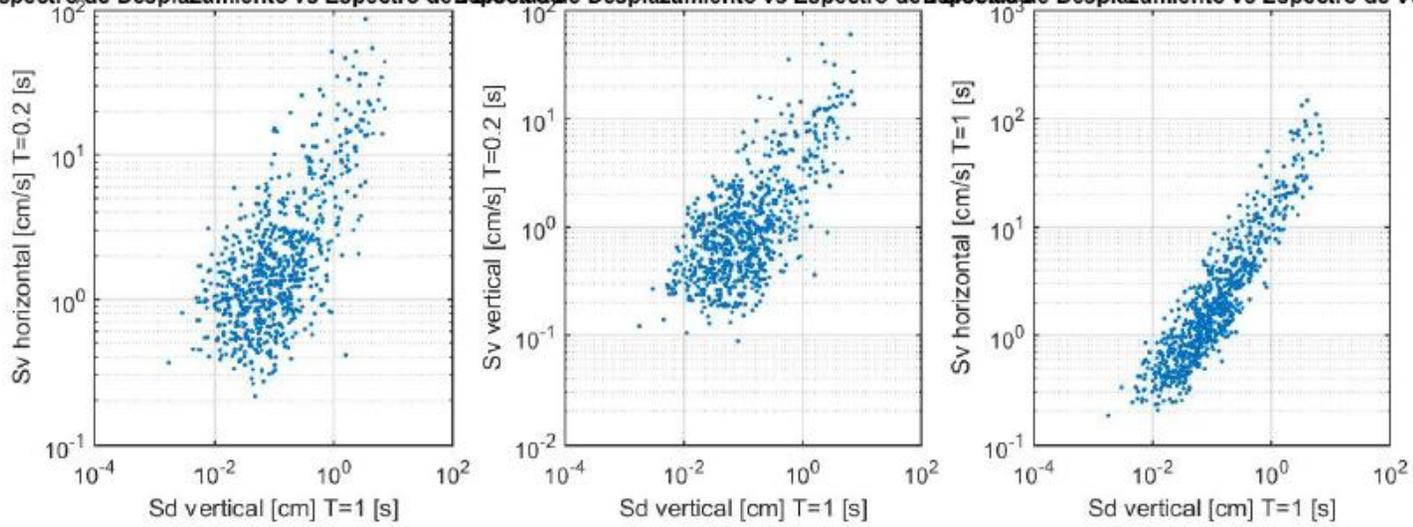


Figura C. 76: Relación entre Espectro de Desplazamiento Horizontal $T=1$ [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

Espectro de Desplazamiento vs Espectro de Velocidad Horizontal T=0.2 [s] **Espectro de Desplazamiento vs Espectro de Velocidad Vertical T=0.2 [s]** **Espectro de Desplazamiento vs Espectro de Velocidad Horizontal T=1 [s]**



Espectro de Desplazamiento vs Espectro de Velocidad Vertical T=1 [s] **Espectro de Desplazamiento vs Espectro de Aceleración Horizontal T=0.2 [s]** **Espectro de Desplazamiento vs Espectro de Aceleración Vertical T=0.2 [s]**

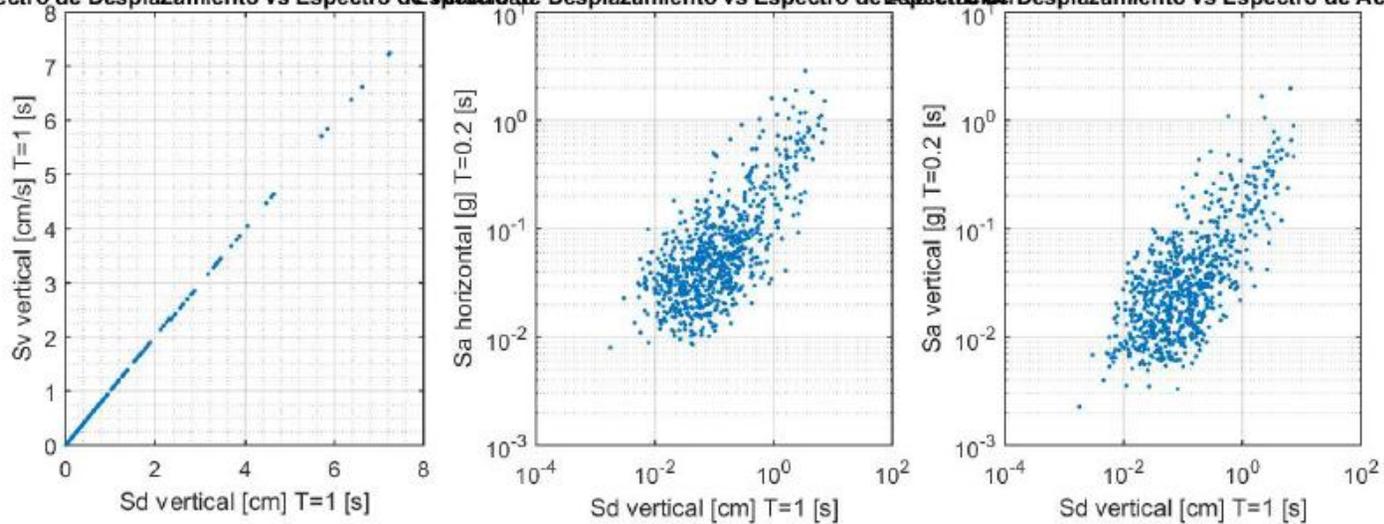


Figura C. 77: Relación entre Espectro de Desplazamiento Vertical T=1 [s] y (a) Espectro de Velocidad Horizontal T=0.2 [s], (b) Espectro de Velocidad Vertical T=0.2 [s], (c) Espectro de Velocidad Horizontal T=1 [s], (d) Espectro de Velocidad Vertical T=1 [s], (e) Espectro de Aceleración Horizontal T=0.2 [s], (f) Espectro de Aceleración Vertical T=0.2 [s].

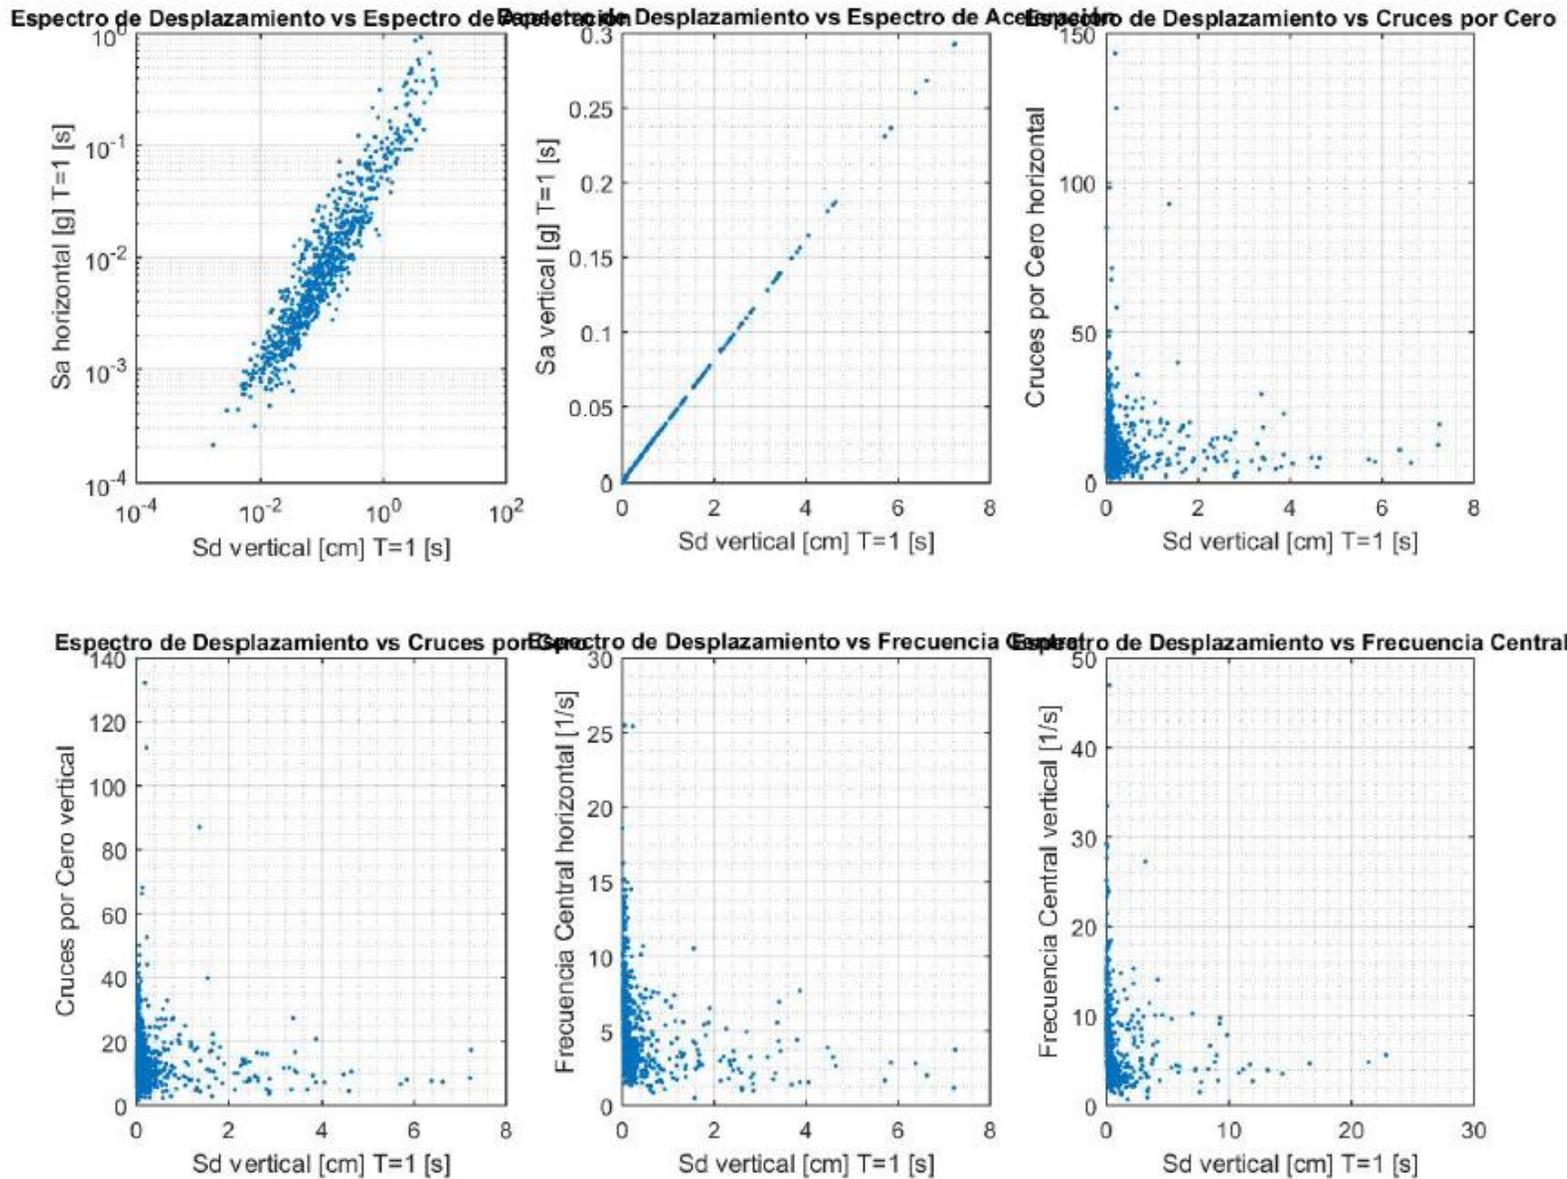


Figura C. 78: Relación entre Espectro de Desplazamiento Vertical T=1 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.

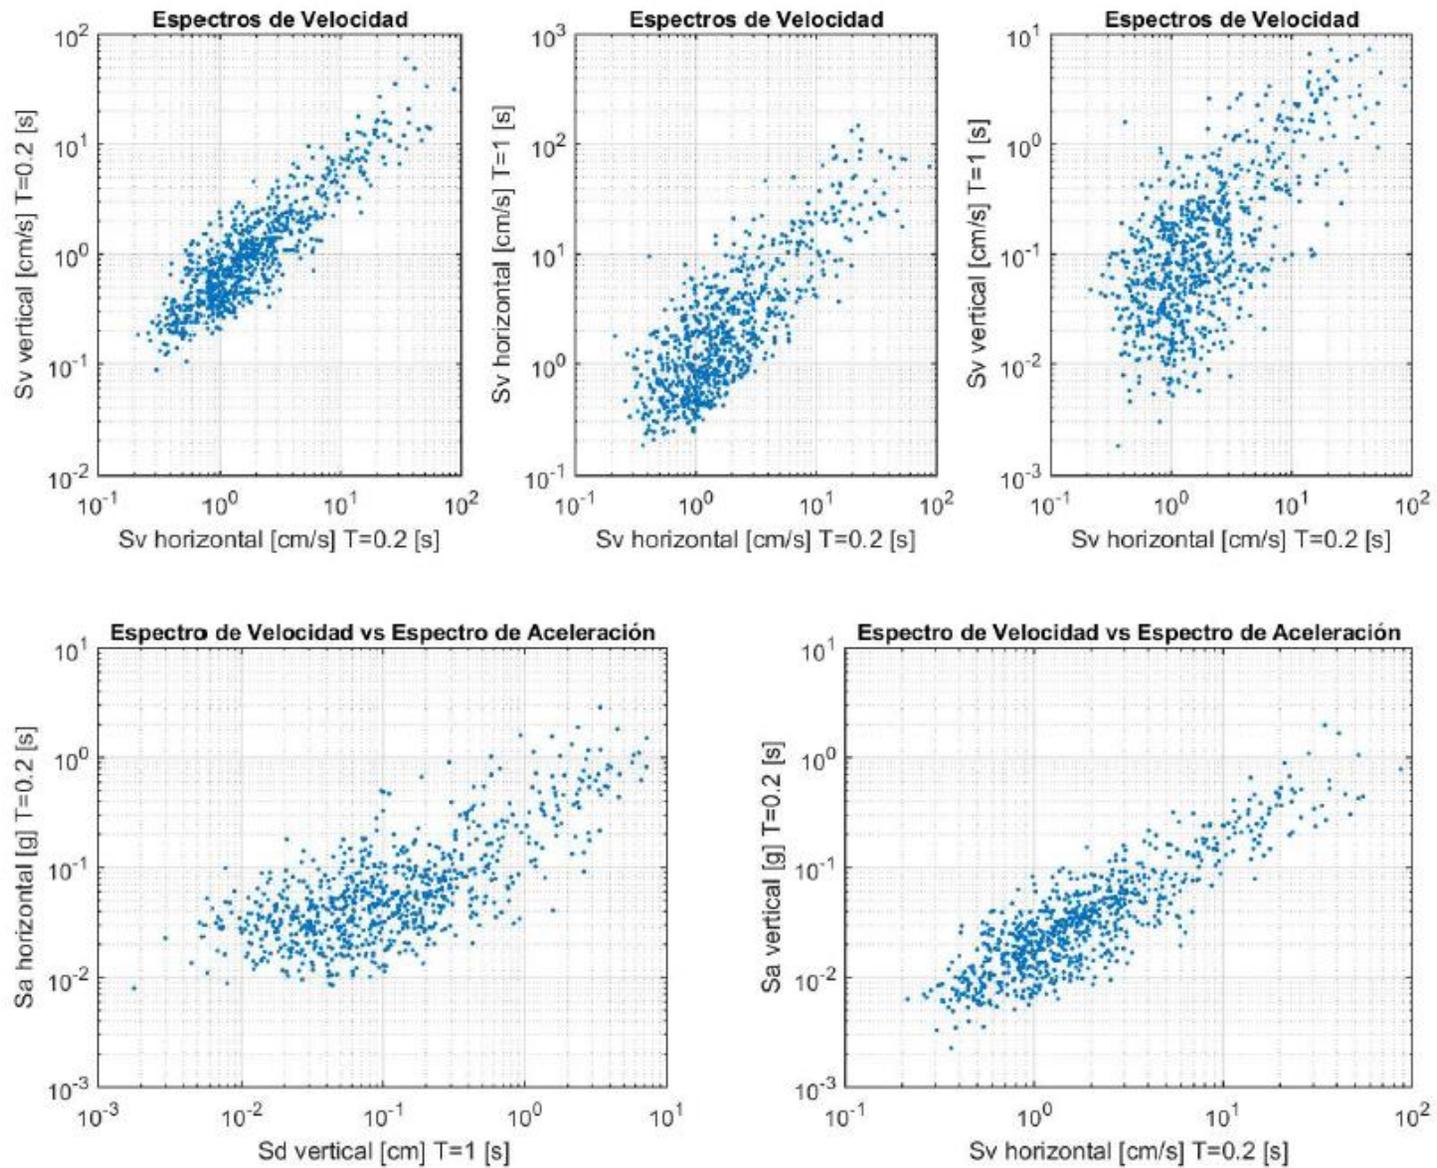
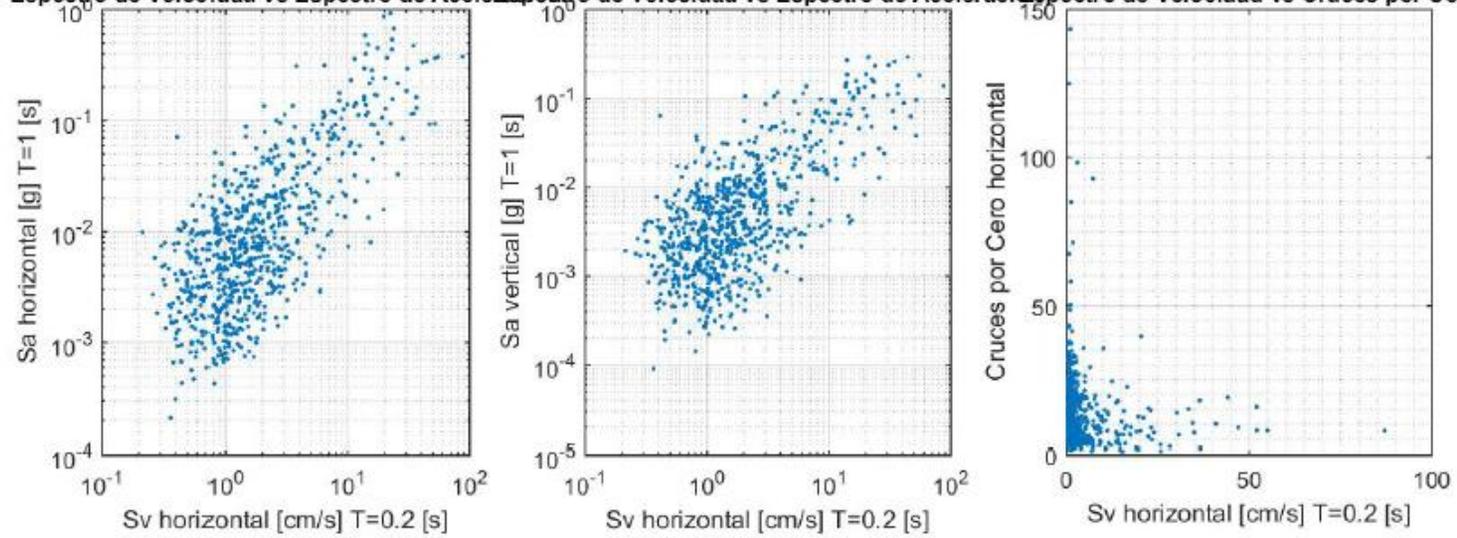


Figura C. 79: Relación entre Espectro de Velocidad Horizontal T=0.2 [s] y (a) Espectro de Velocidad Vertical T=0.2 [s], (b) Espectro de Velocidad Horizontal T=1 [s], (c) Espectro de Velocidad Vertical T=1 [s], (d) Espectro de Aceleración Horizontal T=0.2 [s], (e) Espectro de Aceleración Vertical T=0.2 [s].

Espectro de Velocidad vs Espectro de Aceleración Horizontal T=1 [s] **Espectro de Velocidad vs Espectro de Aceleración Vertical T=1 [s]** **Espectro de Velocidad vs Cruces por Cero Horizontal**



Espectro de Velocidad vs Cruces por Cero Vertical **Espectro de Velocidad vs Contenido de Frecuencia Central Horizontal** **Espectro de Velocidad vs Contenido de Frecuencia Central Vertical**

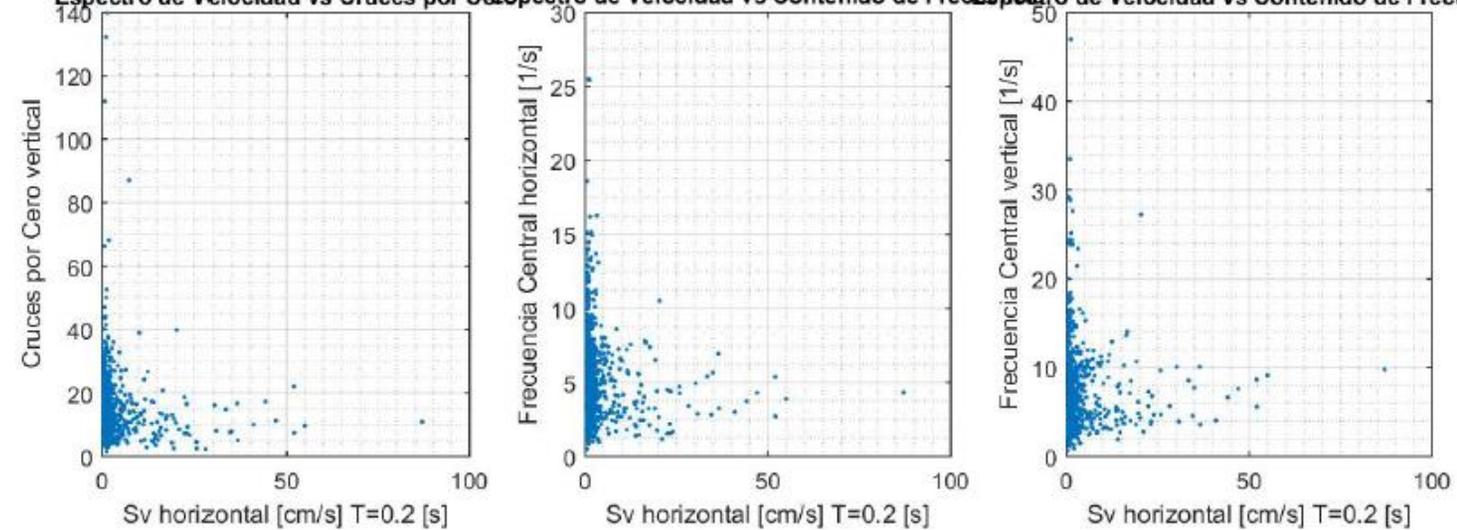


Figura C. 80: Relación entre Espectro de Velocidad Horizontal T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.

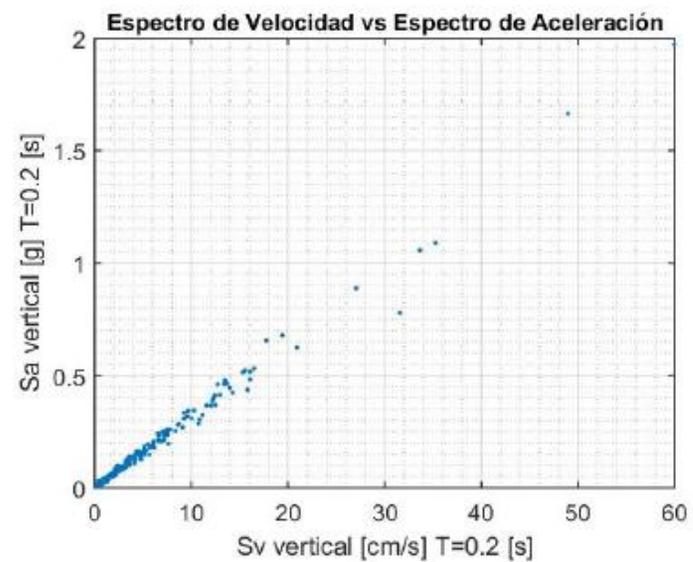
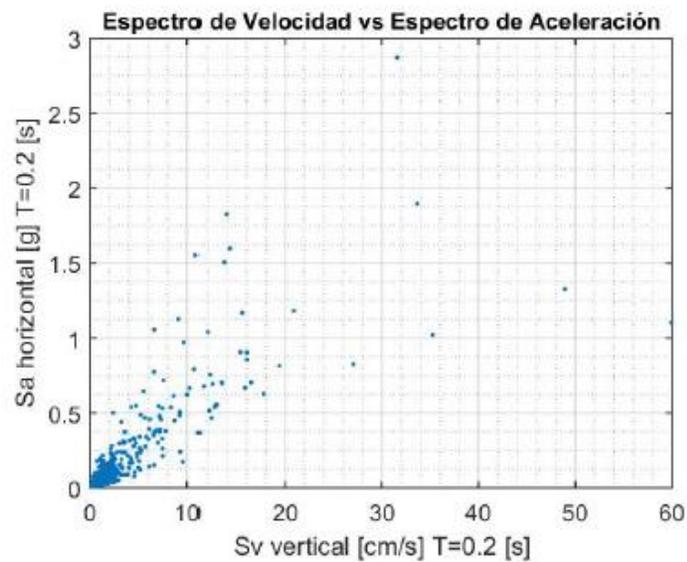
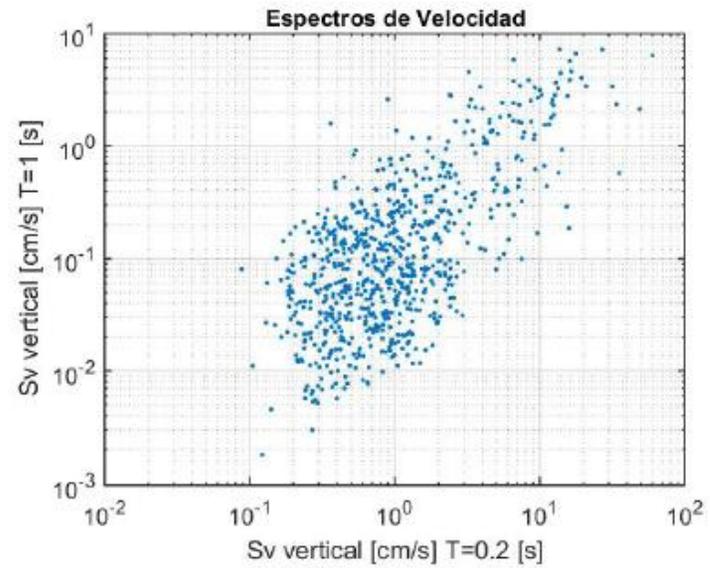
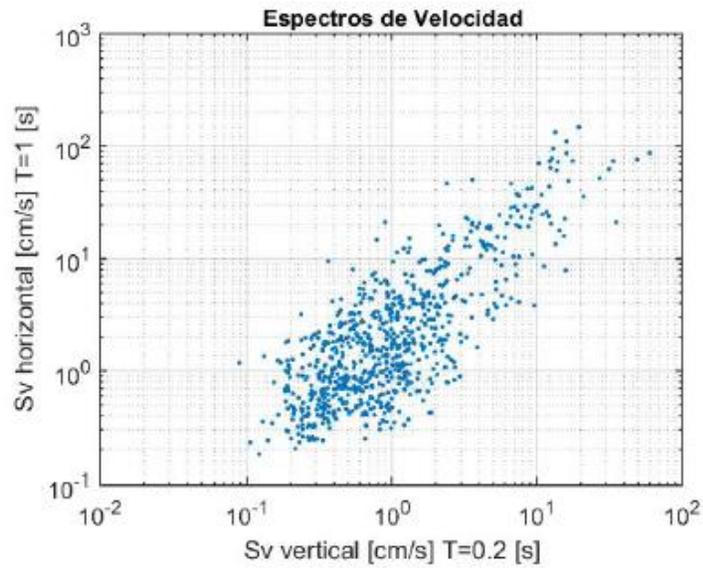


Figura C. 81: Relación entre Espectro de Velocidad Vertical T=0.2 [s] y (a) Espectro de Velocidad Horizontal T=1 [s], (b) Espectro de Velocidad Vertical T=1 [s], (c) Espectro de Aceleración Horizontal T=0.2 [s], (d) Espectro de Aceleración Vertical T=0.2 [s].

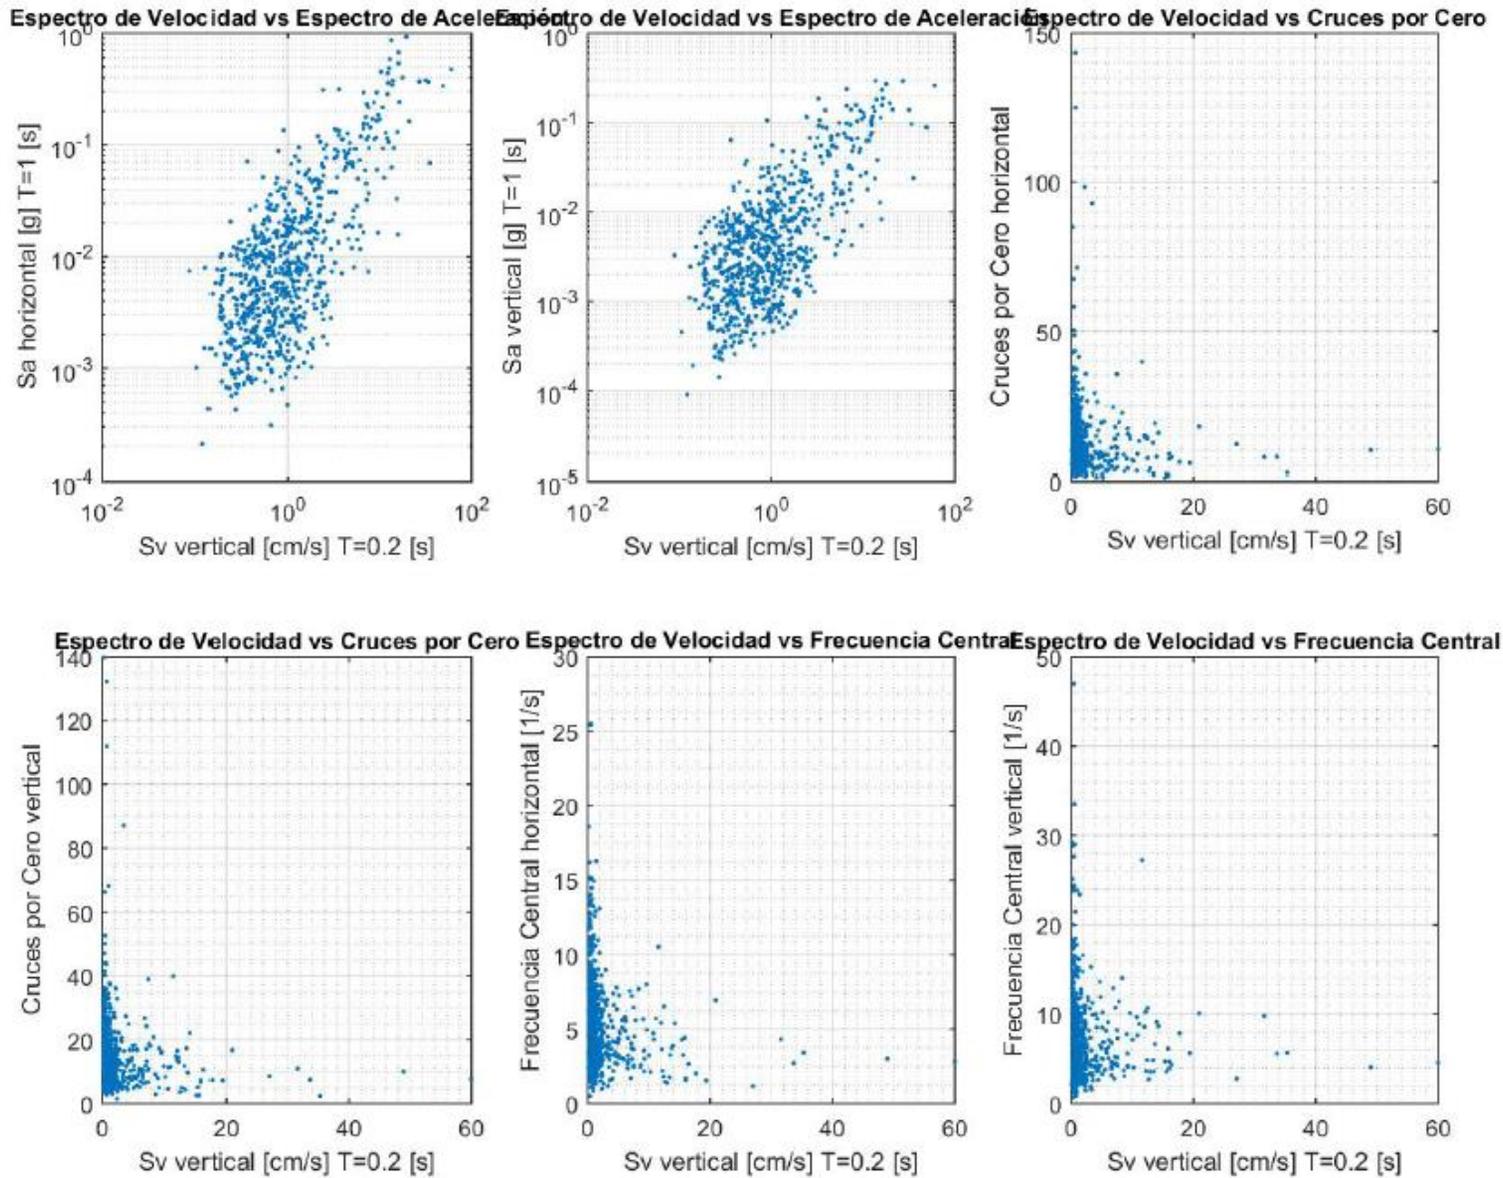


Figura C. 82: Relación entre Espectro de Velocidad Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal. (f) Frecuencia Central Vertical.

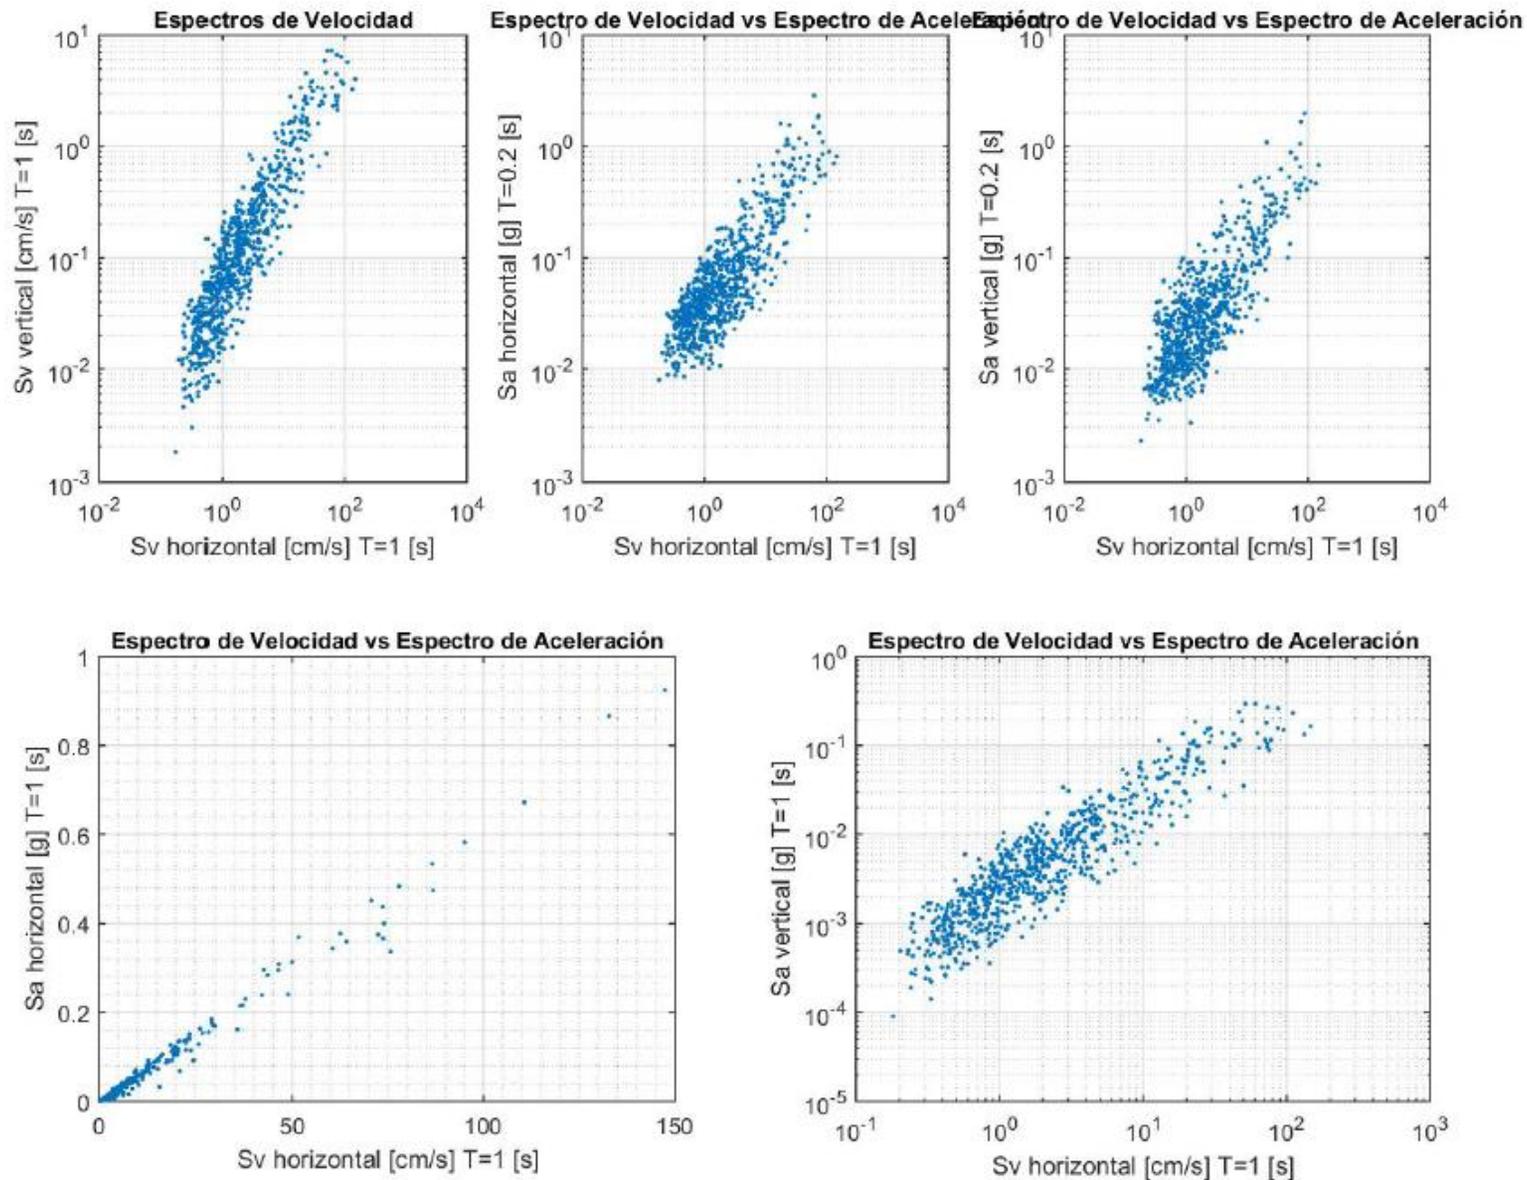


Figura C. 83: Relación entre Espectro de Velocidad Horizontal T=1 [s] y (a) Espectro de Velocidad Vertical T=1 [s], (b) Espectro de Aceleración Horizontal T=0.2 [s], (c) Espectro de Aceleración Vertical T=0.2 [s], (d) Espectro de Aceleración Horizontal T=1 [s], (e) Espectro de Aceleración Vertical T=1 [s].

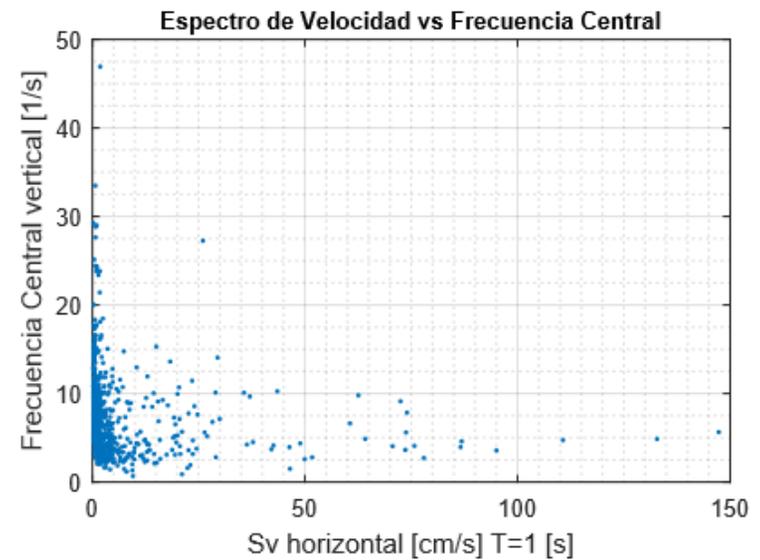
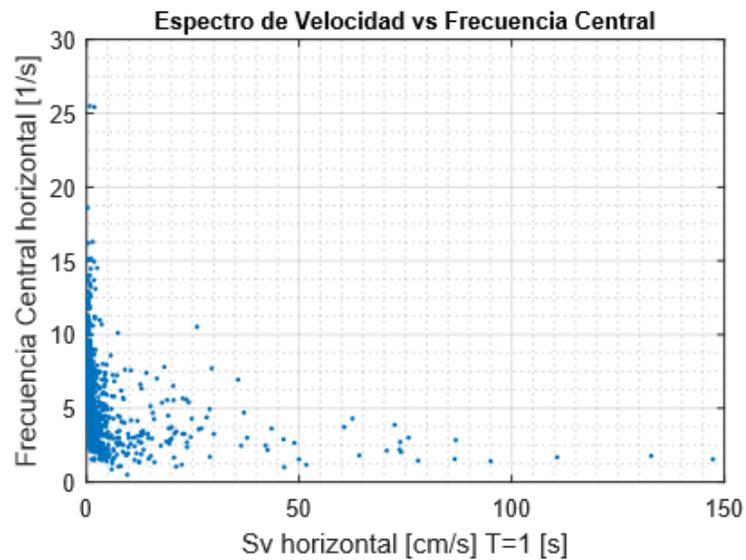
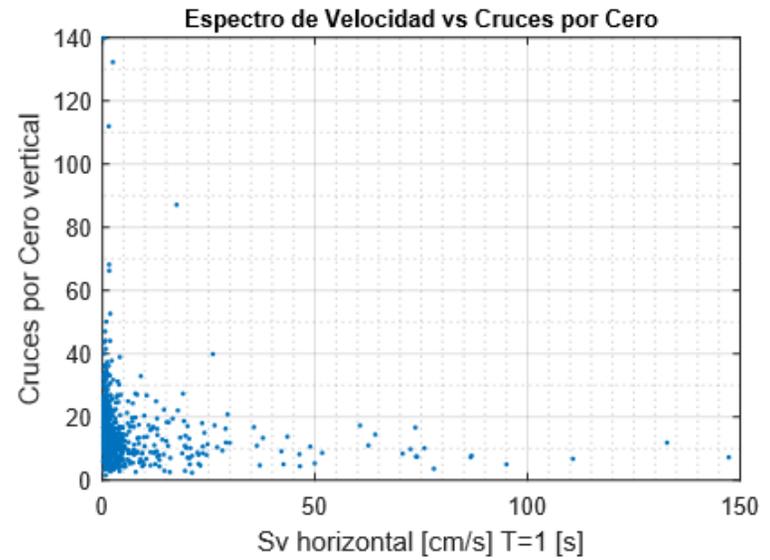
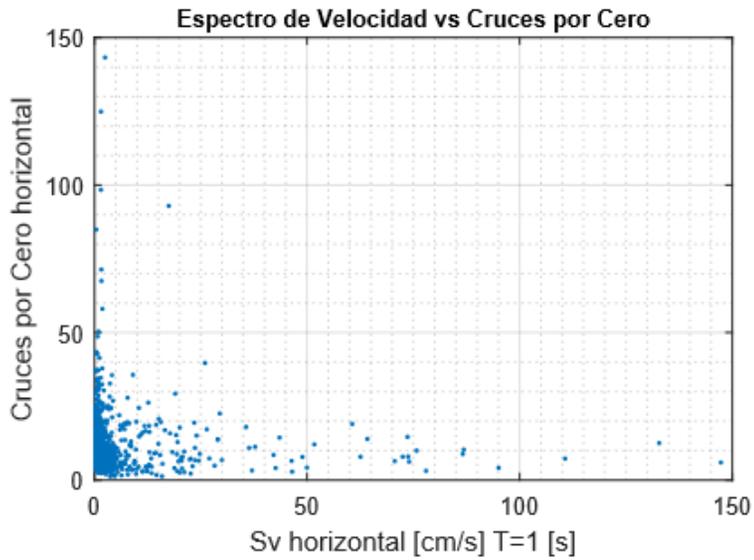


Figura C. 84: Relación entre Espectro de Velocidad Horizontal T=1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Horizontal, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

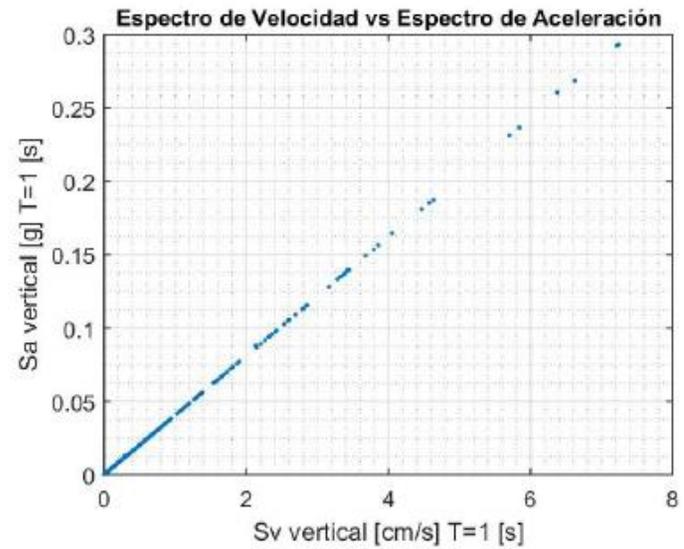
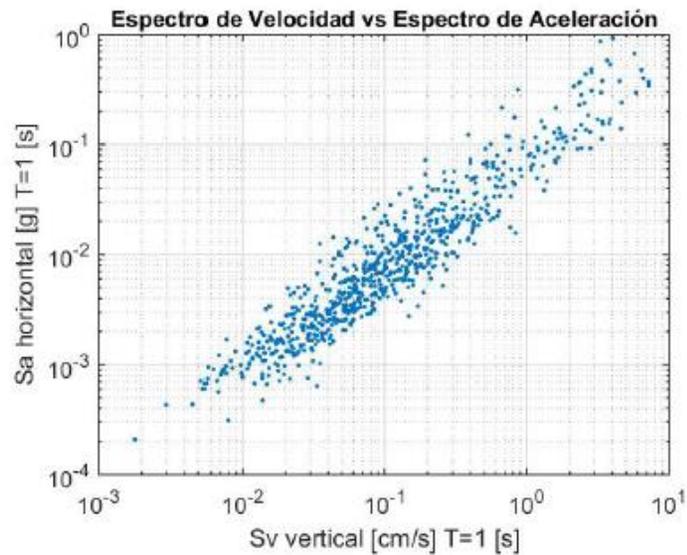
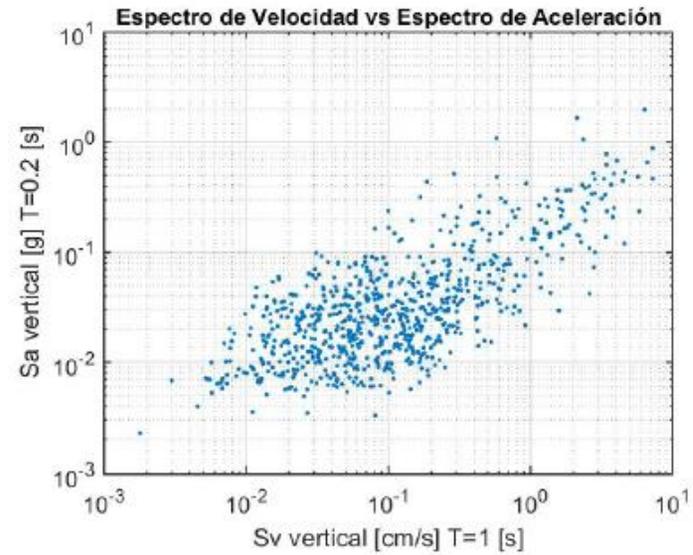
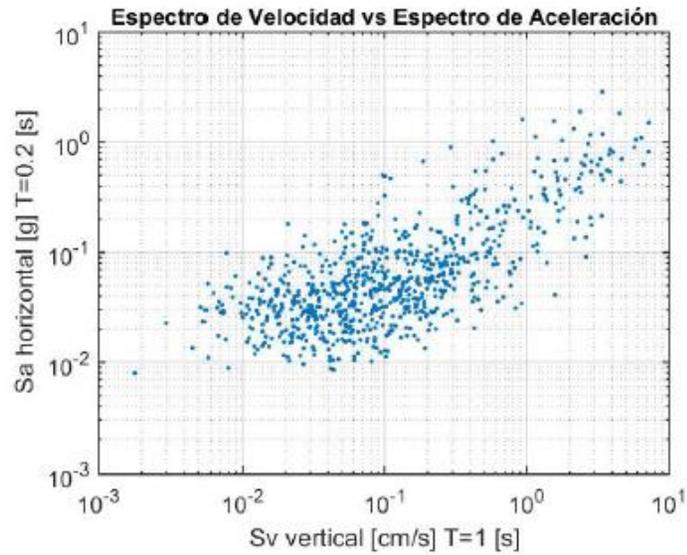


Figura C. 85: Relación entre Espectro de Velocidad Vertical T=1 [s] y (a) Espectro de Aceleración Horizontal T=0.2 [s], (b) Espectro de Aceleración Vertical T=0.2 [s], (c) Espectro de Aceleración Horizontal T=1 [s], (d) Espectro de Aceleración Vertical T=1 [s].

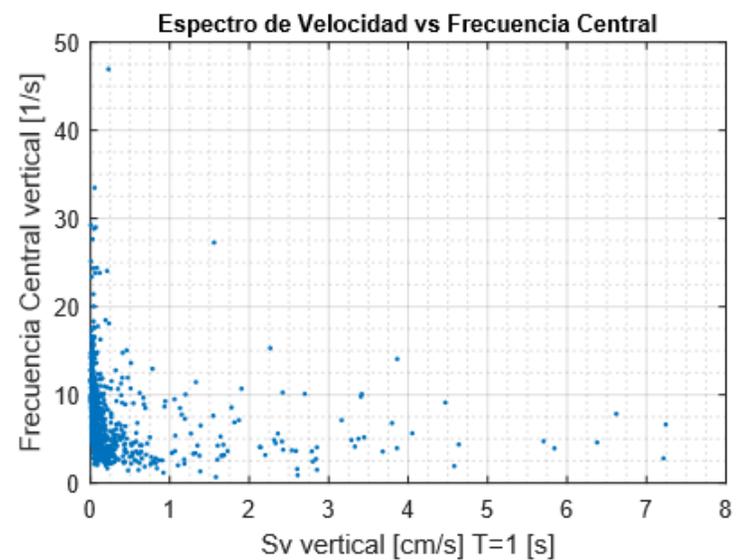
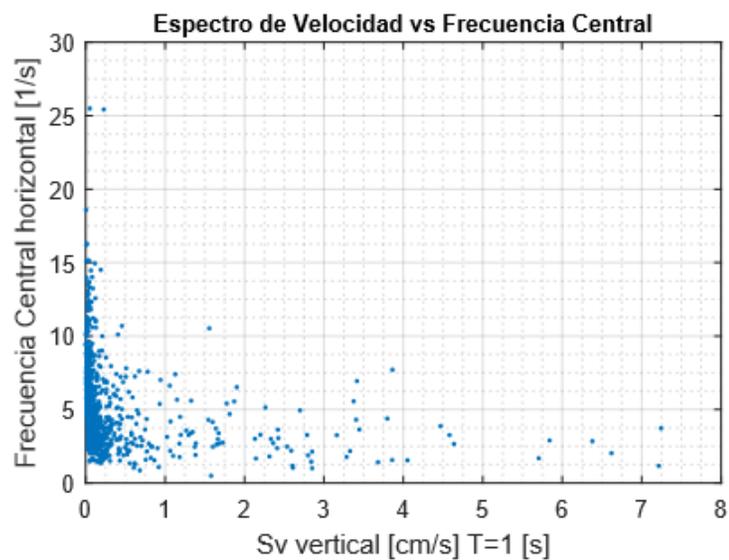
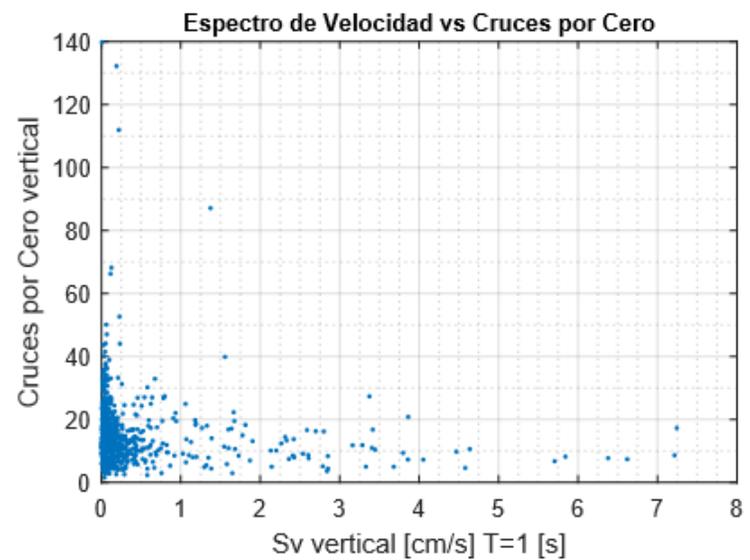
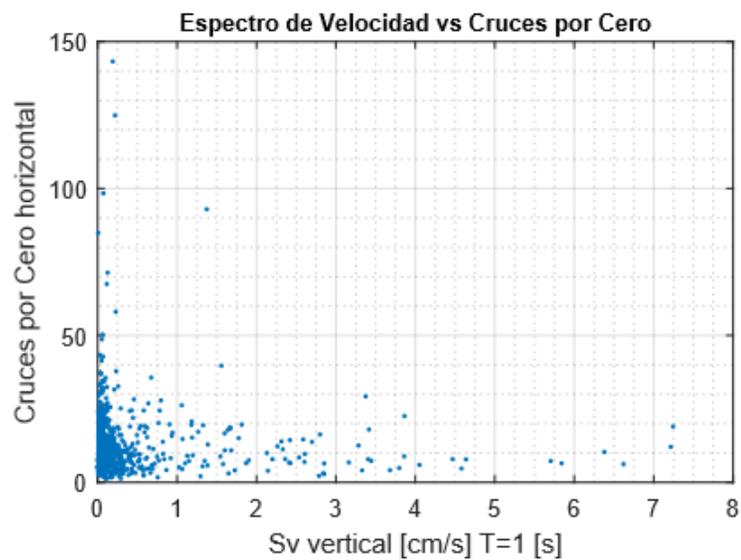


Figura C. 86: Relación entre Espectro de Velocidad Vertical T=1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

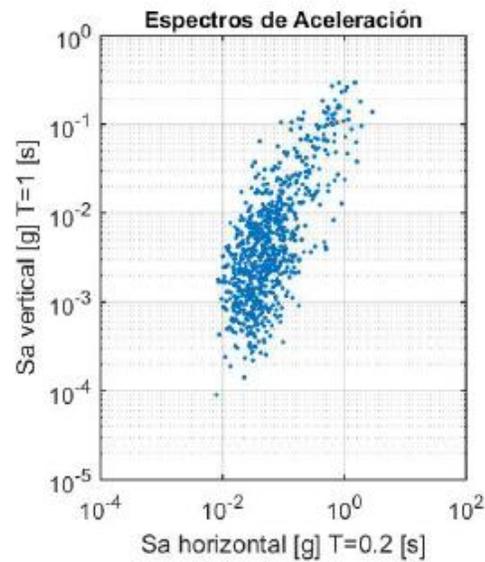
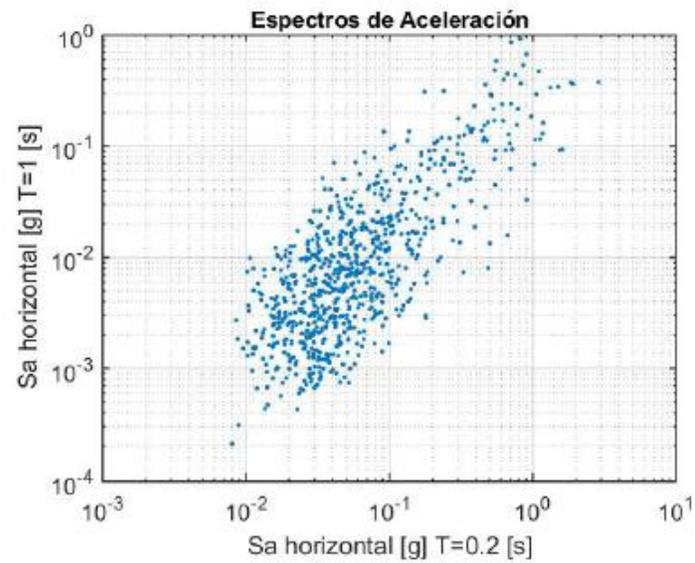
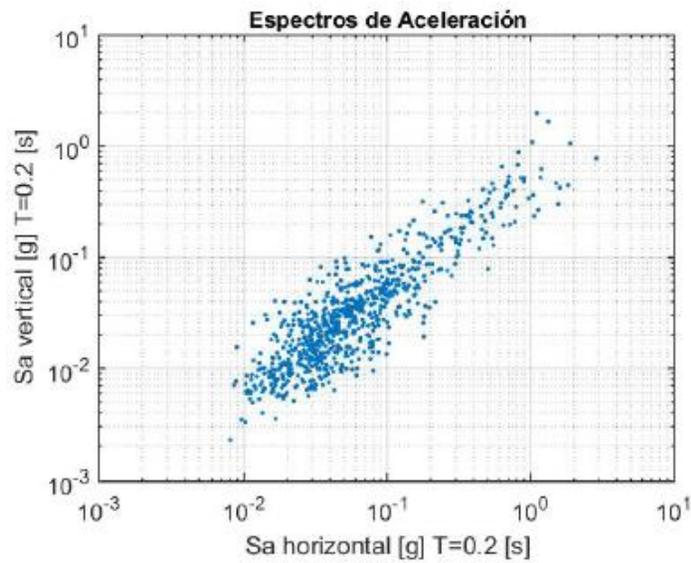


Figura C. 87: Relación entre Relación entre Espectro de Aceleración Horizontal $T=0.2$ [s] y (a) Espectro de Aceleración Vertical $T=0.2$ [s], (b) Espectro de Aceleración Horizontal $T=1$ [s], (c) Espectro de Aceleración Vertical $T=1$ [s].

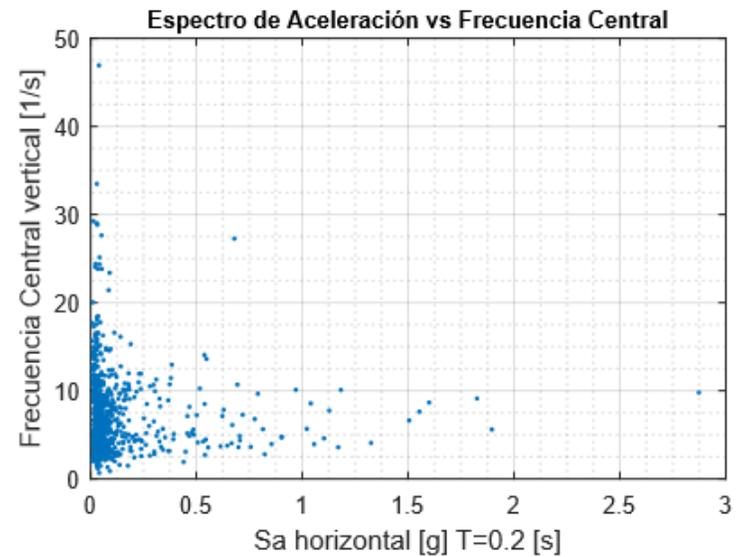
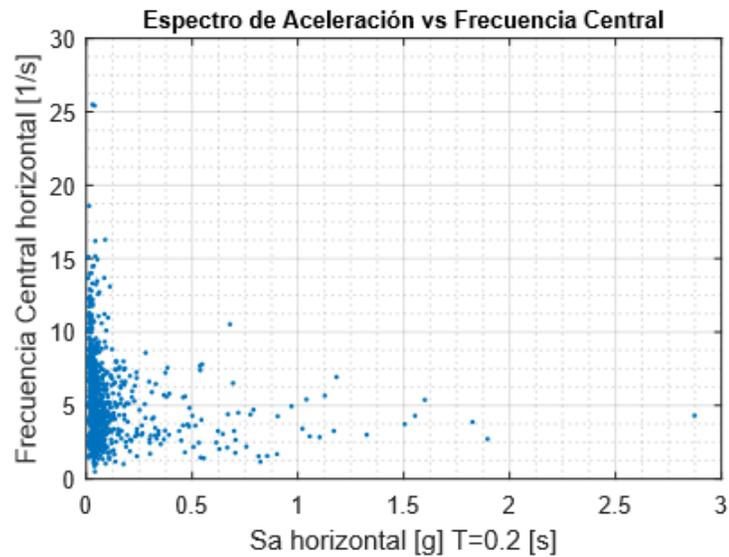
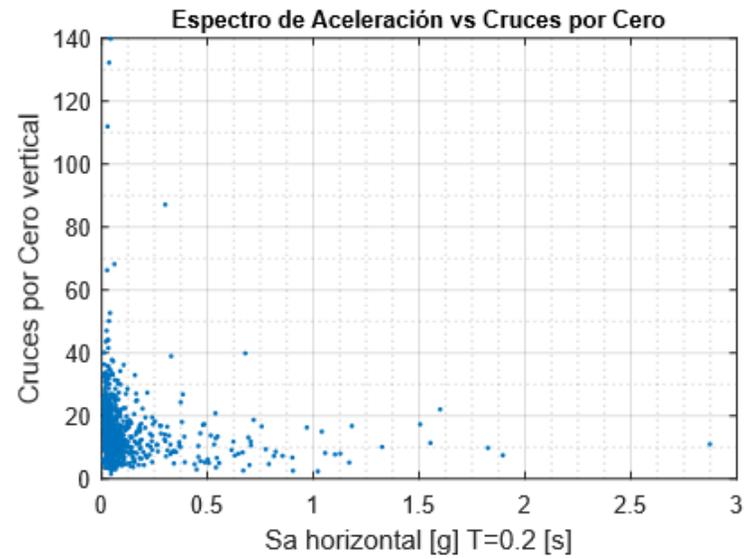
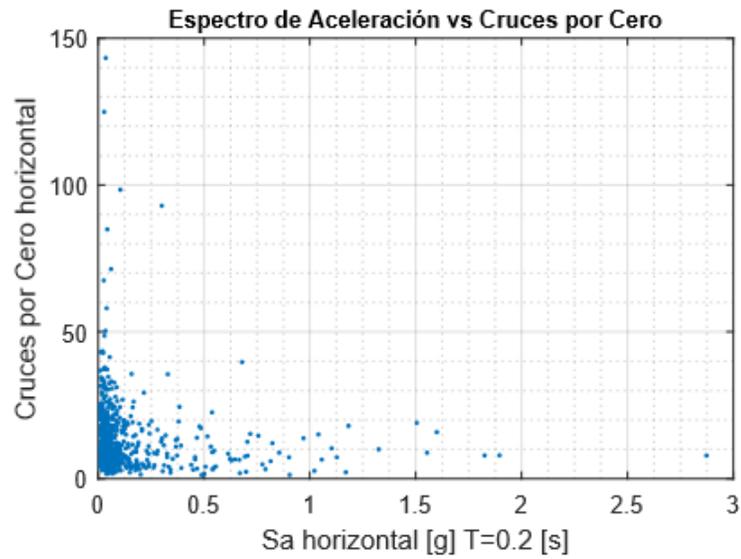


Figura C. 88: Relación entre Relación entre Espectro de Aceleración Horizontal T=0.2 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

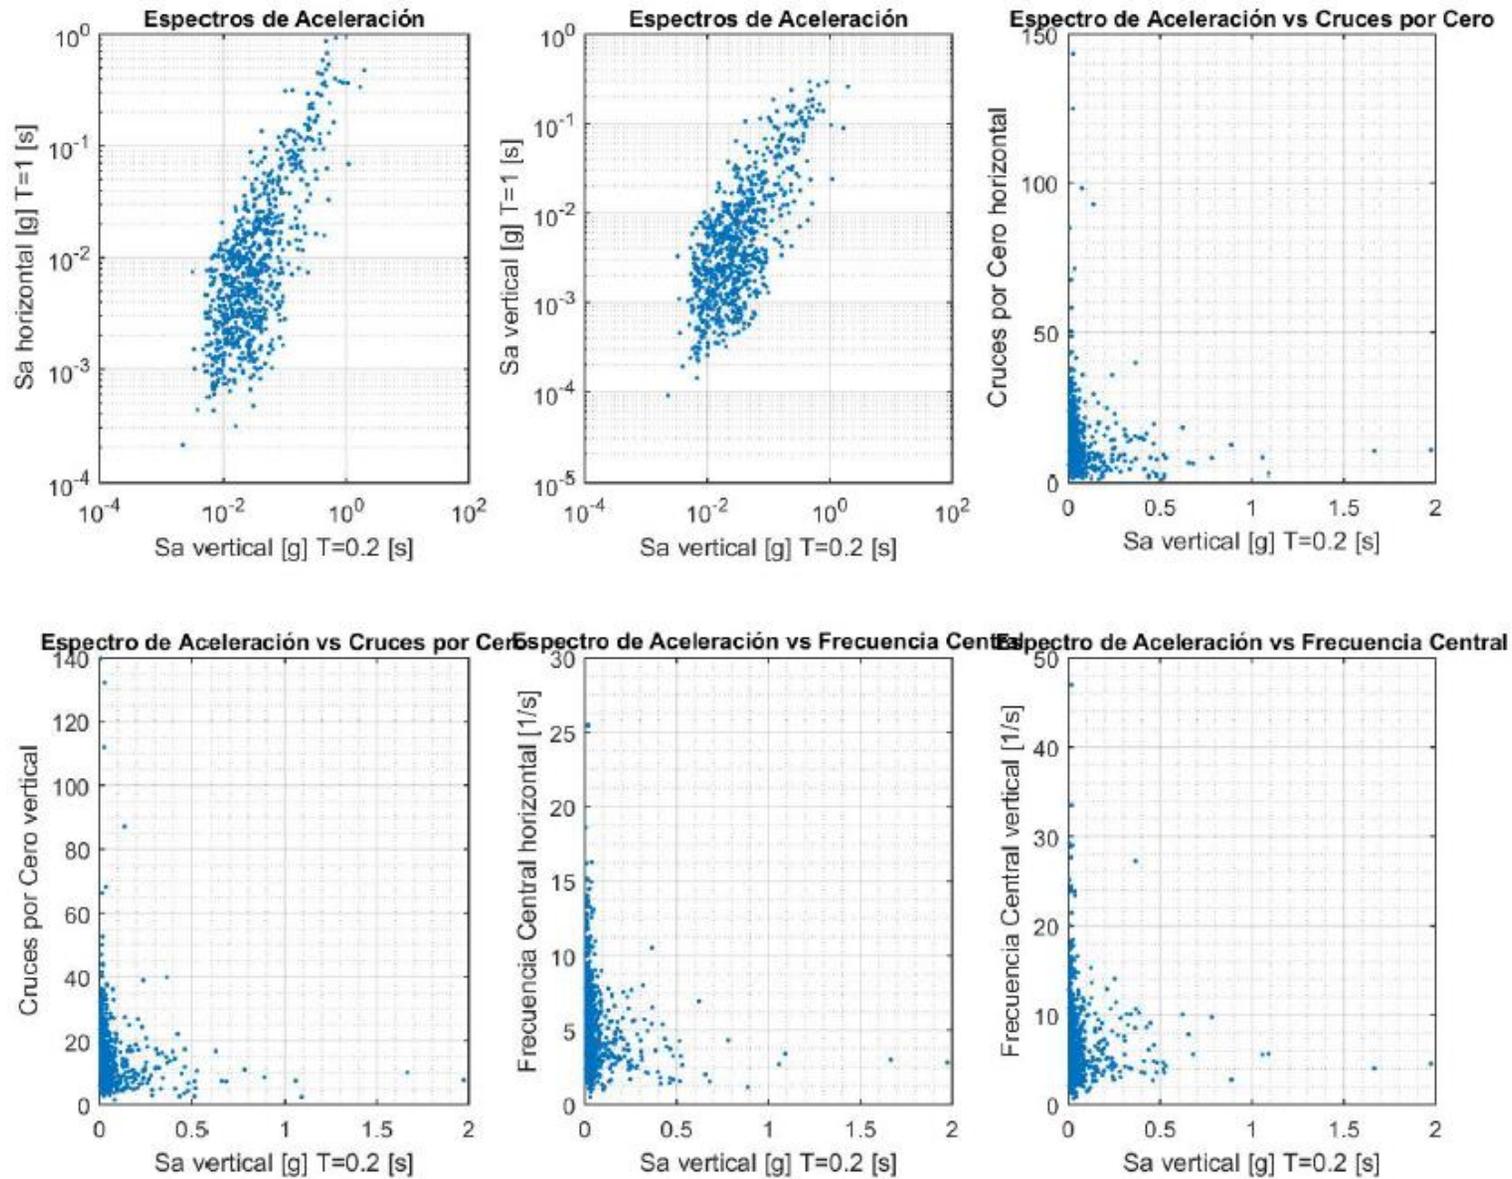


Figura C. 89: Relación entre Relación entre Espectro de Aceleración Vertical T=0.2 [s] y (a) Espectro de Aceleración Horizontal T=1 [s], (b) Espectro de Aceleración Vertical T=1 [s], (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.

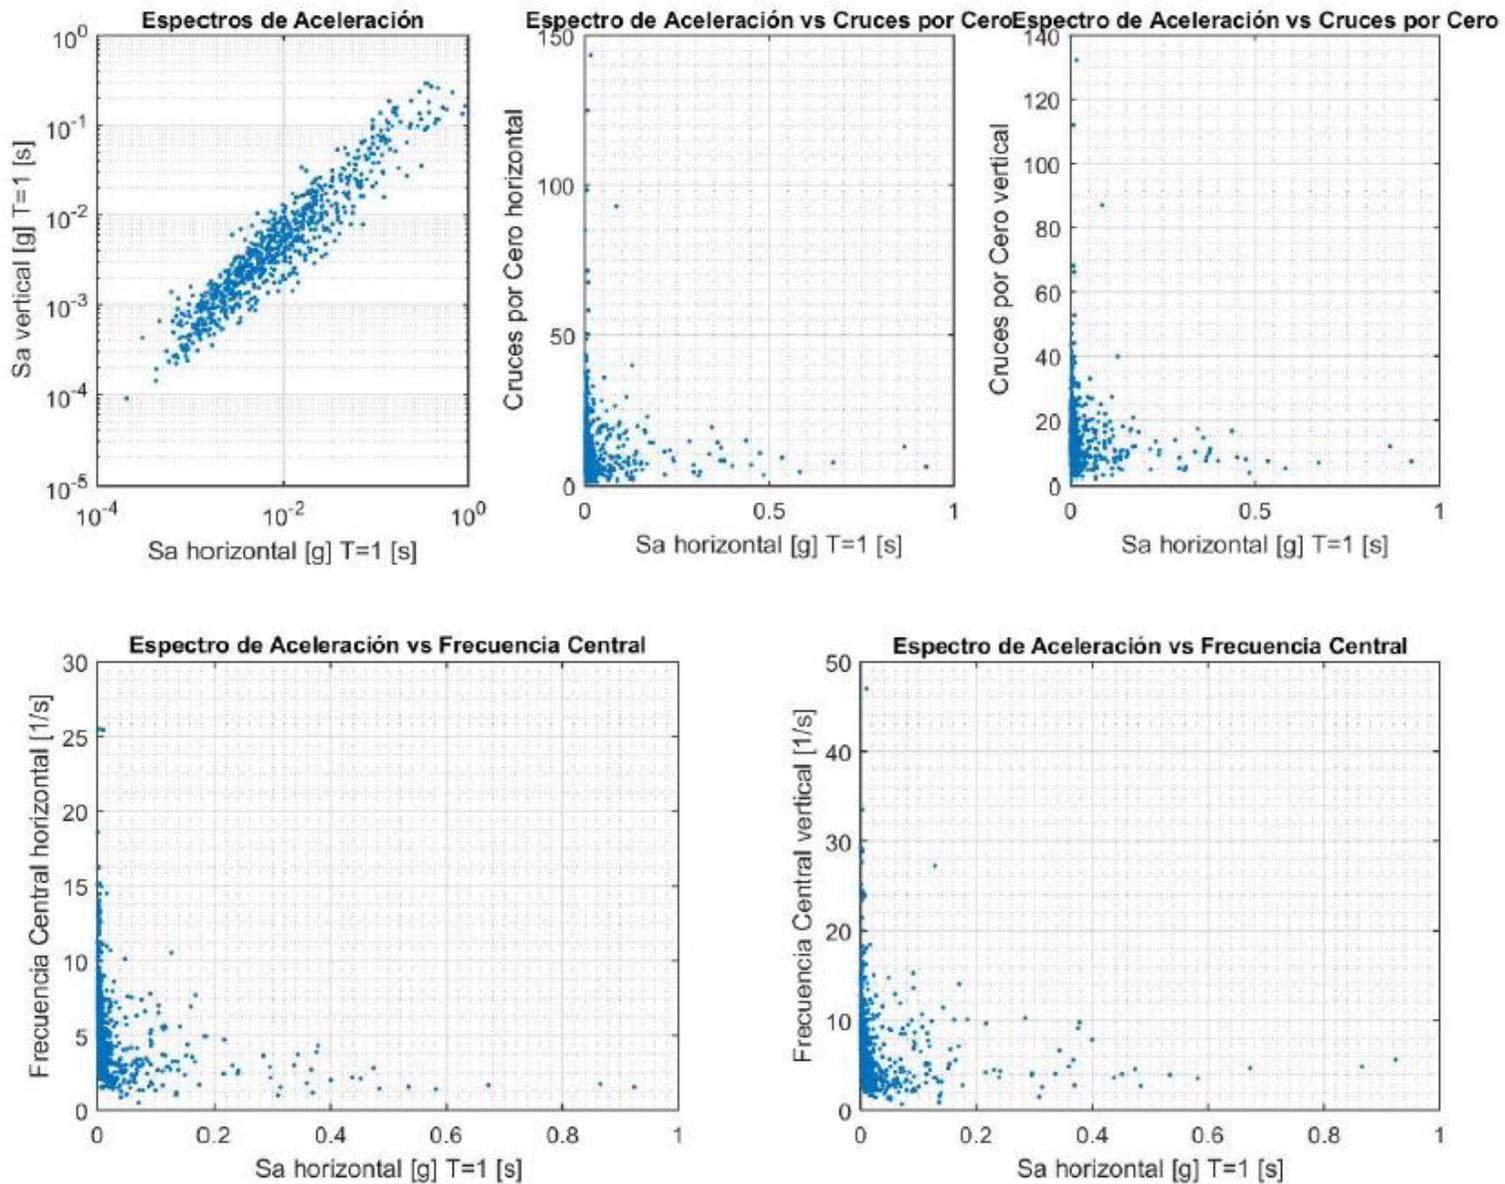


Figura C. 90: Relación entre Espectro de Aceleración Horizontal T= 1 [s] y (a) Espectro de Aceleración Vertical T= 1 [s], (b) Cruces por Cero Horizontal, (c) Cruces por Cero Vertical, (d) Frecuencia Central Horizontal, (e) Frecuencia Central Vertical.

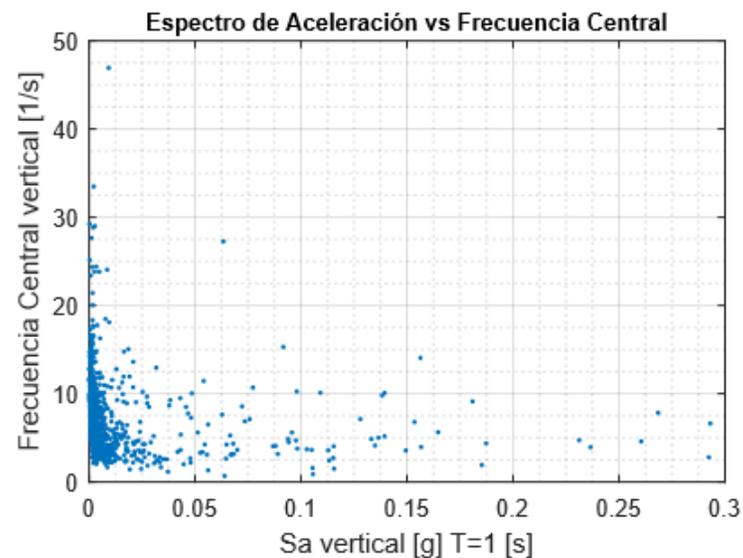
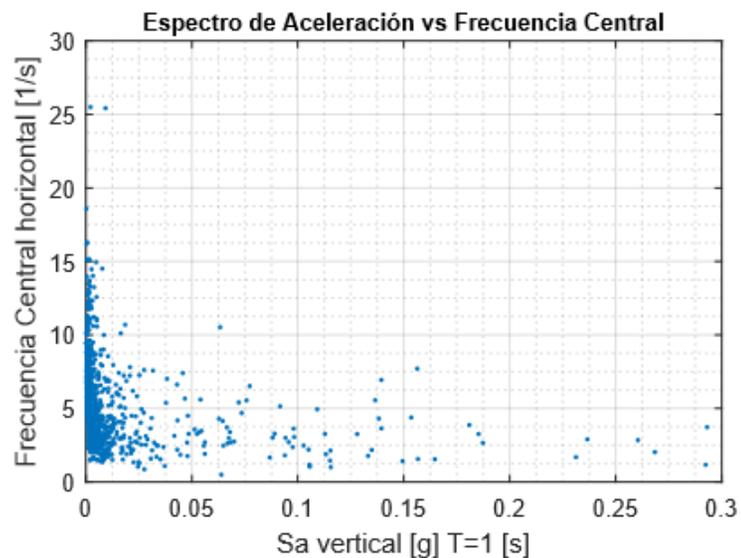
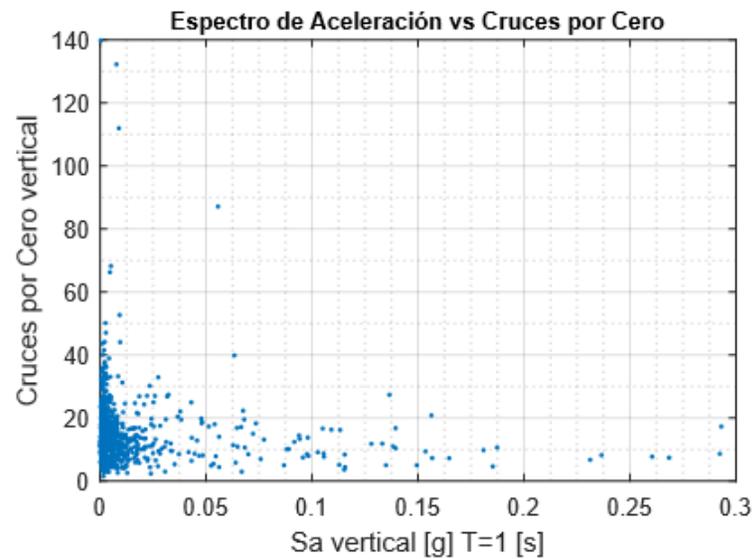
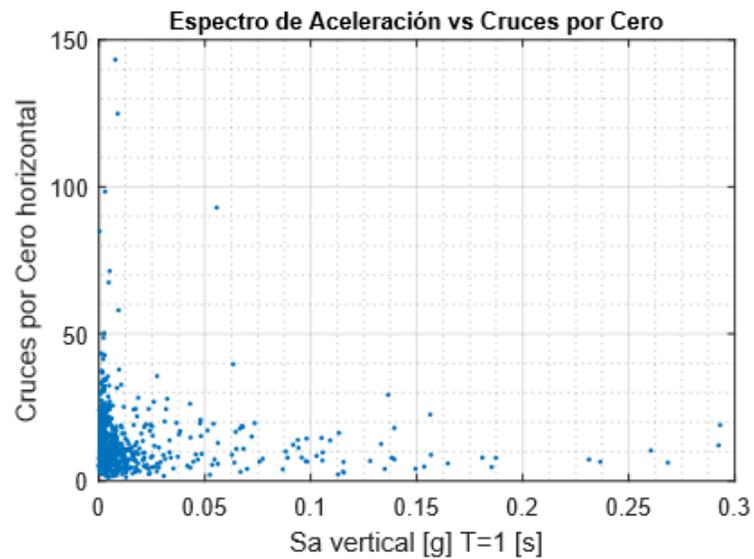


Figura C. 91: Relación entre Espectro de Aceleración Vertical T= 1 [s] y (a) Cruces por Cero Horizontal, (b) Cruces por Cero Vertical, (c) Frecuencia Central Horizontal, (d) Frecuencia Central Vertical.

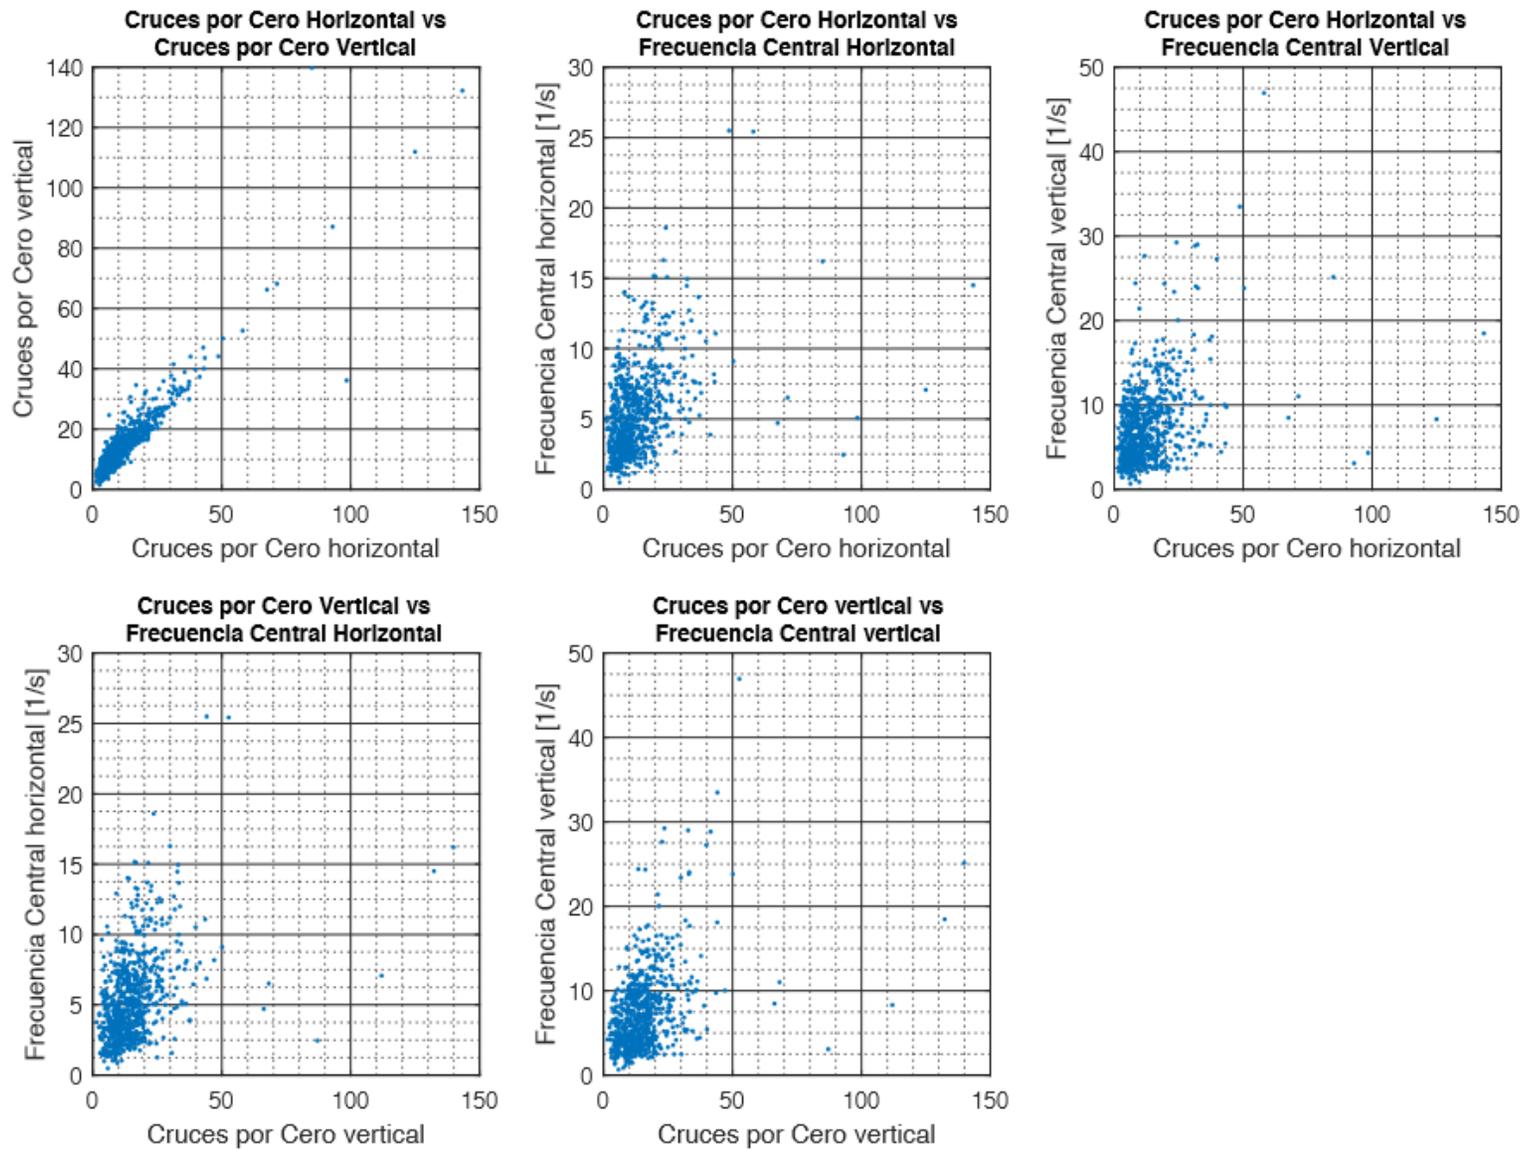


Figura C. 92: Relación entre Cruces por Cero Horizontal y (a) Cruces por Cero Vertical, (b) Frecuencia Central Horizontal, (c) Frecuencia Central Vertical, (d) Relación entre Cruces por Cero Vertical y Frecuencia Central Horizontal, (e) Relación entre Cruces por Cero Vertical y Frecuencia Central Vertical.

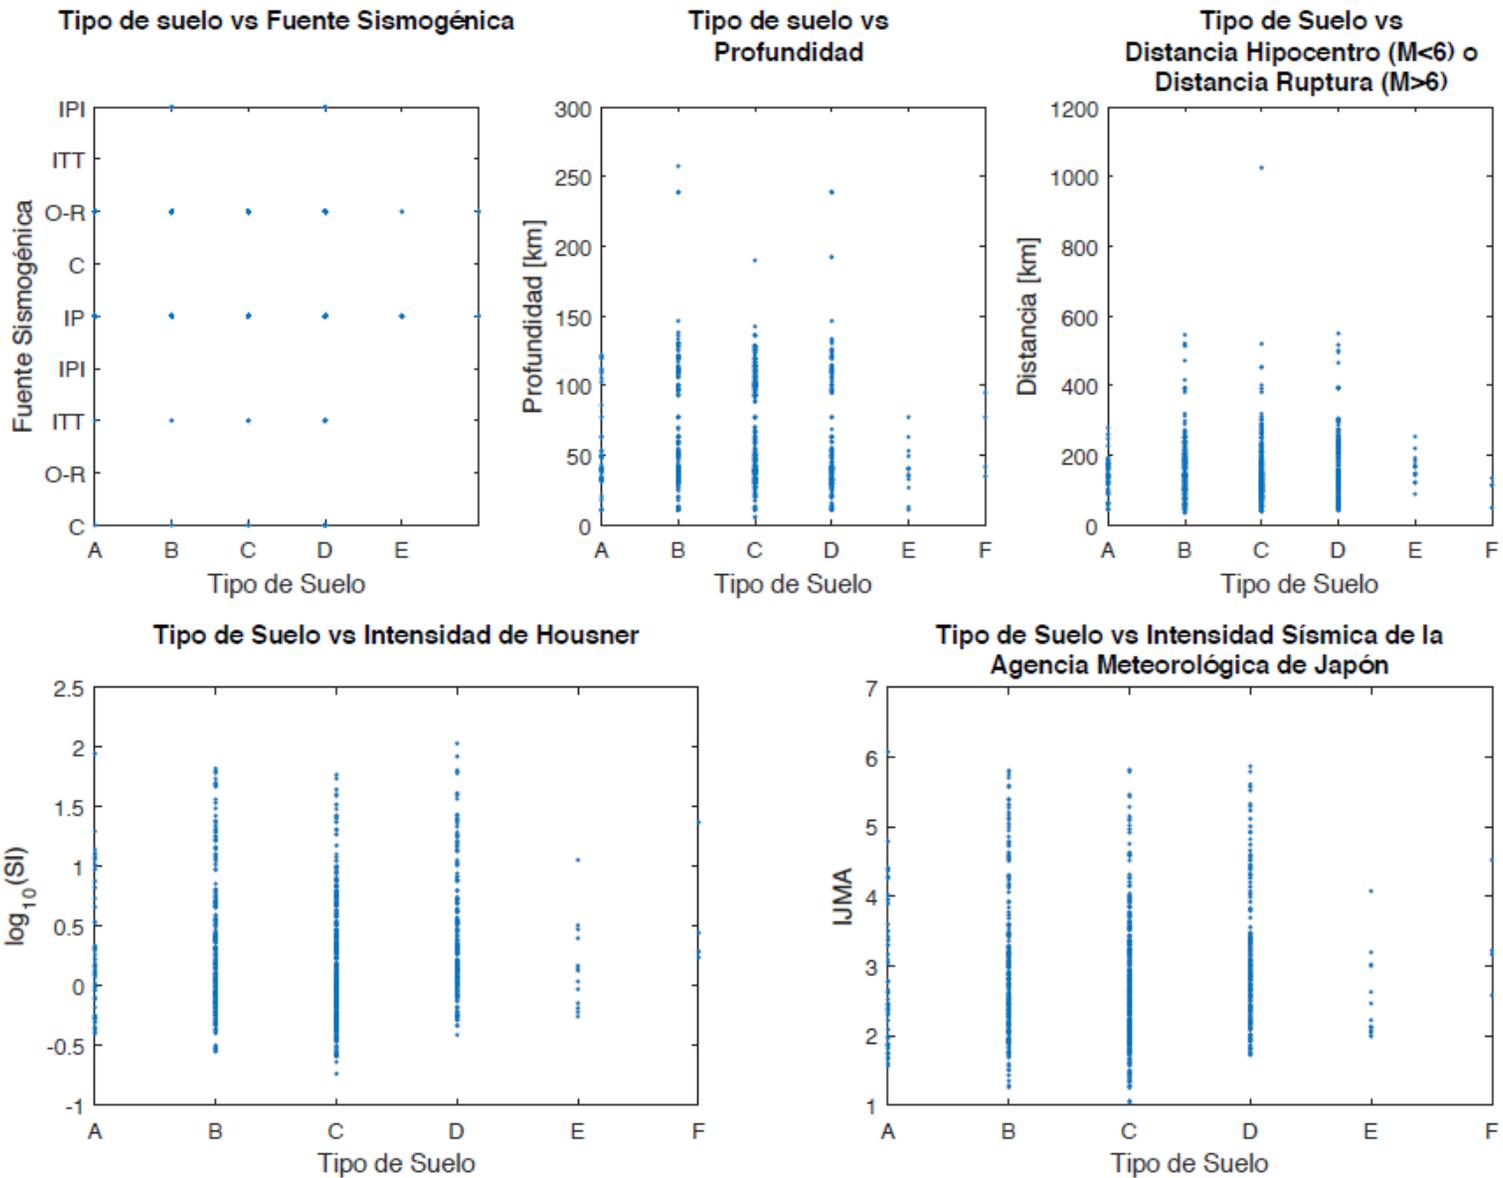


Figura C. 93: Relación entre Tipo de Suelo y (a) Fuente Sismogénica, (b) Profundidad, (c) Distancia Hipocentro o Ruptura, (d) $\log(SI)$, (e) IJMA.

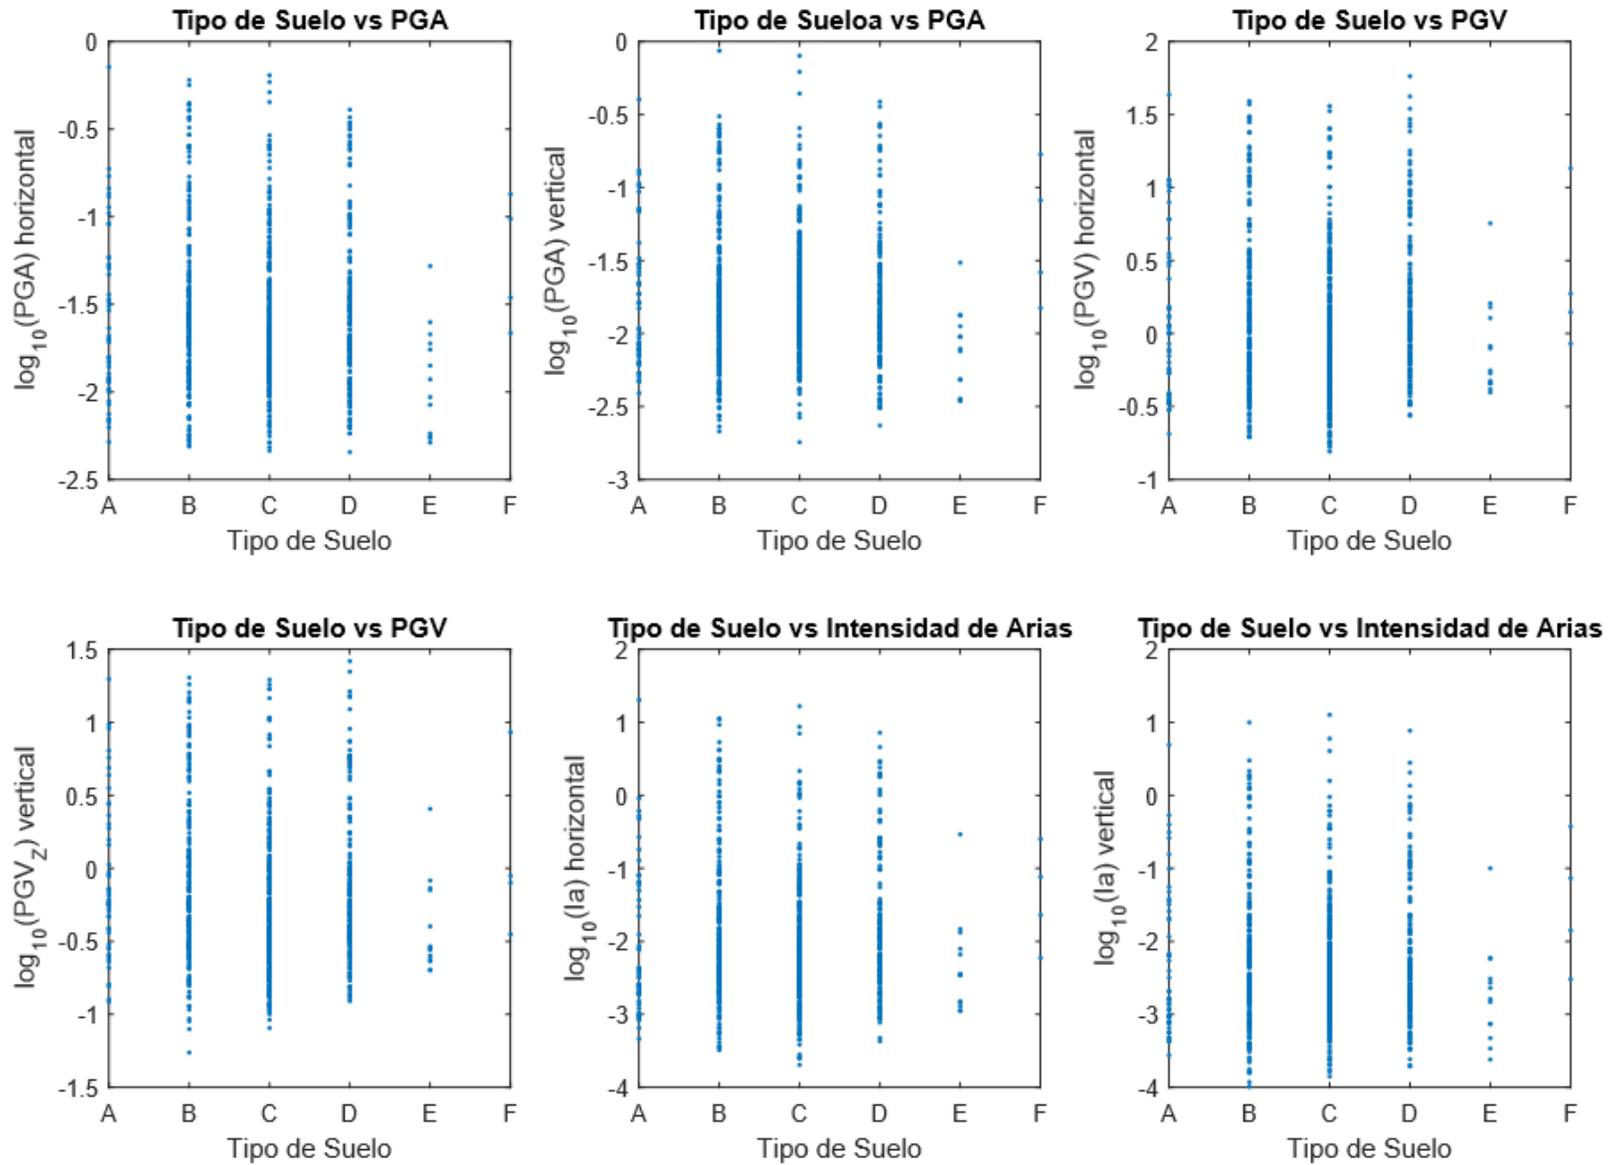


Figura C. 94: Relación entre Tipo de Suelo y (a) $\log(\text{PGA})$ Horizontal, (b) $\log(\text{PGA})$ Vertical, (c) $\log(\text{PGV})$ Horizontal, (d) $\log(\text{PGV})$ Vertical, (e) $\log(I_a)$ Horizontal, (f) $\log(I_a)$ Vertical.

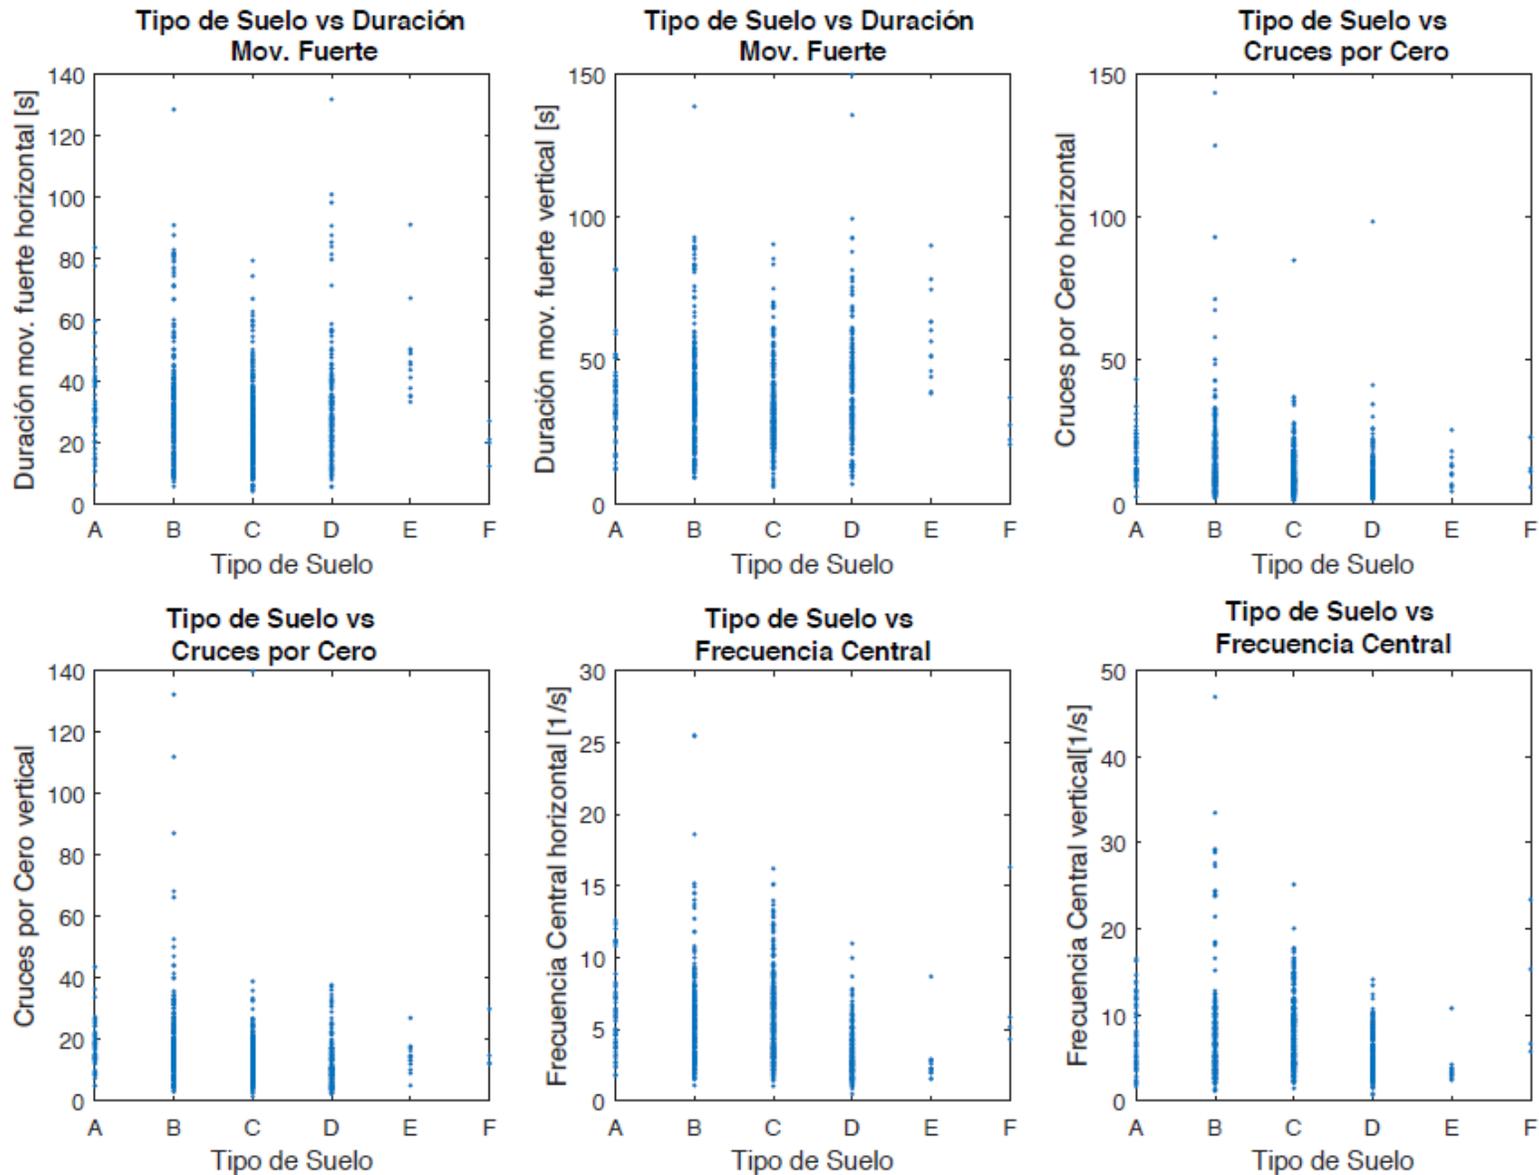


Figura C. 95: Relación entre Tipo de Suelo y (a) Duración Mov. Fuerte Horizontal, (b) Duración Mov. Fuerte Vertical, (c) Cruces por Cero Horizontal, (d) Cruces por Cero Vertical, (e) Frecuencia Central Horizontal, (f) Frecuencia Central Vertical.

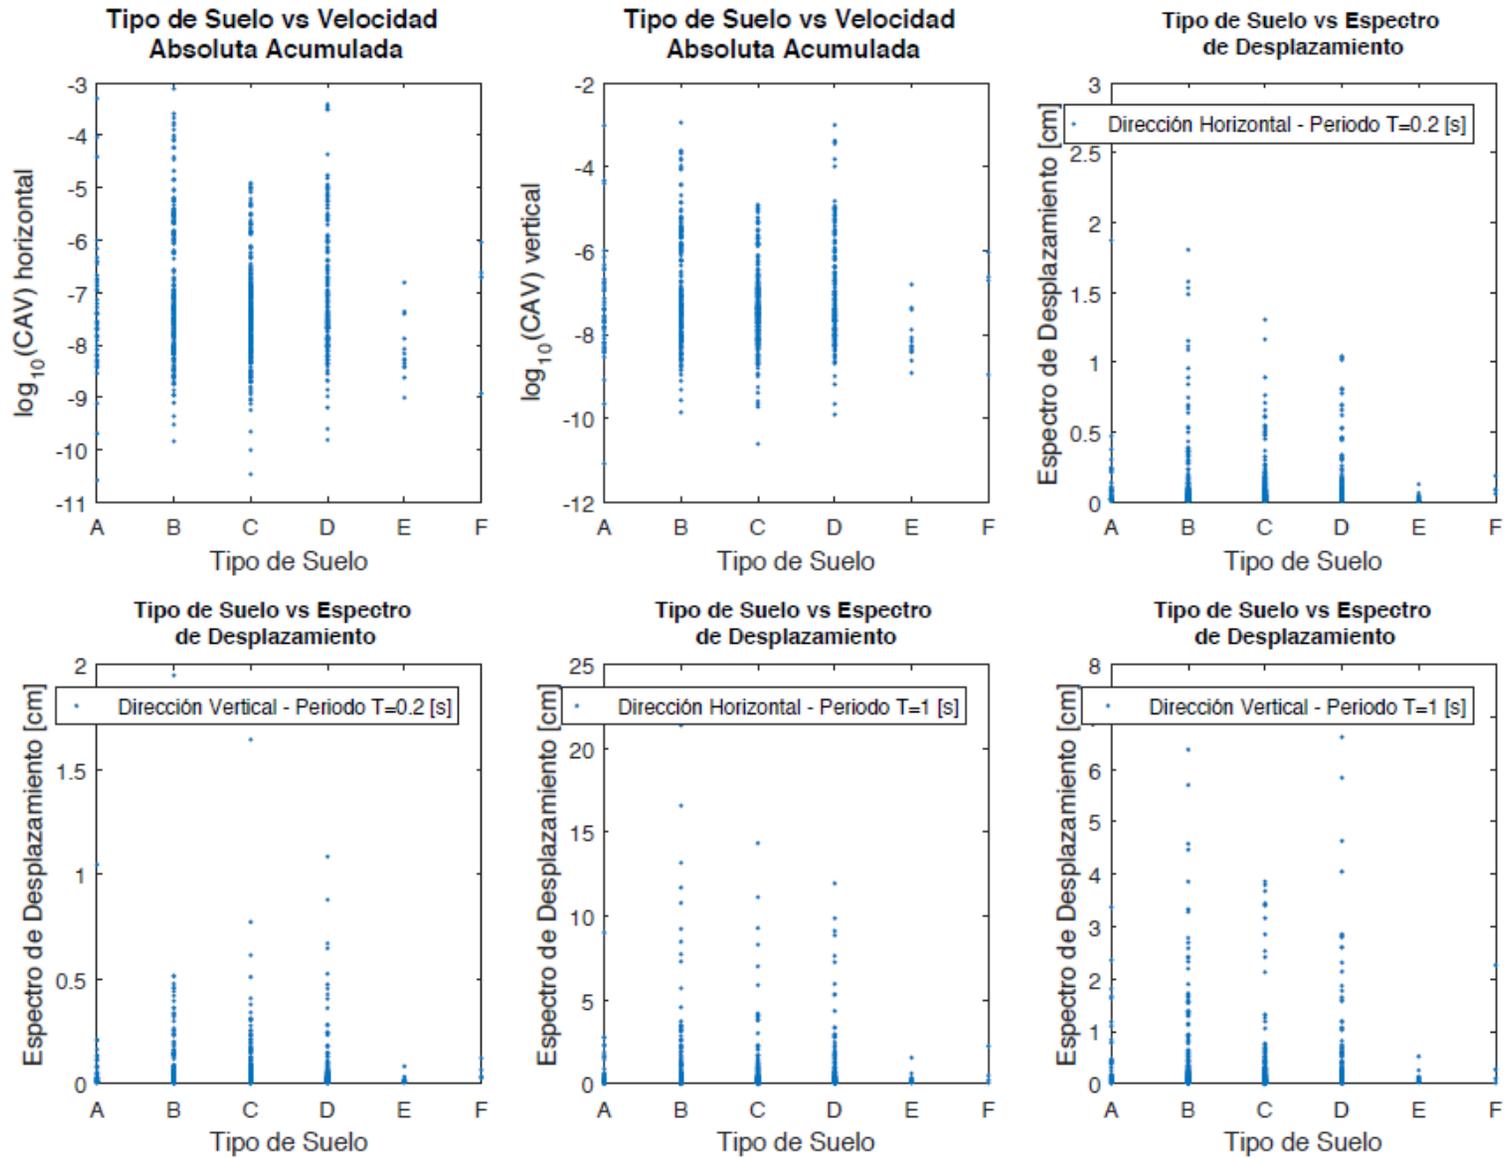


Figura C. 96: Relación entre Tipo de Suelo y (a) Espectro de Desplazamiento Horizontal T=0.2 [s], (b) Espectro de Desplazamiento Vertical T=0.2 [s], (c) Espectro de Desplazamiento Horizontal T=1 [s], (d) Espectro de Desplazamiento Vertical T=1 [s].

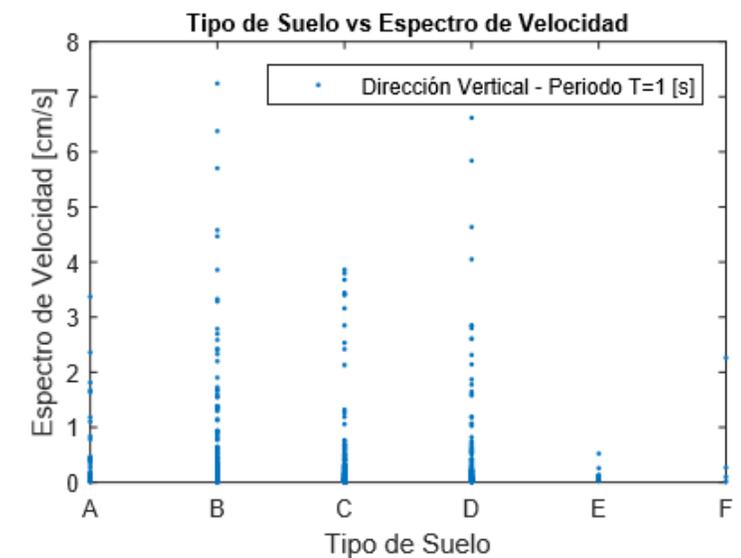
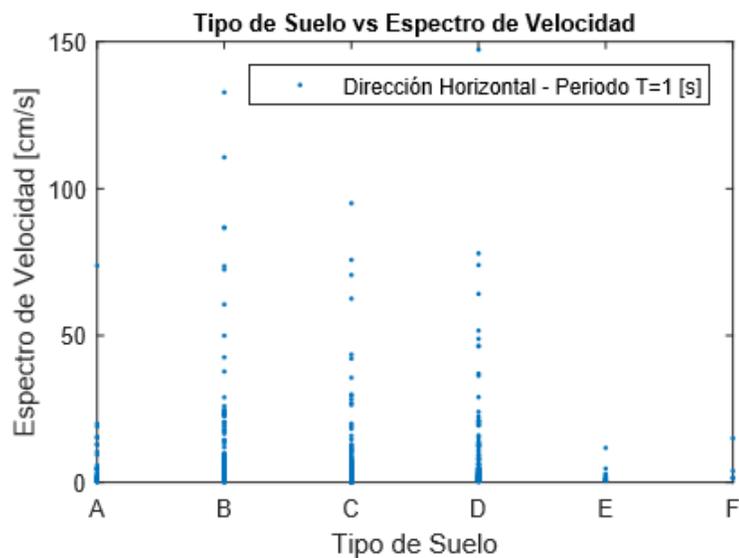
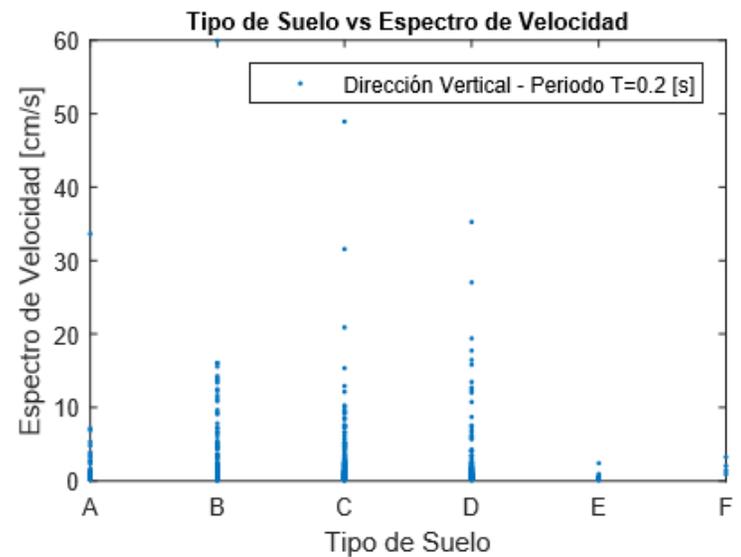
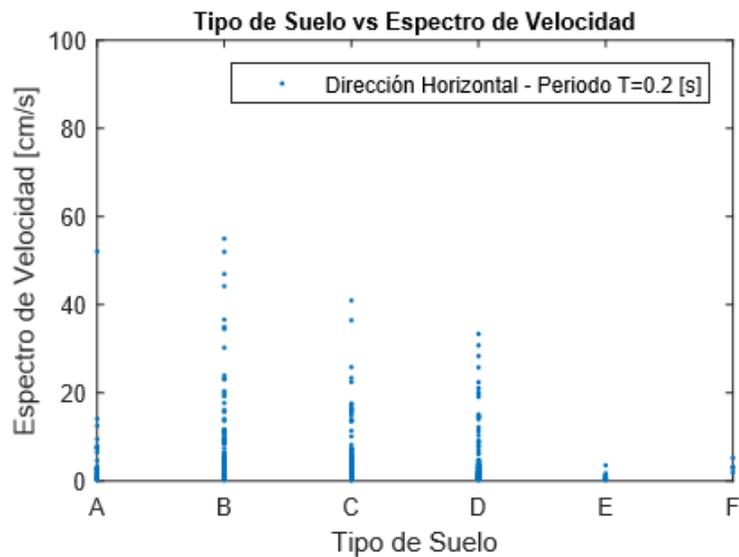


Figura C. 97: Relación entre Tipo de Suelo y (a) log(CAV) Horizontal, (b) log(CAV) Vertical, (c) Espectro de Velocidad Horizontal T=0.2 [s], (d) Espectro de Velocidad Vertical T=0.2 [s], (e) Espectro de Velocidad Horizontal T=1 [s], (f) Espectro de Velocidad Vertical T=1 [s].

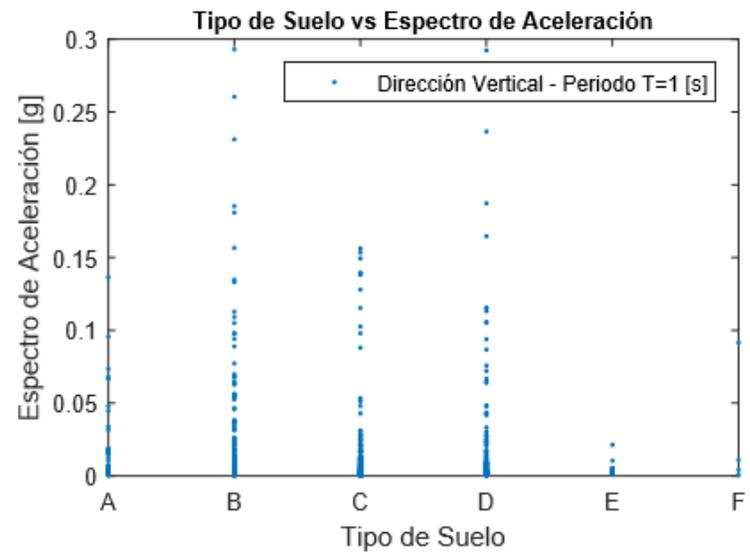
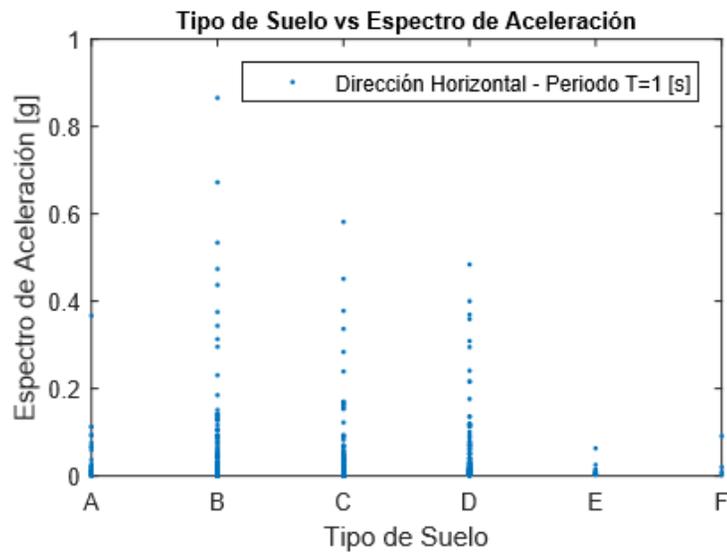
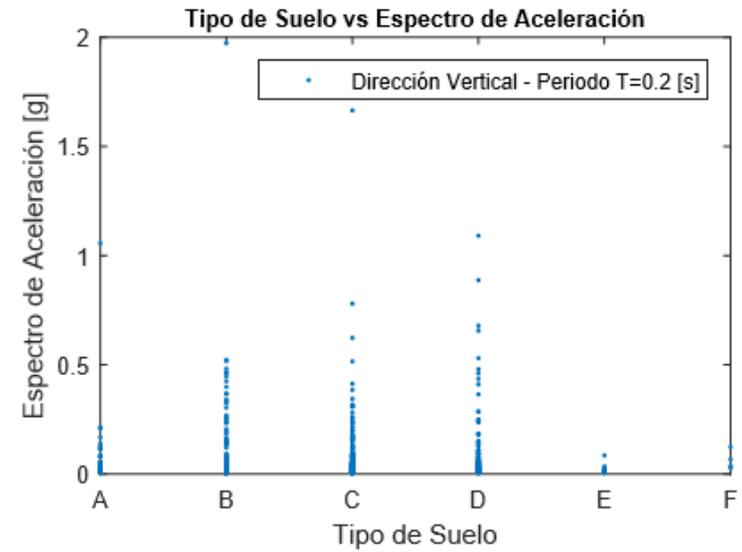
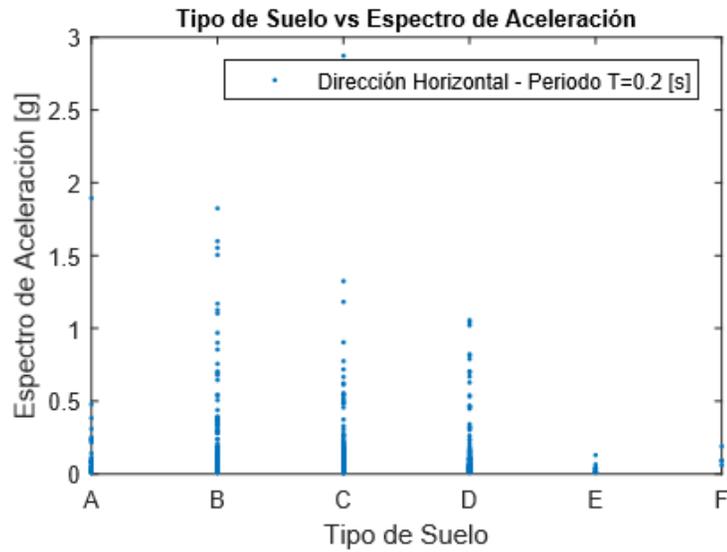


Figura C. 98: Relación entre Tipo de Suelo y (a) Espectro de Aceleración Horizontal $T=0.2$ [s], (b) Espectro de Aceleración Vertical $T=0.2$ [s], (c) Espectro de Aceleración Horizontal $T=1$ [s], (d) Espectro de Aceleración Vertical $T=1$ [s].