



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

EVALUACIÓN DE METODOLOGÍAS DE SEGUIMIENTO MODAL

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA
INGENIERÍA, MENCIÓN INGENIERÍA ESTRUCTURAL, SÍSMICA Y GEOTÉCNICA

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

WLADIMIR MAURICIO GONZÁLEZ VÉLEZ

PROFESOR GUÍA:
RUBÉN BOROSCHEK KRAUSKOPF

MIEMBROS DE LA COMISIÓN:
ENRIQUE LÓPEZ DROGUETT
MARCOS ORCHARD CONCHA

SANTIAGO DE CHILE

2018

RESUMEN DE LA TESIS PARA OPTAR A TÍTULO
DE INGENIERO CIVIL Y GRADO DE MAGÍSTER
EN CIENCIAS DE LA INGENIERÍA, MENCIÓN
INGENIERÍA ESTRUCTURAL, SÍSMICA Y GEO-
TÉCNICA

POR: Wladimir Mauricio González Vélez

FECHA: 03/07/2018

PROFESOR GUÍA: Rubén Boroschek Krauskopf

EVALUACIÓN DE METODOLOGÍAS DE SEGUIMIENTO MODAL

La identificación operacional en estructuras civiles tienen como fin el monitoreo continuo de estas. Sin embargo, al estar apoyada en algoritmos de identificación que suponen parámetros constantes del sistema a lo largo de toda la ventana de análisis, es incapaz de controlar la evolución del sistema en el tiempo. Las metodologías de seguimiento modal tienen como fin el control automático de la evolución temporal de los modos físicos.

Una parte importante de la variación de los parámetros del sistema puede explicarse a partir de las variables meteorológicas, sobre todo de la temperatura. Esto es especialmente cierto para la frecuencia modal. En cambio, la forma modal puede considerarse constante, al menos ante variaciones moderadas del ambiente. El objetivo de este trabajo es evaluar las metodologías existentes de seguimiento modal y, al mismo tiempo, evaluar la pertinencia de incorporar el efecto de las variables meteorológicas a estas, recogido a través de modelos estadísticos.

La evaluación se hace sobre la identificación del edificio de la Torre Central de la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile, que ha estado siendo monitoreado de manera continua desde el año 2009 a la fecha. También se cuenta con los registros de la estación meteorológica del Departamento de Geofísica de la Universidad de Chile, aledaña a la estructura a estudiar.

Los resultados obtenidos indican que la incorporación de modelos de frecuencia modal en función de variables meteorológicas al seguimiento modal permite capturar la evolución de los modos físicos, sin embargo la metodología puede verse muy afectada por los altos niveles de ruido en los registros o la identificación. También muestran que, si bien la forma modal permanece virtualmente constante, esta no puede ser usada como parámetro exclusivo de seguimiento si la cantidad de sensores es muy baja. Adicionalmente, se comprueba que la temperatura y la dirección de incidencia de los rayos solares son las variables meteorológicas a considerar para predecir con precisión la frecuencia modal.

Tabla de Contenido

1. Introducción	1
1.1. Objetivos	2
1.2. Metodología	2
1.3. Alcances	3
2. Marco Teórico	5
2.1. Identificación Modal	5
2.2. Normalización de la Frecuencia Modal	6
2.2.1. Normalización del Registro y Normalización Modal	6
2.2.2. Normalización orientada a Detección de Daño	7
2.3. Modelos Predictivos de la Frecuencia	9
2.3.1. Regresión Lineal	10
2.3.2. ARX (Modelo Autorregresivo Polinomial)	11
2.3.3. Modelo MLP (Red Neuronal)	13
2.4. Seguimiento Modal	14
2.4.1. AFDD-T	14
2.4.2. Seguimiento Asociativo	17
2.4.3. Seguimiento auxiliado por Modelos Predictivos de la Frecuencia	19
3. Caso de estudio	21
3.1. Edificio de Torre Central	21
3.2. Caracterización de las Variables Meteorológicas	23
3.3. Caracterización de los Registros de Aceleraciones	39

3.3.1.	Ventanas de Tiempo Empleadas	39
3.3.2.	Frecuencia de Muestreo	39
3.3.3.	Registros de Sismos y de Vibración Ambiente	40
3.3.4.	Canales Activos	41
4.	Identificación del Sistema	43
4.1.	Preprocesamiento de los registros	43
4.2.	Identificación mediante Diagramas de Estabilización	43
4.3.	Limpieza Posterior de la Identificación	48
4.3.1.	Limpieza Basada en Amortiguamiento	48
4.3.2.	Limpieza Basada en Frecuencia (DBSCAN)	50
4.3.3.	Limpieza Basada en Frecuencia y Forma Modal (OPTICS)	54
5.	Entrenamiento de Modelos de Frecuencia	60
5.1.	Frecuencias para Entrenamiento de Modelos	60
5.2.	Variables Meteorológicas Significativas	63
5.3.	Regresión Lineal	66
5.4.	Regresión Lineal con Historia de Regresores	71
5.5.	ARX	76
5.6.	MLP	81
6.	AFDD-T	87
6.1.	AFDD-T para el Caso de Estudio	87
6.2.	Seguimiento para el Período Anterior al Terremoto	88
6.3.	Seguimiento para el Período Posterior al Terremoto	91
6.4.	Seguimiento Durante el Terremoto	92
7.	Seguimiento Modal Auxiliado por Modelos de Frecuencia	94
7.1.	Condiciones para el Seguimiento Modal	94
7.2.	Metodología de Seguimiento para el Período Posterior al Terremoto	95
7.2.1.	Métrica del Espacio	95

7.2.2. Selección de Modos de Referencia	96
7.3. Seguimiento Modal con Modelo Lineal	97
7.4. Seguimiento Modal con Modelo Lineal con Historia de Regresores	99
7.5. Seguimiento Modal con Modelo ARX	100
7.6. Seguimiento Modal con Modelo MLP	102
7.7. Comportamiento del Amortiguamiento Modal	103
7.8. Comportamiento de la Forma Modal	109
8. Comentarios Finales	120
Bibliografía	124
A. Limpieza Manual de Canales	Anexo A - 1
B. Parámetros para <i>Clustering</i> por OPTICS de Identificación	Anexo B - 1
C. Parámetros para <i>Clustering</i> por DBSCAN en Preprocesamiento de Datos de Entrenamiento de Modelos	Anexo C - 1

Índice de tablas

3.1. Características de los acelerómetros.	22
3.2. Características de los sensores de la estación meteorológica.	24
3.3. Variables meteorológicas medidas por la estación y las unidades usadas.	25
3.4. Intervalos de tiempo superiores a una semana sin mediciones.	39
4.1. Síntesis de criterios fuertes para la limpieza preliminar de polos.	44
4.2. Síntesis de criterios débiles para la limpieza preliminar de polos.	44
4.3. Caracterización preliminar de modos físicos.	47
4.4. Síntesis de etapas de la limpieza posterior de la identificación.	48
7.1. Selección de modos de referencia para el año 2011.	97
A.1. Descarte Manual de Canales	Anexo A - 1
B.1. Parámetros de OPTICS usados en limpieza de Identificación.	Anexo B - 6
C.1. Parámetros de DBSCAN para preprocesamiento de frecuencias.	Anexo C - 1

Índice de figuras

2.1. Esquema del proceso de normalización.	8
2.2. Esquema de plantillas de vectores de carga para PLS.	10
2.3. Esquema del grafo de un modelo MLP.	13
2.4. Forma de un gráfico de MAC vs. f	15
2.5. Algoritmo de AFDD-T.	16
2.6. Metodología de Seguimiento Modal.	18
2.7. Esquema del seguimiento auxiliado por modelos predictivos de la frecuencia.	19
3.1. Vista satelital de Torre Central.	22
3.2. Ubicación de los acelerómetros.	23
3.3. Registro temporal de la temperatura del aire.	26
3.4. Registro temporal de la humedad relativa.	26
3.5. Registro temporal de la radiación solar.	27
3.6. Registro temporal de la presión barométrica.	27
3.7. Registro temporal de la precipitación.	28
3.8. Registro temporal de la magnitud del viento promedio (vectorial).	28
3.9. Registro temporal de la magnitud del viento promedio (escalar).	29
3.10. Registro temporal de la dirección del viento.	29
3.11. Registro temporal de la desviación estándar de la dirección del viento.	30
3.12. Registro temporal de la magnitud del viento instantánea.	30
3.13. Registro temporal de cénit solar.	31
3.14. Registro temporal de asimut solar.	31

3.15. Histograma de la temperatura del aire.	32
3.16. Histograma de la humedad relativa.	32
3.17. Histograma de la radiación solar.	33
3.18. Histograma de la presión barométrica.	33
3.19. Histograma de la precipitación.	34
3.20. Histograma de la magnitud del viento promedio (vectorial).	34
3.21. Histograma de la magnitud del viento promedio (escalar).	35
3.22. Histograma de la dirección del viento.	35
3.23. Histograma de la desviación estándar de la dirección del viento.	36
3.24. Histograma de la magnitud del viento instantánea.	36
3.25. Histograma del cenit solar.	37
3.26. Histograma del asimut solar.	37
3.27. Correlación de las variables meteorológicas.	38
3.28. Registro temporal de la frecuencia de muestreo de los sensores.	40
3.29. Histograma mensual de sismos.	41
3.30. Canales activos para todas las fechas.	42
4.1. Frecuencias identificadas para todos los registros existentes.	46
4.2. Histograma de frecuencias identificadas.	46
4.3. Frecuencias modales identificadas (limpieza por amortiguamiento).	49
4.4. Histograma de frecuencias identificadas (limpieza por amortiguamiento).	49
4.5. Frecuencias modales identificadas (primera etapa de limpieza por frecuencia).	51
4.6. Histograma de frecuencias identificadas (primera etapa de limpieza por frecuencia).	52
4.7. Frecuencias modales identificadas (segunda etapa de limpieza por frecuencia).	53
4.8. Histograma de frecuencias identificadas (segunda etapa de limpieza por frecuencia).	53
4.9. Parámetro α en distancia modal.	56
4.10. Frecuencias modales identificadas (limpieza por frecuencia y forma modal).	58
4.11. Histograma de frecuencias identificadas (limpieza por frecuencia y forma modal).	58

4.12. Resultado de separación de modos físicos en grupos distintos tras <i>Clustering</i> por OPTICS.	59
4.13. Efecto de uso de parámetros permisivos en <i>Clustering</i> por OPTICS	59
5.1. Selección manual de frecuencias para entrenamiento.	61
5.2. Suavizado por método <i>rlowess</i> de la frecuencia.	62
5.3. Preprocesamiento de frecuencias para entrenamiento.	62
5.4. Efecto de la lluvia en la primera frecuencia modal.	63
5.5. PLS de variables significativas para modelos.	64
5.6. Significancia de la radiación solar en la frecuencia.	65
5.7. Significancia de la dirección del sol en la frecuencia.	66
5.8. Modelo lineal de primera frecuencia modal.	67
5.9. Modelo lineal de segunda frecuencia modal.	67
5.10. Modelo lineal de tercera frecuencia modal.	68
5.11. Modelo lineal de cuarta frecuencia modal.	68
5.12. Modelo lineal de quinta frecuencia modal.	69
5.13. Modelo lineal de sexta frecuencia modal.	69
5.14. Modelo lineal de séptima frecuencia modal.	70
5.15. Modelo lineal de octava frecuencia modal.	70
5.16. Modelo lineal de novena frecuencia modal.	71
5.17. Modelo lineal con historia de regresores de primera frecuencia modal.	72
5.18. Modelo lineal con historia de regresores de segunda frecuencia modal.	72
5.19. Modelo lineal con historia de regresores de tercera frecuencia modal.	73
5.20. Modelo lineal con historia de regresores de cuarta frecuencia modal.	73
5.21. Modelo lineal con historia de regresores de quinta frecuencia modal.	74
5.22. Modelo lineal con historia de regresores de sexta frecuencia modal.	74
5.23. Modelo lineal con historia de regresores de séptima frecuencia modal.	75
5.24. Modelo lineal con historia de regresores de octava frecuencia modal.	75
5.25. Modelo lineal con historia de regresores de novena frecuencia modal.	76
5.26. Modelo ARX de primera frecuencia modal.	77

5.27. Modelo ARX de segunda frecuencia modal.	77
5.28. Modelo ARX de tercera frecuencia modal.	78
5.29. Modelo ARX de cuarta frecuencia modal.	78
5.30. Modelo ARX de quinta frecuencia modal.	79
5.31. Modelo ARX de sexta frecuencia modal.	79
5.32. Modelo ARX de séptima frecuencia modal.	80
5.33. Modelo ARX de octava frecuencia modal.	80
5.34. Modelo ARX de novena frecuencia modal.	81
5.35. Modelo MLP autorregresivo de primera frecuencia modal.	82
5.36. Modelo MLP autorregresivo de segunda frecuencia modal.	83
5.37. Modelo MLP autorregresivo de tercera frecuencia modal.	83
5.38. Modelo MLP autorregresivo de cuarta frecuencia modal.	84
5.39. Modelo MLP autorregresivo de quinta frecuencia modal.	84
5.40. Modelo MLP autorregresivo de sexta frecuencia modal.	85
5.41. Modelo MLP autorregresivo de séptima frecuencia modal.	85
5.42. Modelo MLP autorregresivo de octava frecuencia modal.	86
5.43. Modelo MLP autorregresivo de novena frecuencia modal.	86
6.1. FDD para período previo al terremoto.	88
6.2. AFDD-T para período previo al terremoto.	89
6.3. Gráfico de MAC vs. f contaminado por ruido.	90
6.4. AFDD-T para el primer modo de referencia.	90
6.5. FDD para período posterior a terremoto.	91
6.6. AFDD-T para período posterior al terremoto.	92
6.7. FDD para período que incorpora al terremoto.	92
6.8. AFDD-T para período que incorpora al terremoto.	93
7.1. Uso de modelos para compensar lagunas en mediciones.	95
7.2. Resultado del seguimiento modal auxiliado por modelos lineales de la frecuencia.	98
7.3. Evolución de la frecuencia de referencia obtenida por modelos lineales.	98

7.4. Resultado del seguimiento modal auxiliado por modelos lineales con historia de regresores.	99
7.5. Evolución de la frecuencia de referencia obtenida por modelos lineales con historia de regresores.	100
7.6. Evolución de la frecuencia de referencia obtenida por modelos ARX.	101
7.7. Módulo de parámetros de modelos ARX.	102
7.8. Resultado del seguimiento modal auxiliado por modelos MLP de la frecuencia.	102
7.9. Evolución de la frecuencia de referencia obtenida por modelos MLP.	103
7.10. Evolución del amortiguamiento en el tiempo.	104
7.11. Relación entre el amortiguamiento y la temperatura para el primer modo.	104
7.12. Relación entre el amortiguamiento y la temperatura para el segundo modo.	105
7.13. Relación entre el amortiguamiento y la temperatura para el tercer modo.	105
7.14. Relación entre el amortiguamiento y la temperatura para el cuarto modo.	106
7.15. Relación entre el amortiguamiento y la temperatura para el quinto modo.	106
7.16. Relación entre el amortiguamiento y la temperatura para el sexto modo.	107
7.17. Relación entre el amortiguamiento y la temperatura para el séptimo modo.	107
7.18. Relación entre el amortiguamiento y la temperatura para el octavo modo.	108
7.19. Relación entre el amortiguamiento y la temperatura para el noveno modo.	108
7.20. Evolución temporal de la distancia MAC para el primer modo.	109
7.21. Evolución temporal de la distancia MAC para el segundo modo.	110
7.22. Evolución temporal de la distancia MAC para el tercer modo.	110
7.23. Evolución temporal de la distancia MAC para el cuarto modo.	111
7.24. Evolución temporal de la distancia MAC para el quinto modo.	111
7.25. Evolución temporal de la distancia MAC para el sexto modo.	112
7.26. Evolución temporal de la distancia MAC para el séptimo modo.	112
7.27. Evolución temporal de la distancia MAC para el octavo modo.	113
7.28. Evolución temporal de la distancia MAC para el noveno modo.	113
7.29. Relación entre distancia MAC y temperatura para el primer modo.	114
7.30. Relación entre distancia MAC y temperatura para el segundo modo.	115

7.31. Relación entre distancia MAC y temperatura para el tercer modo.	115
7.32. Relación entre distancia MAC y temperatura para el cuarto modo.	116
7.33. Relación entre distancia MAC y temperatura para el quinto modo.	116
7.34. Relación entre distancia MAC y temperatura para el sexto modo.	117
7.35. Relación entre distancia MAC y temperatura para el séptimo modo.	117
7.36. Relación entre distancia MAC y temperatura para el octavo modo.	118
7.37. Relación entre distancia MAC y temperatura para el noveno modo.	118
A.1. <i>RMS</i> de registros para el año 2010.	Anexo A - 2
A.2. <i>RMS</i> de registros para el año 2011.	Anexo A - 2
A.3. <i>RMS</i> de registros para el año 2012.	Anexo A - 3
A.4. <i>RMS</i> de registros para el año 2013.	Anexo A - 3
A.5. Eliminación manual de canal E4.	Anexo A - 4
A.6. Eliminación manual de canal E5.	Anexo A - 5

Capítulo 1

Introducción

La identificación de un sistema consiste en el ajuste de un modelo a las observaciones y la posterior deducción de las propiedades de interés desde el modelo (con mayor frecuencia se tratará de propiedades modales). La identificación operacional en estructuras civiles tiene como fin su monitoreo continuo, principalmente para alertar tempranamente de daño. Esta ha sido implementada y la automatización del proceso alcanzada preliminarmente. Sin embargo, los algoritmos de identificación más difundidos (FDD y algoritmos SSI) suponen que durante toda la ventana de análisis los parámetros del sistema son constantes, *i.e.* que se está observando el mismo sistema de principio a fin. Por esto, un algoritmo de identificación tradicional por sí mismo no es una herramienta que permita controlar la evolución del sistema en el tiempo. De la necesidad de controlar la evolución temporal, y que esto sea un control automático, surgen las metodologías de seguimiento modal.

Una metodología de seguimiento modal, apoyada de la historia de los modos físicos, halla el nuevo estado de estos a partir de la identificación hecha de una ventana de tiempo. La relación entre la historia y el nuevo estado del modo físico está determinada por una cercanía definida a partir de la frecuencia y la forma modal. Esta última es fundamental para garantizar que la cercanía indique que se tratan del mismo modo físico.

Por otra parte, se ha estudiado la dependencia de la frecuencia modal de las variables meteorológicas, y se ha concluido que, bajo condiciones normales, la temperatura del medio es la principal variable explicativa. Esto significa que variaciones (principalmente) de esta última provocan variaciones en la frecuencia modal que la alejan de la historia de frecuencias del modo físico y, sin embargo, no son indicativas de daño. Una metodología de normalización caracteriza esta dependencia y extrae de la señal toda variación atribuible a las variables meteorológicas, dejando solo aquellas atribuibles a daño.

En este trabajo se busca evaluar las metodologías de seguimiento modal ya existentes e incorporar a estas modelos predictivos de frecuencias, reservados usualmente para normalización. Para ello, se aplican las metodologías conocidas a la identificación del edificio de Torre Central de la Facultad de Ciencias Físicas y Matemáticas (FCFM) de la Universidad de Chile, que

además cuenta en sus cercanías con la estación meteorológica del Departamento de Geofísica de la misma facultad para medir las variables meteorológicas necesarias.

1.1. Objetivos

Objetivo principal

1. Evaluar la efectividad de las distintas metodologías de seguimiento modal escogidas para este trabajo.

Objetivos secundarios

1. Evaluar la estabilidad temporal del amortiguamiento estimado, en miras a verificar si puede ser usado como parámetro para seguimiento modal.
2. Evaluar la precisión en la estimación de la forma modal en el seguimiento modal.
3. Evaluar la pertinencia de incorporar modelos predictivos de la frecuencia al seguimiento modal, dados los distintos modelos escogidos para este proceso.

1.2. Metodología

Inicialmente, se hace una revisión bibliográfica enfocada en determinar el estado actual de las técnicas de seguimiento modal, incluyendo también bibliografía sobre identificación operacional y normalización si es pertinente. En este punto se hace énfasis en los estudios hechos sobre estructuras civiles, en contraste a los probados únicamente con modelos computacionales. Los algoritmos escogidos de la bibliografía, sumados a los propuestos en este trabajo, son evaluados usando el *software* MATLAB.

A continuación, se caracteriza el caso de estudio para este trabajo: el edificio de Torre Central ubicado dentro de la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile, monitoreado de forma continua desde el año 2009 por ocho acelerómetros, capaces de medir tanto movimientos débiles (vibración ambiental) como fuertes (sismos). Para este trabajo, se usarán los registros comprendidos entre los años 2009 a 2016 (incluidos). Adicional a este sistema de monitoreo, se cuenta con una estación meteorológica cercana a la estructura de donde se obtienen las mediciones de las variables meteorológicas.

Se analiza en detalle el trabajo de Fabbrocino y Rainieri sobre seguimiento modal en el espacio de frecuencias [1] y se evalúa la efectividad de este para rastrear modos frente a variaciones ambientales y cambios abruptos del sistema (daño).

Con el algoritmo de interpretación automática de diagramas de estabilización propuesto en [2] y validado en [3], se identifica el sistema para el período de tiempo entre los años 2009 y 2016. De esta identificación se extraen las frecuencias modales necesarias para entrenar los modelos de frecuencia en función de variables meteorológicas (usados como forma de incorporar el efecto del ambiente al seguimiento modal).

Previo al entrenamiento de los modelos, se hace un análisis de las variables meteorológicas para discriminar aquellas significativas para la frecuencia de las despreciables. Luego, son entrenados los siguientes modelos: regresión multiparamétrica lineal (en función de un valor pasado o de una porción de la historia de los regresores), ARX y MLP (red neuronal).

Finalmente, obtenidos los modelos, se prueba la efectividad del seguimiento modal auxiliado por modelos predictivos de frecuencia. La prueba a realizar consiste en rastrear los modos de referencia escogidos por un período determinado de tiempo y contrastarlo con la identificación hecha para ese período, verificando si se logra capturar la evolución temporal de los modos físicos.

1.3. Alcances

Capítulo 2 - Marco Teórico

En este capítulo se expone el marco conceptual y teórico en que se fundamenta este trabajo. Primero, se explica brevemente en qué consiste la identificación de sistemas y se describen las metodologías usadas. Luego, se explican las bases de las metodologías de normalización y se describen los modelos estadísticos escogidos. Por último, se describen las técnicas de seguimiento modal a emplear.

Capítulo 3 - Caso de Estudio

En este capítulo se caracteriza brevemente el edificio de Torre Central, su estructuración y su ubicación. Se caracterizan, además, las variables medidas por la estación meteorológica cercana al edificio. Finalmente, se caracterizan el sistema de monitoreo continuo del edificio, las ventanas de tiempo empleadas en la identificación y la frecuencia de muestreo de los sensores en el intervalo de tiempo de interés. Se muestra también la metodología para diferenciar registros de vibraciones ambientales de registros sísmicos y la metodología para identificar sensores contaminados por ruido en cada ventana de tiempo.

Capítulo 4 - Identificación del Sistema

En este capítulo se caracteriza el procesamiento de los registros previo a la identificación. Se implementa la identificación con el algoritmo SSI-COV y la interpretación automática de diagramas de estabilización validada en [3]. Finalmente, se realiza una limpieza de modos espurios de la identificación en tres etapas: la primera, basada en amortiguamiento; la segunda, exclusivamente en frecuencia; y la tercera, en frecuencia y forma modal.

Capítulo 5 - Entrenamiento de Modelos para Normalización

En este capítulo se seleccionan, desde la identificación, los datos de entrenamiento de los modelos estadísticos y se caracteriza el preprocesamiento hecho de estos. A continuación se selecciona de las variables meteorológicas aquellas con significancia para la frecuencia modal. Luego se muestra el entrenamiento de los modelos escogidos para este trabajo: multiparamétrico lineal (para un valor pasado o para la historia de los regresores), ARX y MLP. Para cada uno se muestra el de mejor ajuste para cada frecuencia modal.

Capítulo 6 - AFDD-T

En este capítulo se prueba el algoritmo de AFDD-T (*Automatic Frequency Domain Decomposition - Tracking*) propuesto en [1]. Este se prueba en tres períodos: antes, durante y después del terremoto del Maule de 2010.

Capítulo 7 - Seguimiento Modal Auxiliado por Normalización

En este capítulo se explica, en detalle, la metodología de seguimiento modal auxiliado por modelos predictivos de la frecuencia, los problemas a enfrentar y la solución escogida para estos. Luego, Se prueba el seguimiento modal auxiliado por los modelos entrenados en el Capítulo 5.

Capítulo 8 - Conclusiones

En este capítulo se entregan las conclusiones sobre los metodologías probadas y los comentarios finales sobre sus particularidades y resultados obtenidos.

Capítulo 2

Marco Teórico

2.1. Identificación Modal

La identificación de un sistema consiste en el ajuste de un modelo a las observaciones y la posterior extracción de las propiedades de interés a partir de los parámetros de este modelo (en lo sucesivo propiedades modales). Un algoritmo de identificación modal toma el registro de la respuesta del sistema -y además, aunque no necesariamente, el registro de la sollicitación ^[1]- y entrega el conjunto de modos identificados. De las distintas clases de algoritmos, para este trabajo son relevantes dos: AFDD-T (***A**utomatic **F**requency **D**omain **D**ecomposition - **T**racking*) [1], basado en el FDD (***F**requency **D**omain **D**ecomposition*) [4]; y SSI-COV (***C**OVariance driven-**S**tochastic **S**ubspace **I**dentification*) [5]. La explicación formal de estos escapa al alcance de este trabajo, pero se entregarán las nociones necesarias.

AFDD-T, al estar basado en FDD, es un algoritmo de identificación de solo salida en espacio de frecuencias. Las crestas en el periodograma de la respuesta están asociadas a los modos físicos del sistema, y son halladas por inspección visual o con un algoritmo de detección automática (*peak-picking*). El algoritmo de AFDD-T elimina la interacción con el usuario en la determinación de las crestas y también en la estimación de las propiedades modales asociadas a estas (específicamente el amortiguamiento modal); aprovechando la identificación hecha en ventanas previas para esto (ver Sección 2.4.1).

SSI-COV, por otro lado, es un algoritmo de identificación de solo salida en espacio de tiempo (espacio estado). Este calibra un modelo ARMA a la respuesta y luego deriva de sus parámetros un estimador de la matriz de estado. De la descomposición en valores singulares de esta matriz se obtienen los parámetros modales.

Ambos algoritmos son de solo salida y suponen que la sollicitación es un ruido blanco de media cero. Ambos, entonces, están pensados para ser usados con registros de vibraciones ambiente.

¹Esta es la distinción entre algoritmos de solo salida (*output-only*) y entrada-salida (*input-output*).

La forma más robusta de identificación es la que se hace usando diagramas de estabilización. Estos interpretan en un rango amplio de órdenes de modelo (de forma sintética, la cantidad de polos del polinomio característico de la matriz de estado) el ajuste del modelo, e identifican aquellos polos cuya ocurrencia es una constante (las columnas estables del diagrama). En este trabajo se usa la interpretación automática de diagramas de estabilización propuesta en [2] y validada en [3] para los polos obtenidos por SSI-COV.

Toda interpretación automática, independiente de qué versión sea usada, puede dividirse en cuatro etapas consecutivas:

1. Eliminación de todos los polos cuyas propiedades indiquen claramente que no se relacionan con un modo estructural.
2. *Clustering*^[2] de los polos a lo largo de los órdenes de modelo.
3. Selección de *Clusters* relevantes por su cardinalidad.
4. Caracterización de cada *Cluster*, a partir de un valor representativo para cada propiedad modal.

Cada etapa requiere de la discrecionalidad del usuario. La primera requiere que defina qué propiedades medir y qué valores son característicos de modos físicos y no de espurios; la segunda, qué algoritmo de *Clustering* usar; la tercera, qué es un *Cluster* relevante; y la cuarta, la forma de obtener el valor representativo del *Cluster*.

2.2. Normalización de la Frecuencia Modal

Las estructuras ven modificadas sus propiedades mecánicas en función de factores ambientales. Varios estudios se han hecho exponiendo el tema y hay consenso en que es la temperatura la principal variable explicativa [6] [7] [8] [9]. Puesto que estas variaciones entorpecen las metodologías de detección de daño y, en el caso de este trabajo, las de seguimiento modal, es que interesa caracterizar este efecto. Si además es descartado este efecto, se estará frente a un proceso de normalización.

2.2.1. Normalización del Registro y Normalización Modal

Aquí corresponde hacer la distinción entre la normalización del registro y la normalización de la frecuencia modal. La diferencia entre ambas es el proceso que se normaliza: en la primera

²Puesto que el objetivo de esta etapa es un agrupamiento “ciego” de polos similares (sin caracterización previa de los conjuntos), la herramienta a usar invariablemente es alguna forma de *Clustering*.

es el registro de la respuesta y en la segunda, la frecuencia modal obtenida de la identificación.

La normalización del registro tiene sentido únicamente si este tiene una tendencia temporal que modelar, como es el caso de registros de deformaciones y desplazamientos. Esto excluye el caso en que la respuesta medida es la aceleración, pues esta es un proceso estacionario de media cero [3], y por ello sin tendencia temporal. Las péndolas en puentes colgantes son, por antonomasia, el sistema monitoreado por su desplazamiento o deformación. En [10] se usa un modelo MLP (ver Sección 2.3.3) para caracterizar el efecto de la temperatura sobre el registro de desplazamiento del tirante de un puente.

La normalización de la frecuencia modal, a la que se refiere en lo sucesivo este trabajo, se aplica sobre la frecuencia modal identificada. Obtenida la serie de tiempo que representa a la frecuencia modal, ambas metodologías de normalización se desarrollan de forma idéntica: se usa la serie temporal para entrenar un modelo [4] y luego con este se extrae el efecto del ambiente. La diferencia sustancial es que no existen sensores que midan frecuencia modal y, por lo tanto, esta serie temporal no se mide, sino que se deduce.

El seguimiento modal es, teóricamente, la manera más correcta de obtener la serie temporal en tiempo real, ya que se evalúa simultáneamente que exista una regularidad tanto en la frecuencia como en la forma modal (ver Sección 2.4). La normalización, entonces, puede asistirse del seguimiento modal para obtener resultados más exactos. En este trabajo se plantea usar los modelos predictivos de frecuencia modal, usados en la normalización para caracterizar el efecto de los factores ambientales, como apoyo al seguimiento modal.

2.2.2. Normalización orientada a Detección de Daño

Cuando se menciona la normalización en técnicas de detección temprana de daño, el propósito de esta es remover del proceso la componente no indicativa de daño, *i.e.* las variaciones producto del ambiente. Después, la detección de daño se hace caracterizando el estado normal del sistema a través de un índice y admitiendo cierta variación de este índice en los estados sucesivos; si el límite es superado, se advertirá la posibilidad de daño ocurrido en ese instante.

Algebraicamente, si y_i es la variable a normalizar (la frecuencia modal del i -ésimo modo), esta se trabaja como la suma de un término \hat{y}_i controlado por los factores ambientales y un término ν_i independiente [Ec. 2.1].

$$y_i(t) = \hat{y}_i(t) + \nu_i(t) \quad (2.1)$$

³Siempre teniendo en cuenta que la sollicitación es un ruido blanco de media cero.

⁴Una excepción es la normalización usando PCA, que no requiere de modelo [11].

\hat{y}_i es construido con un modelo alimentado con datos de entrenamiento (de frecuencia modal y factores ambientales), y luego es usado para llevar y_i a un estado de referencia para cada factor ambiental considerado; *e.g.* si durante la campaña de monitoreo varió la temperatura ambiente, la normalización llevará la frecuencia al estado que habría tenido si la temperatura ambiente hubiera tenido un valor único (la referencia) [Fig. 2.1]. La frecuencia normalizada, matemáticamente, corresponde a la suma del error del modelo $\nu_i(t)$ y la frecuencia asociada al estado de referencia.




Figura 2.1: Esquema del proceso de normalización. Nótese que no necesariamente es removida toda tendencia temporal de la frecuencia modal. Esto es posible solo si se cuenta con toda variable relevante para la frecuencia medida y su relación bien modelada.

La normalización para detección de daño puede realizarse solo si la frecuencia modal y_i es conocida, pues se necesita para determinar ν_i . Entonces, la normalización orientada a detección de daño solo puede plantearse una vez obtenida la serie de tiempo que representa a la frecuencia, *i.e.* después de la etapa de seguimiento modal. Para el seguimiento apoyado en modelos predictivos de la frecuencia, \hat{y}_i es usado para acercar la referencia escogida inicialmente al estado presente del sistema.

2.3. Modelos Predictivos de la Frecuencia

A continuación se describen los modelos predictivos de la frecuencia que se usan en este trabajo para caracterizar la influencia de las variables meteorológicas en esta. Todos estos modelos, al requerir de una muestra de datos para deducir el comportamiento del sistema, caen en la categoría de **modelos estadísticos**.

Para diferenciar aquellas variables de alta significancia para la frecuencia modal de aquellas que no, el enfoque escogido es el de PLS (***P**artial **L**east-squares **R**egression*). El objetivo primario de este método es reducir la cantidad de regresores del modelo, reemplazándolos por un conjunto más pequeño de combinaciones lineales de estos [12]. De esta manera, se evita saturar el modelo con información irrelevante que ralentice su entrenamiento o incluso empeore su ajuste con las observaciones.

PLS entrena sucesivamente modelos lineales de la variable de salida en función de todos los eventuales regresores. Con cada nuevo modelo, la tendencia asociada a este es restada de la salida; y el siguiente modelo, ajustado a la diferencia. La idea base es que con pocas combinaciones lineales se pueda capturar de buena forma el comportamiento del sistema, siendo estos después usados como entrada de cualquiera sea el modelo a entrenar.

En este trabajo, se usa un enfoque ligeramente distinto del anterior. En lugar de reducir el espacio reescribiendo las entradas, lo que se busca es descartar aquellas entradas más insignificantes. Para ello, se consideran únicamente los dos primeros modelos lineales. Cada variable es asociada a dos ponderadores, uno por cada modelo, representados a través del **vector de carga** en el espacio cartesiano [Fig. 2.2]. Si una variable tiene mucha significancia para la salida, el ponderador asociado a esta en uno o ambos modelos lineales debiera ser grande y, por lo tanto, el vector de carga tener un módulo grande. En sentido opuesto, una variable insignificante se expresa con un vector de carga de módulo casi nulo. Finalmente, estas últimas son descartadas.




Figura 2.2: Esquema de plantillas de vectores de carga para PLS. En la plantilla se puede representar la distinción entre variables significantes e insignificantes con una circunferencia centrada en el origen de radio determinado por el usuario.

El criterio escogido difiere del presente en [13], derivado a su vez del que se encuentra en [14], donde se discrimina según el coeficiente de determinación R^2 , tanto entre la salida y las entradas, como entre las entradas. El motivo para preferir el enfoque de PLS es que con este es más sencillo generalizar reglas para descartar variables.

2.3.1. Regresión Lineal

En un Modelo Lineal, la variable dependiente en el instante i -ésimo, y_i , se representa como una combinación lineal de las N variables independientes, $u_{i'n}$, medidas en el mismo instante o uno pasado, más un error ν_i asociado [Ec. 2.2].

$$y_i = \sum_{n=1}^N \beta_n \cdot u_{i'n} + \nu_i \quad (2.2)$$

Con β_n el coeficiente de ajuste del predictor n -ésimo para todos los instantes i [5].

⁵Sin un término constante β_0 sumado al lado derecho de [Ec. 2.2], se asume que la media de y_i es cero. De no serlo, basta con reescribir $y_i \rightarrow y_i - \bar{y}$ para que la expresión siga siendo válida, con \bar{y} la media sobre todos los instantes.

En [15] se prueba la normalización usando Modelos Lineales de frecuencia en función de la temperatura para un puente de arco de hormigón pretensado, concluyendo su efectividad para caracterizar el comportamiento normal de la estructura (aunque esta conclusión solo podría extenderse a casos de estudio similares). Por otro lado, en [13], para el mismo caso de estudio de este trabajo (ver capítulo 3), se compara el Modelo Lineal con Modelos Autorregresivos para concluir su efectividad. Ambos trabajos coinciden en que la ventaja principal de este modelo es su simplicidad.

En [13] se prueban distintos Modelos Lineales de la frecuencia en función de la temperatura ambiente, presión atmosférica, humedad relativa y/o saturación del suelo a 10 m de profundidad; permitiendo además cierto desfase temporal entre variables independientes y la variable dependiente. Como índice comparativo del ajuste, en este trabajo se usa el NMSE (*Normalized Mean Square Error*) [Ec. 2.3].

$$NMSE = 1 - \left(\frac{\|y - \hat{y}\|^2}{\|y - \bar{y}\|^2} \right) \quad (2.3)$$

Con y la variable dependiente medida, \hat{y} la variable dependiente modelada e \bar{y} la media de los valores medidos. El valor $NMSE$ tiene recorrido entre $-\infty$ y 1. Si su valor es cero, entonces el modelo no es mejor que un ajuste lineal sobre la variable dependiente. Entonces, valores menores o iguales a cero acusan que el modelo no está capturando la relación entre variable dependiente e independientes.

2.3.2. ARX (Modelo Autorregresivo Polinomial)

Un modelo AR (*Auto Regressive model*) es uno en que la variable dependiente en el instante i -ésimo y_i se escribe como una combinación lineal de sus observaciones pasadas y_{i-n} más un cierto error asociado ν_i [Ec. 2.4].

$$y_i = \sum_{n=1}^N a_n \cdot y_{i-n} + \nu_i \quad (2.4)$$

En que N y a_n son el **orden autorregresivo** y el **coeficiente autorregresivo** respectivamente. N indica cuántos pasos hacia atrás en el tiempo se consideran relevantes. El supuesto común a todos los modelos autorregresivos es que el error ν_i es de media 0 y que este es independiente de las observaciones pasadas y_{i-n} y los errores pasados ν_{i-n} (correlación nula entre ellos) [16]. En otras palabras:

$$\begin{aligned}
 E[\nu] &= 0 \\
 E[\nu_n \cdot \nu_m] &= E[\nu_n] \cdot E[\nu_m] = 0 \text{ para } n \neq m \\
 E[\nu_n \cdot y_m] &= E[\nu_n] \cdot E[y_m] = 0 \text{ para } n > m
 \end{aligned}$$

en que $E[\cdot]$ es el operador para esperanza.

Que ν_i tenga media cero supone que toda tendencia temporal del proceso estocástico está contenida en la componente determinística $\sum_{n=1}^N a_n \cdot y_{i-n}$ [Ec. 2.4].

Por otro lado, tal como se explica en [17], la nula correlación de ν_i con observaciones pasadas es consecuencia de suponer que el modelo obtenido es el óptimo: si el error actual está correlacionado con observaciones pasadas, ello significa que contiene información relativa al sistema que no fue extraída en el entrenamiento del modelo y, por lo tanto, el modelo no es el óptimo.

La vasta preferencia por usar modelos autorregresivos para el análisis de procesos estocásticos radica en su versatilidad y en la sencillez de la calibración [6] [18] [16]. Además, son de los pocos modelos que tienen una solución cerrada (analítica), obtenida por ajuste de mínimos cuadrados [19]. Esto último implica que la solución no es aproximada por algún método iterativo, aliviando el tiempo dedicado a la calibración.

Un modelo ARX (**A**uto **R**egressive **eX**ogenous model) es un modelo autorregresivo que incorpora además las observaciones pasadas de el(los) predictor(es) $u_{i'-m}$ [6] [Ec. 2.5].

$$y_i = \sum_{n=1}^{N_a} a_n \cdot y_{i-n} + \sum_{m=1}^{N_b} b_m \cdot u_{(i-N_k)-m} + \nu_i \tag{2.5}$$

Donde N_a es el **orden autorregresivo**, N_b el **orden exógeno** y N_k el **retraso temporal** entre la variable objetivo y el predictor [6].

Para determinar el mejor modelo ARX, se debe hallar la terna $\{N_a, N_b, N_k\}$ que mejor ajuste para todos los instantes. En este trabajo, la evaluación del ajuste del modelo, al igual que para los Modelos Lineales, es con el $NMSE$ [Ec. 2.3].

⁶En algunos textos, en lugar de variable exógena, al predictor se le suele llamar variable estacional (*seasonable variable*) y, consistentemente con ello, la sigla incorpora una S al principio en lugar de la X al final: $ARX \rightarrow SAR$.

2.3.3. Modelo MLP (Red Neuronal)

Un modelo ANN (*Artificial Neural Network*) es un sistema computacional basado en un grafo de una o varias entradas y salidas, usado para transformar una señal de entrada en una señal de salida a partir de evaluaciones sencillas hechas en sus nodos internos, llamados **neuronas**. Las neuronas están organizadas en **capas** asociadas a distintas etapas de la evaluación del sistema, dentro de las cuales ningún par de neuronas está conectado, pero sí lo pueden estar con neuronas de otras capas.

Una Red Neuronal no requiere el conocimiento por parte del usuario de la relación exacta entre entradas y salidas; al ser muy flexible es capaz de hallarla por sí misma. También, al estar compuesta de operaciones sencillas, su evaluación es muy rápida (sólo su entrenamiento puede ocupar un tiempo considerable).

Un modelo MLP (*MultiLayer Perceptron*) denota un tipo específico de grafo en que todos los nodos de una capa están conectados a todos los nodos de la siguiente. La definición formal de una Red Neuronal y de un modelo MLP puede encontrarse en [20].

En [10] se usa un modelo MLP para la normalización del registro de desplazamiento del tirante de un puente. El modelo usado en ese trabajo es de una capa oculta con 10 neuronas, con una relación no lineal entre la capa de entrada y la capa oculta, y una relación lineal entre la capa oculta y la de salida [Fig. 2.3] y [Ec. 2.6].

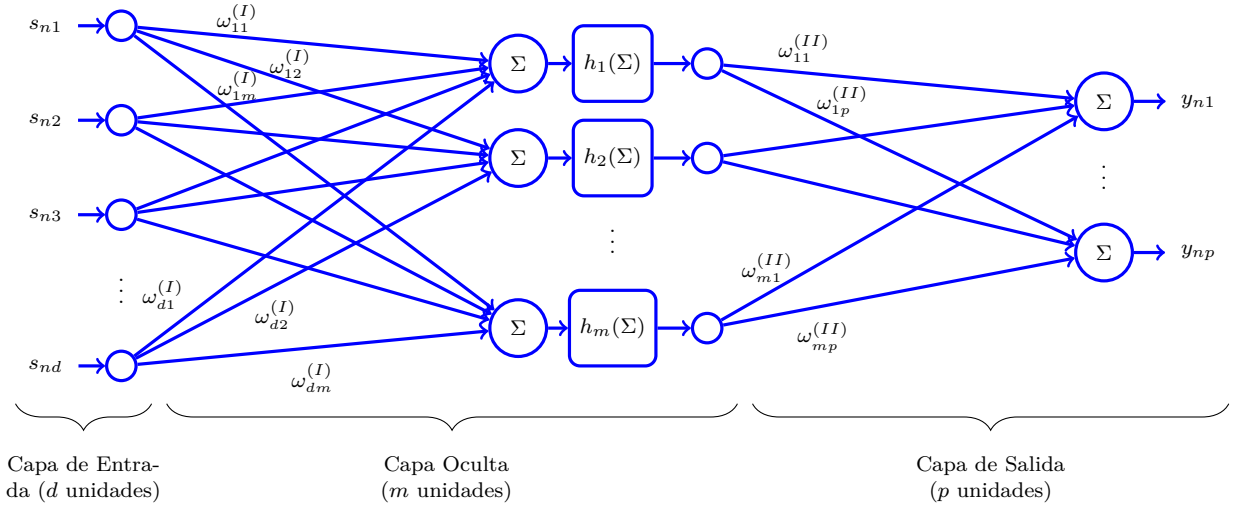


Figura 2.3: Esquema del grafo de un modelo MLP con d entradas, m unidades ocultas y p salidas [10].

$$y_{iv} = \hat{y}_{iv} + \nu_{iv} = \sum_{s=1}^m h \left(\sum_{j=1}^d \omega_{ij} \cdot s_{jk}^{(II)} \right) \cdot s_{sv}^{(III)} + \nu_{iv} \quad (2.6)$$

$i = 1, \dots, n$ y $v = 1, \dots, p$.

En que y_{iv} es la respuesta estructural en el instante i del canal v , \hat{y}_{iv} la estimación dada por la regresión, ν_{iv} el error residual del modelo, $h(\cdot)$ la relación no lineal entre la capa de entrada y la capa oculta -una tangente hiperbólica-, $\omega_{jk}^{(II)}$ y $\omega_{sv}^{(III)}$ los pesos asociados a los arcos en el primer y segundo tramo respectivamente.

En este trabajo se contruye un modelo MLP de la frecuencia modal en función de la historia de las variables meteorológicas, *i.e.* del registro de estas comprendido entre el presente y un tiempo prudente hacia el pasado (especificado en el Capítulo 5); análogo a la componente exógena del modelo ARX (ver Sección 2.3.2).

2.4. Seguimiento Modal

El seguimiento modal se enmarca dentro del monitoreo en tiempo real de estructuras [7]. Su objetivo es capturar la evolución de los modos físicos identificados en el tiempo. Dada una nueva ventana de tiempo que identificar, y además conociendo la historia de los modos físicos de las ventanas previamente identificadas, se obtiene el estado actual de estos modos físicos.

La historia conocida de los modos físicos queda caracterizada por los **modos de referencia**, un conjunto de modos cuyas propiedades tienen valores considerados representativos de estos. La práctica usual es seleccionarlos manualmente tras una campaña preliminar de monitoreo.

2.4.1. AFDD-T

En rigor, un algoritmo de identificación y seguimiento, AFDD-T (***A**utomatic **F**requency **D**omain **D**ecomposition - **T**racking*) fue propuesto por G. Fabbrocino y C. Rainieri en la tesis doctoral del último [21]. Es un algoritmo de identificación en el dominio de frecuencias basado en el algoritmo LEONIDA de identificación automática propuesto en el mismo documento.

AFDD-T [Fig. 2.5], valiéndose de los modos de referencia, encuentra en el periodograma de la respuesta los modos físicos, lo que en el algoritmo de FDD se debe hacer por inspección visual o por algún algoritmo de *peak-picking* automático. Para ello AFDD-T, por cada modo

⁷SHM (***S**tructural **H**ealth **M**onitoring*) es el nombre con que se suele denotar al monitoreo en tiempo real de estructuras civiles, por su claro objetivo orientado a detectar fallas en tiempo real.

de referencia, calcula la distancia MAC (*Modal Assurance Criterion*) [Ec. 2.7] entre la forma modal y el primer vector singular de la matriz de periodograma cruzado de la respuesta en cada frecuencia (nombrado como gráfico de MAC vs. f) [Fig. 2.4].

$$MAC(\phi_i, \phi_j) = \frac{|\phi_i^H \cdot \phi_j|^2}{\|\phi_i\|^2 \cdot \|\phi_j\|^2} \quad (2.7)$$

En que ϕ denota la forma modal y el subíndice hace referencia al modo. ϕ_i^H corresponde al vector hermítico de ϕ_i (el transpuesto conjugado). La distancia MAC indica qué tan similares son dos formas modales: cero indica que son ortogonales; y uno, que son colineales.

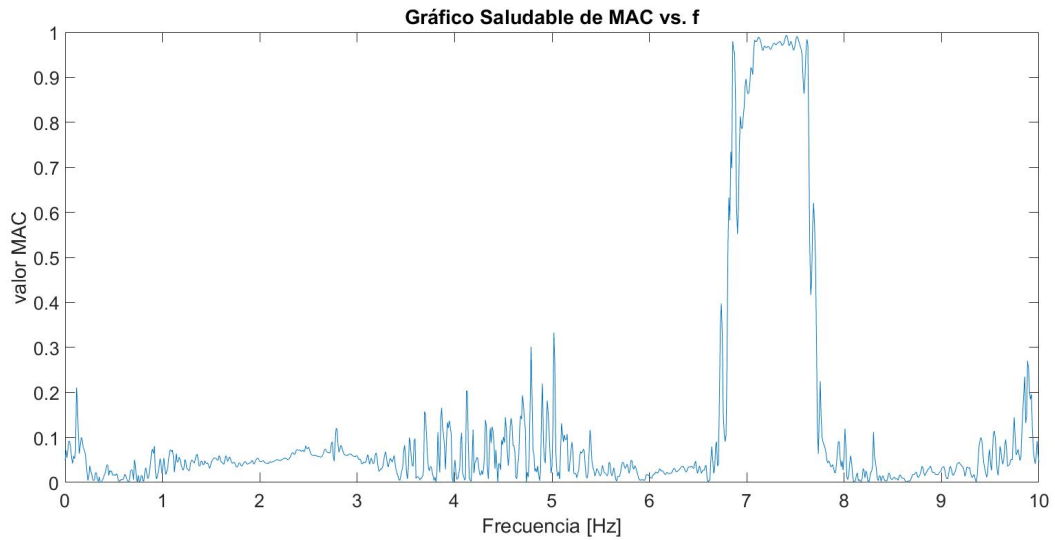


Figura 2.4: Forma típica de un gráfico de MAC vs. f saludable. En el pico de la figura es donde se espera hallar el nuevo estado del modo físico.

Puesto que en una cresta asociada a un modo físico, el primer vector singular representa su forma modal [4], es esperable que la distancia MAC tome valores cercanos a la unidad en la vecindad de la cresta que representa al mismo modo físico que el modo de referencia escogido. Esta es la base del algoritmo de AFDD-T: la meseta del gráfico de MAC vs. f define un filtro con el que se aísla al modo físico, para después obtener las propiedades modales de la siguiente forma:

- la frecuencia modal corresponde a la frecuencia para el máximo primer valor singular en la banda filtrada.
- la forma modal corresponde al primer vector singular asociado a la frecuencia modal obtenida.

- la razón de amortiguamiento se calcula obteniendo la función de respuesta de impulso de la señal filtrada y, por ejemplo, con la fórmula de decremento logarítmico.

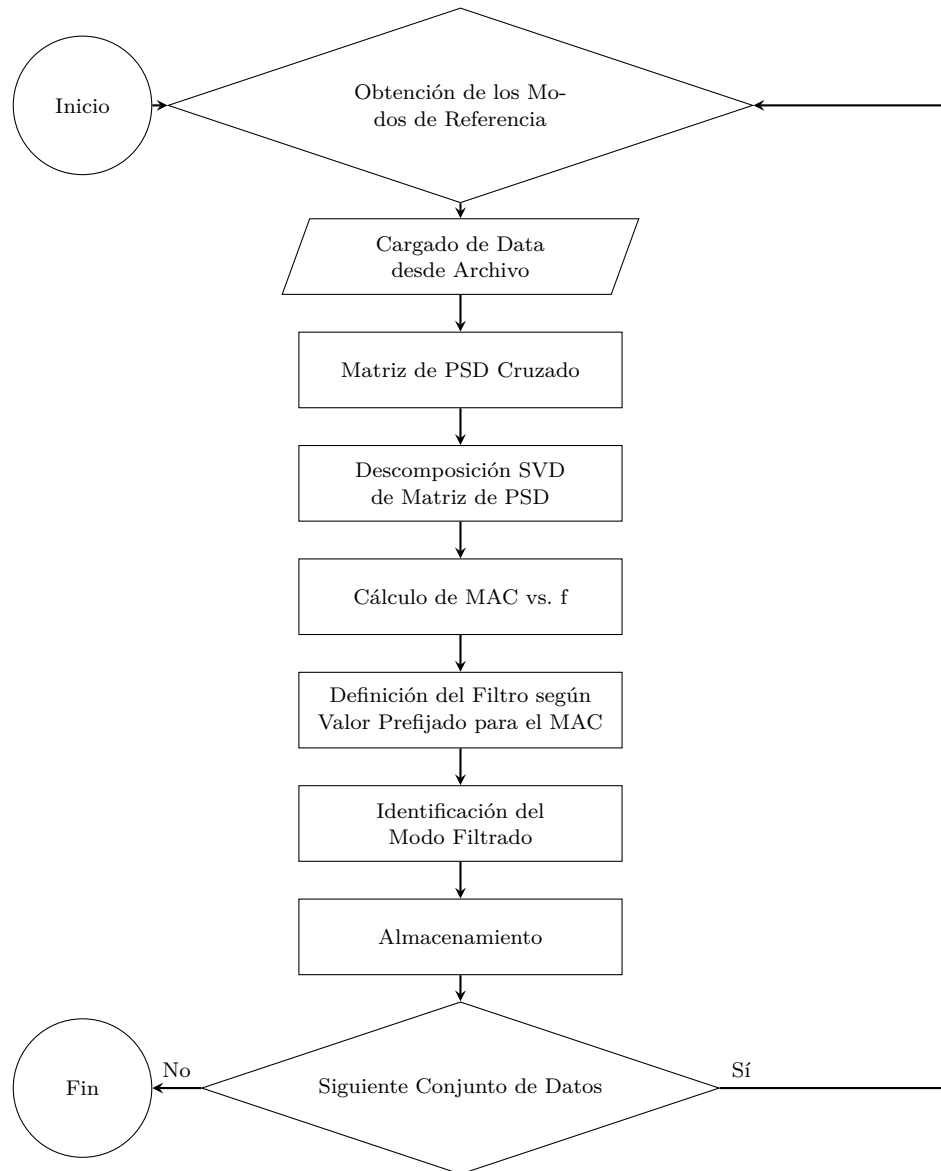


Figura 2.5: Algoritmo de AFDD-T. Este diagrama de flujo es una versión resumida del que se encuentra en [1].

El algoritmo AFDD-T ha sido probado tanto con modelos computacionales como con estructuras civiles (en períodos donde no fueron sometidas a daño, pero sí a sismos) [1], probando ser capaz de identificar modos físicos por un intervalo importante de tiempo.

2.4.2. Seguimiento Asociativo

Por Seguimiento Asociativo se hace referencia a aquel en que los modos de referencia son cotejados con la identificación de cada nueva ventana, obteniendo (siempre que haya sido identificado) el nuevo estado de los modos físicos y, además, limpiando la identificación de modos espurios.

Los distintos criterios que pueden definirse para determinar si un modo corresponde al nuevo estado de un modo físico coinciden en emparejar los modos más cercanos a la referencia, lo que implica haber definido una distancia que formalice la idea de cercanía. Esta distancia es usualmente una combinación lineal de un término que toma en cuenta la distancia en frecuencia y otro que toma en cuenta la distancia en forma modal, *e.g.* la expresión en [Ec. 2.8] derivada de las metodologías de interpretación automática de diagramas de estabilización (ver Sección 2.1).

$$d_{i,i+1} = \frac{f_i - f_{i+1}}{f_i} + 1 - MAC(\vec{\phi}_i, \vec{\phi}_{i+1}) \quad (2.8)$$

La búsqueda del modo más cercano al modo de referencia debe ser en una vecindad que sea lo suficientemente pequeña para que se siga tratando del mismo modo físico. Sin embargo, puesto que existe una variación de la frecuencia modal producto de variables meteorológicas, a lo que hay que sumar variaciones por incertezas de la identificación, el límite a la distancia no puede ser muy estricto o dejará fuera al nuevo estado. Existe, pues, la dificultad de definir un límite que no sea ni tan relajado ni tan restrictivo.

En [22] se elimina la discrecionalidad del usuario en la definición de los límites a la distancia (en el trabajo se define uno para frecuencia y otro para forma modal), transformándolos en límites autoadaptativos, que son ajustados en cada ventana para cada modo, de manera de asegurar que solo un modo identificado por ventana sea catalogado como *cercano* a un modo de referencia [Fig. 2.6].

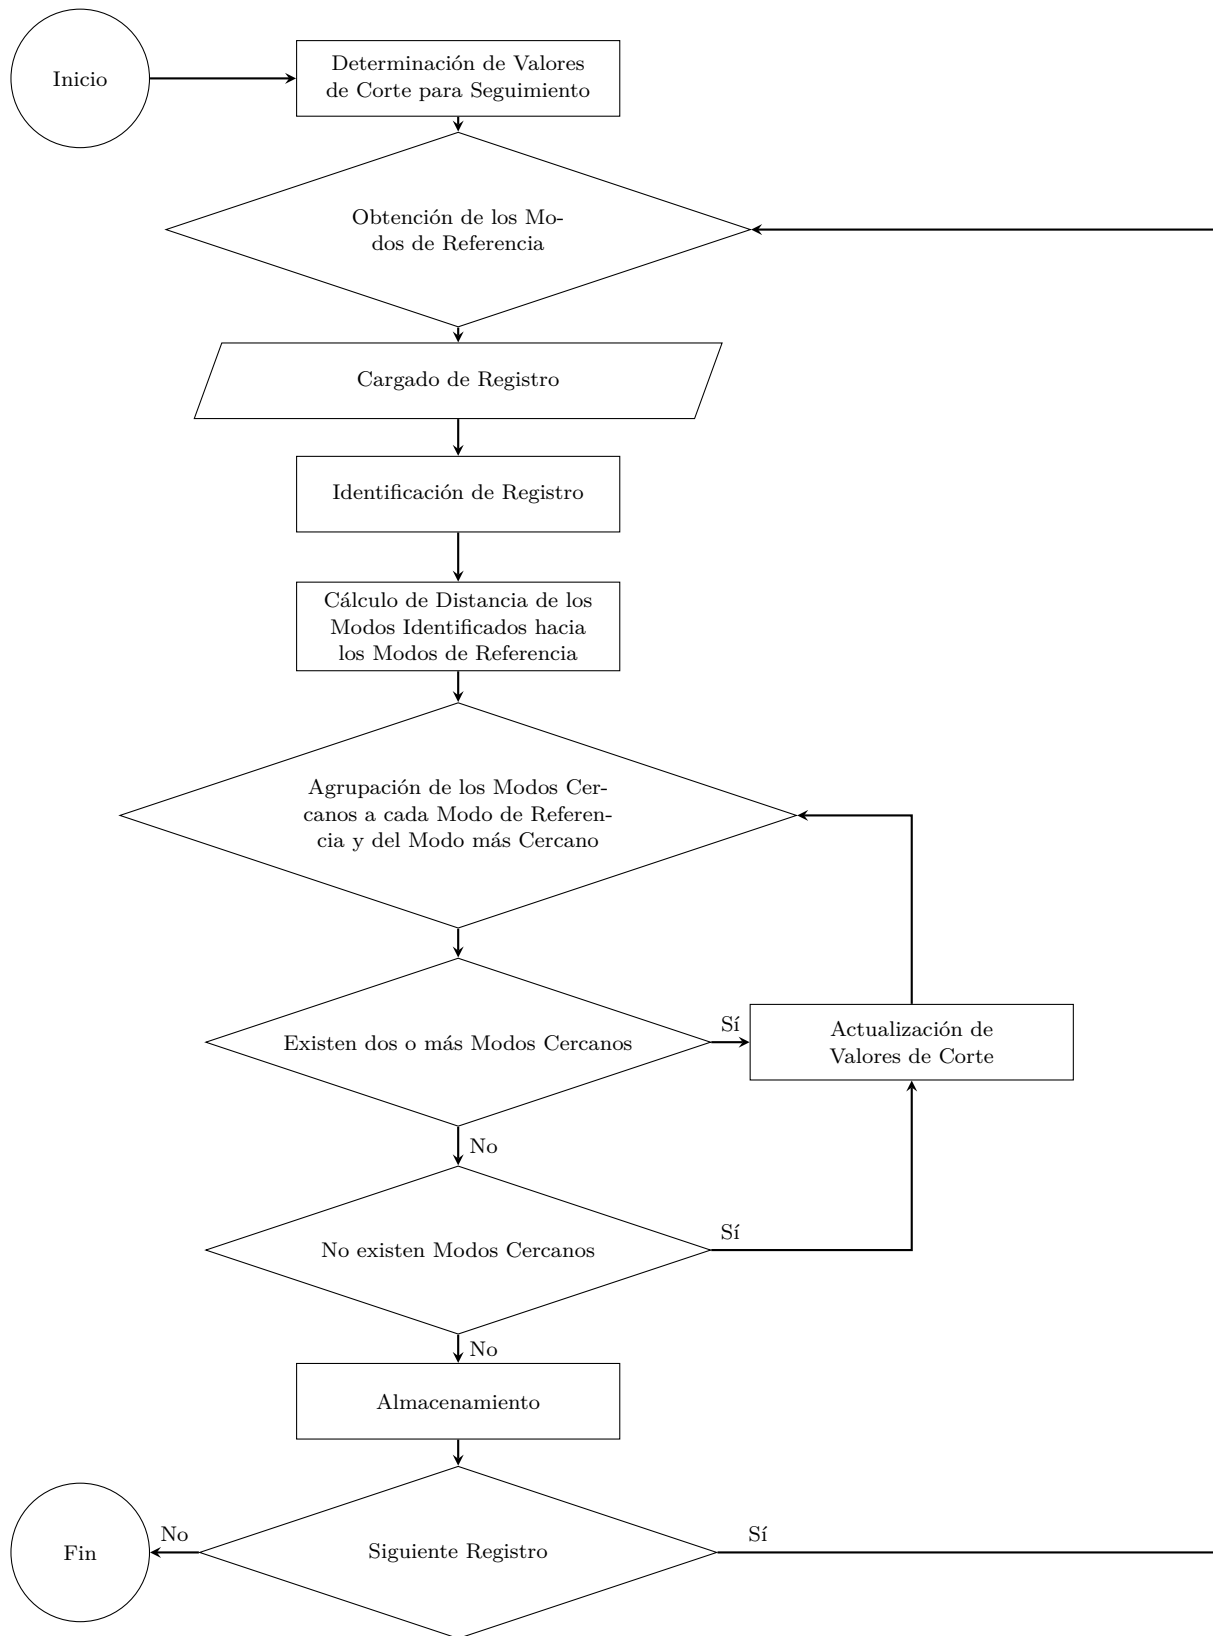


Figura 2.6: Metodología de Seguimiento Modal presente en [22].

Esta metodología, además, es capaz de detectar daño al fijar valores máximos admisibles a la

variación de propiedades modales en cada instante. Sin embargo, supone que en toda ventana los modos fueron identificados, lo que es un supuesto imposible de satisfacer para el caso de estudio escogido (ver Capítulo 3) y, por lo tanto, no es usado en este trabajo.

El seguimiento asociativo como es presentado, en su versión simple y en la propuesta en [22], no es evaluado en este trabajo. Sin embargo, este es la base de la metodología que involucra los modelos predictivos de la frecuencia en el seguimiento, la que será explicada a continuación.

2.4.3. Seguimiento auxiliado por Modelos Predictivos de la Frecuencia

Como ya se ha explicado, la variación de la frecuencia modal por efecto de las variables meteorológicas impide en el seguimiento asociativo el uso de límites estrictos a la distancia en frecuencia. Por ello, en este trabajo se plantea el uso de modelos predictivos de la frecuencia como manera de estimar el nuevo estado de la frecuencia modal y evaluar la distancia respecto a este estimador del nuevo estado, en lugar del estado inicial. En otras palabras, se cambia el concepto de frecuencia de referencia a una frecuencia móvil estimada a partir de variables meteorológicas [Fig. 2.7].

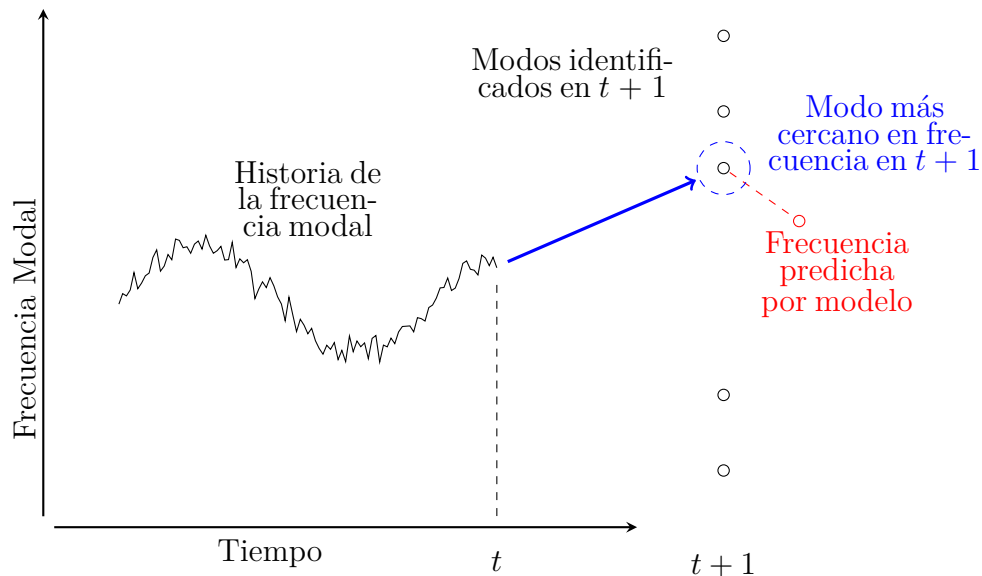


Figura 2.7: Esquema del seguimiento auxiliado por modelos predictivos de la frecuencia. En él se grafica únicamente la relación en frecuencia, pero es necesario tener en cuenta que la cercanía en frecuencia por sí sola no implica que el modo cercano sea el nuevo estado del modo físico.

En el seguimiento modal, el objetivo es obtener el nuevo estado del sistema: la frecuencia, la

forma y el amortiguamiento modal. Al incorporar la modelos predictivos de la frecuencia al proceso se agrega como variable adicional por obtener al error del modelo.

Capítulo 3

Caso de estudio

3.1. Edificio de Torre Central

La estructura a estudiar es la Torre Central de la Facultad de Ciencias Físicas y Matemáticas (FCFM) de la Universidad de Chile (Avenida Almirante Baucher 851, Blanco Encalada 2120, Santiago, Región Metropolitana, Chile) [Fig. 3.1]. Ubicada en el sector central de la FCFM, la estructura fue construida en el año 1962 y actualmente alberga oficinas administrativas y las dependencias del Decanato. El edificio cuenta con ocho pisos y dos subterráneos, y está estructurado con un sistema de muros sismo-resistentes de hormigón armado. El resto de los elementos resistentes corresponden a vigas y columnas.

El edificio, desde el año 2009, está instrumentado con un sistema de medición de vibraciones, conformado por ocho acelerómetros uniaxiales de fuerza balanceada, modelo EpiSensor ES-U2 marca Kinematics, configurados en un rango de 0.25g.

Este sistema de sensores permite el registro en dos rangos: registro de eventos sísmicos y registro de vibraciones ambientales. Estos sensores se encuentran dispuestos de una forma que permite el estudio del movimiento espacial de la estructura: desplazamientos, distorsiones de piso, torsión, etc [Tab. 3.1] [Fig. 3.2]. [14].




Figura 3.1: Vista satelital de Torre Central. En la imagen también se ve la ubicación de la estación meteorológica cercana. [Google Earth Pro V 7.3.0.3832. (12 de febrero de 2006). Santiago, Chile. $33^{\circ}27'27.60''\text{S}$, $70^{\circ}39'44.59''\text{O}$, Altitud de enfoque 314 metros.].

Ubicación	Canal	Sensor	Serial	Dirección	Observaciones
Piso 8	1	EPI 4	346	Oeste-Este	Exterior
	2	EPI 5	345	Norte-Sur	
	3	EPI 6	504	Sur-Norte	
Piso 3	4	EPI 7	1334	Este-Oeste	Exterior
	5	EPI 8	1336	Sur-Norte	
	6	EPI 9	1335	Sur-Norte	
Subterráneo	7	EPI 10	1337	Este-Oeste	
	8	EPI 12	1339	Sur-Norte	

Tabla 3.1: Características de los acelerómetros [14].




Figura 3.2: Ubicación de los acelerómetros [14].

3.2. Caracterización de las Variables Meteorológicas

Se cuenta con una estación meteorológica administrada por el departamento de Geofísica (DGF) de la FCFM, ubicada en el techo del edificio en que se encuentra el departamento de Ingeniería Civil y el de Geofísica, a aproximadamente 40 metros del edificio de la Torre Central [Fig. 3.1].

Un equipo de medición y control *Datalogger Campbell CR10X* guarda las lecturas con un intervalo de registro de 15 minutos -intervalo constante para el período de interés de los años

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

2009 a 2016-. Los sensores incorporados a la estación y sus características se enlistan en [Tab. 3.2]:

Variable	Instrumento	Marca/Modelo
Temperatura del aire (C)	Higro-termómetro de estado sólido	CS-500, Campbell Sci.
Humedad Relativa (%)	Higro-termómetro de estado sólido	CS-500, Campbell Sci.
Radiación solar (W/m^2)	Piranómetro silicon	LI200X, Campbell Sci.
Presión Atmosférica (hPa)	Barómetro estado sólido	PTA-127, Vaisala.
Precipitación (mm)	Pluviómetro de báscula	TE525mm, Texas Instruments
Viento (magnitud en m/s , dirección en grados sex.)	Anemómetro + veleta	03001 Wind Sentry Wind Set, Young.

Tabla 3.2: Características de los sensores de la estación meteorológica (DGF) [13]

El DGF advierte respecto a su estación meteorológica lo siguiente:

1. Esta no es una estación regular climatológica ni sinóptica.
2. La estación no cumple con ninguna norma de observaciones meteorológicas.
3. No cuenta con rutinas de mantención, limpieza y calibración.
4. El aire de Santiago es contaminado, afectando el sensor de radiación solar.

Las variables meteorológicas medidas por la estación se describen en [Tab. 3.3] [1].

¹Datos obtenidos del Grupo de Meteorología, Departamento de Geofísica de la Universidad de Chile.

Variable	Unidades	Observaciones
Temperatura del aire	C	
Humedad relativa	%	
Radiación solar	W/m^2	RS global (directa+difusa)
Presión barométrica	hPa	Se debe sumar 1000 para obtener presión de la estación
Precipitación	mm	Acumulado en los últimos 15 minutos
Magnitud del viento promedio	m/s	Promedio vectorial en los últimos 15 minutos
Magnitud del viento promedio	m/s	Promedio escalar en los últimos 15 minutos
Dirección del viento	(0 – 360)	0 = N, 90 = E, 180 = S, 270 = W
Desv. Std. de dir. del viento	(0 – 360)	
Magnitud del viento instantánea	m/s	Valor máximo de los últimos 15 minutos (gust)

Tabla 3.3: Variables meteorológicas medidas por la estación y las unidades usadas.

Adicionalmente, se agrega como variable meteorológica la dirección desde la que inciden los rayos solares en el edificio. Esta se considera un estimador de las condiciones de borde del sistema. La dirección del sol respecto al edificio se expresa mediante el cénit solar (el ángulo que describe el sol respecto al cénit en un plano vertical) y el asimut solar (el ángulo que describe el sol respecto al norte en un plano horizontal, barrido en sentido horario). El método para calcular ambos está basado exclusivamente en la geometría del movimiento de la tierra entorno al sol [23].

El registro temporal de todas las variables, desde el año 2009 al año 2016, se muestra en [Fig. 3.3] a [Fig.3.14].

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS




Figura 3.3: Registro temporal de la temperatura del aire.

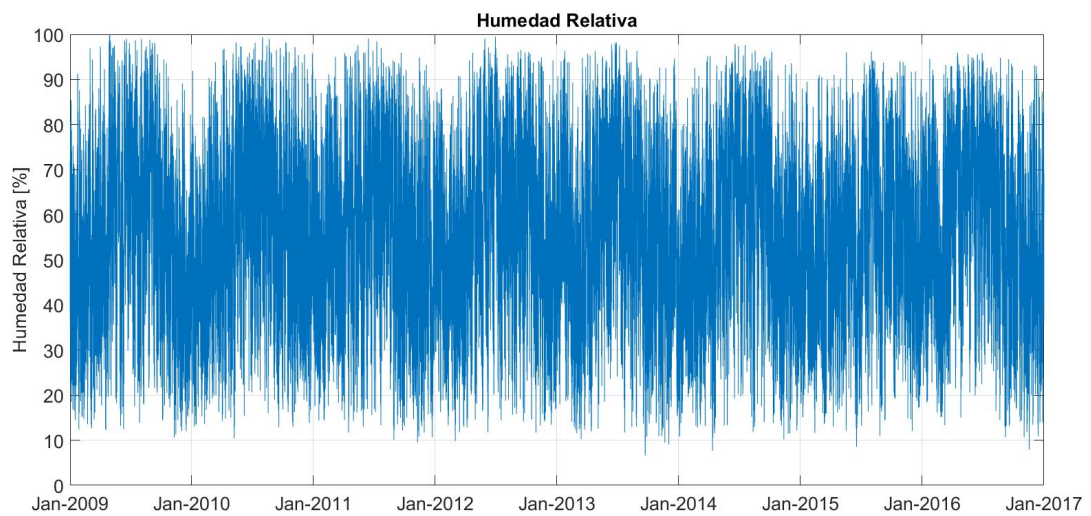


Figura 3.4: Registro temporal de la humedad relativa.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS




Figura 3.5: Registro temporal de la radiación solar.

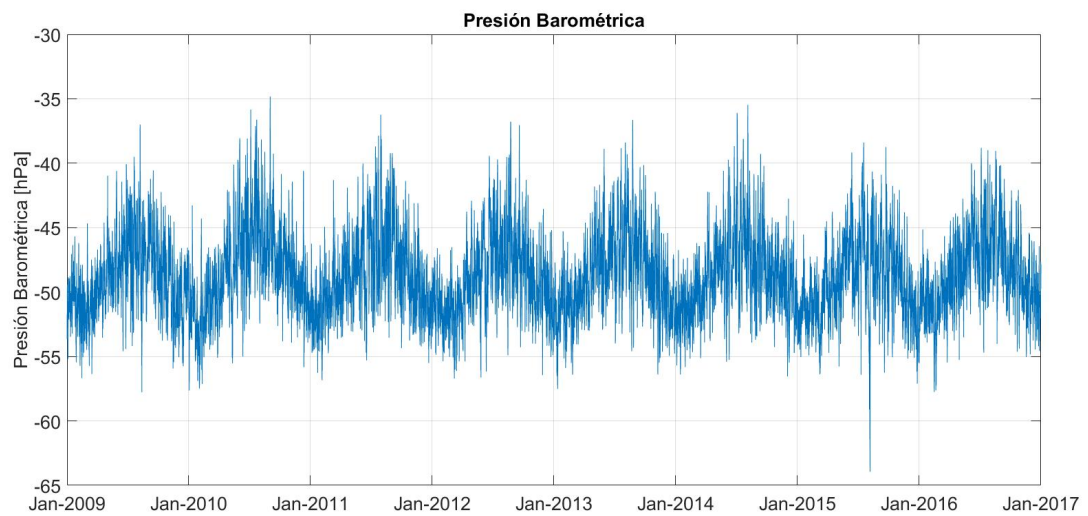


Figura 3.6: Registro temporal de la presión barométrica.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

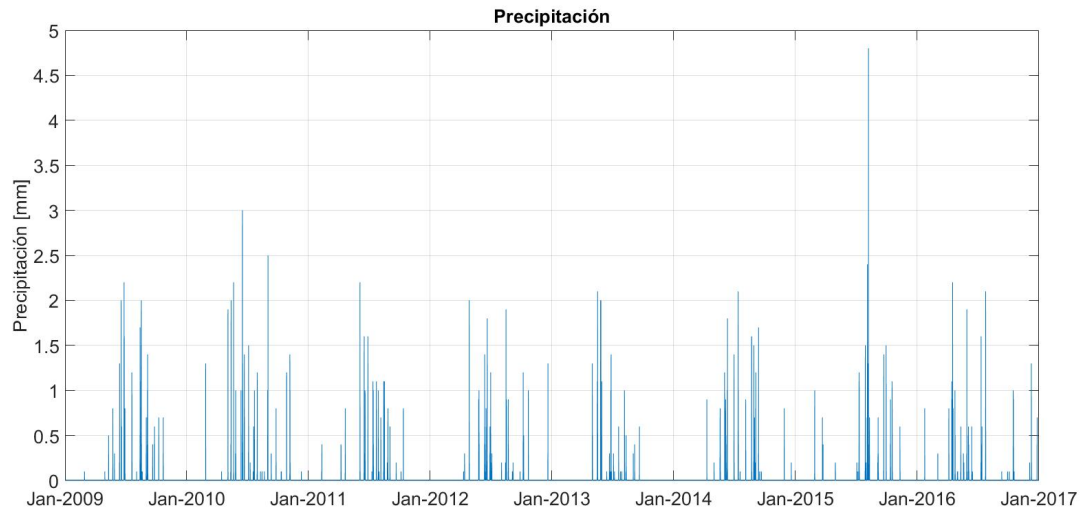


Figura 3.7: Registro temporal de la precipitación.




Figura 3.8: Registro temporal de la magnitud del viento promedio (vectorial).

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS




Figura 3.9: Registro temporal de la magnitud del viento promedio (escalar).

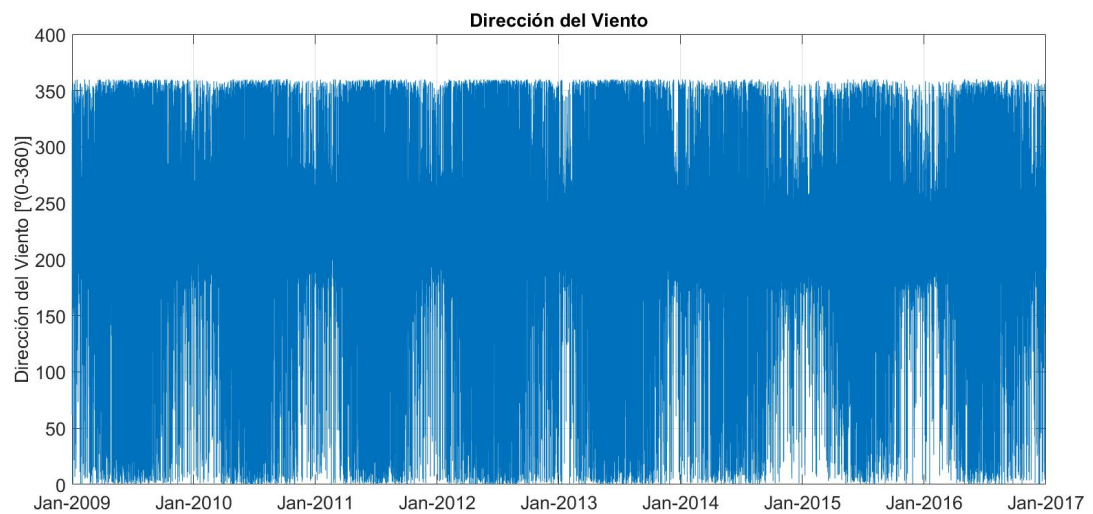


Figura 3.10: Registro temporal de la dirección del viento.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS




Figura 3.11: Registro temporal de la desviación estándar de la dirección del viento.




Figura 3.12: Registro temporal de la magnitud del viento instantánea.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS




Figura 3.13: Registro temporal de cénit solar.

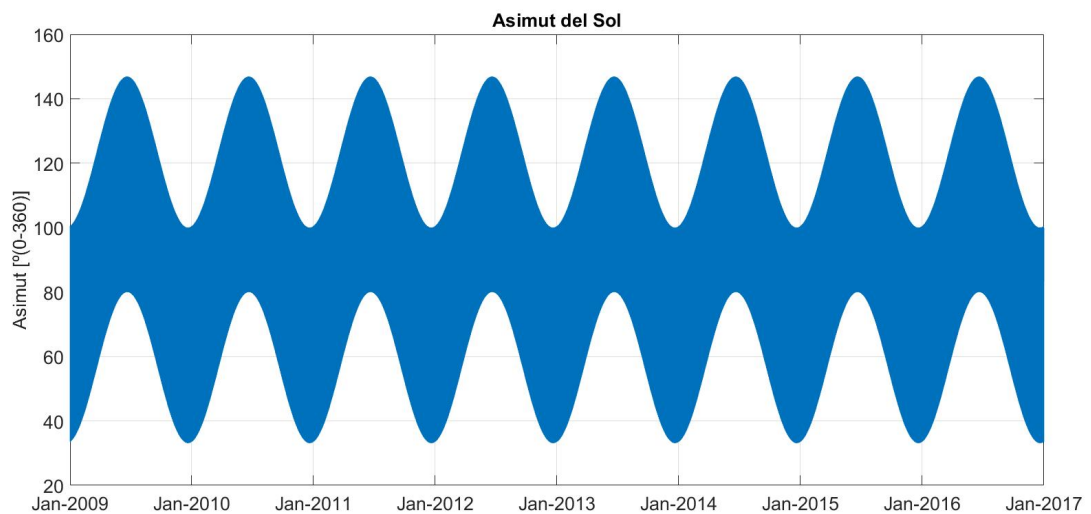


Figura 3.14: Registro temporal de asimut solar.

El histograma de todas las variables, desde el año 2009 al año 2016, se muestra en [Fig. 3.15] a [Fig.3.26].

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

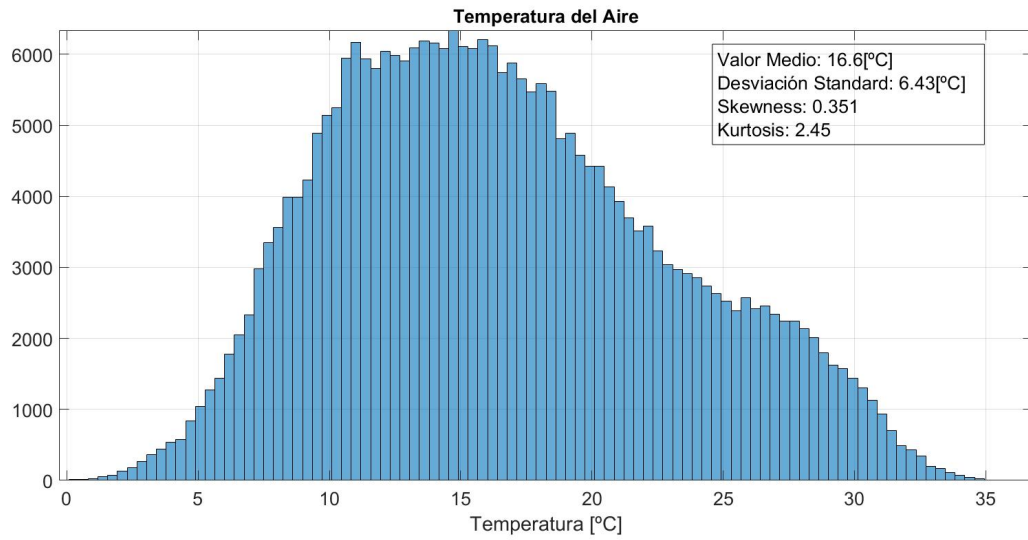


Figura 3.15: Histograma de la temperatura del aire para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

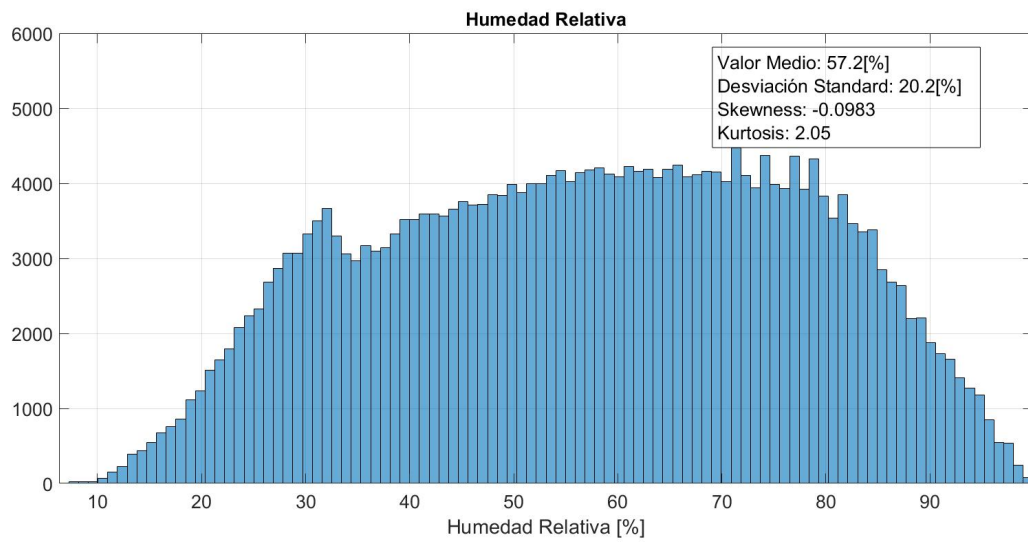


Figura 3.16: Histograma de la humedad relativa para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

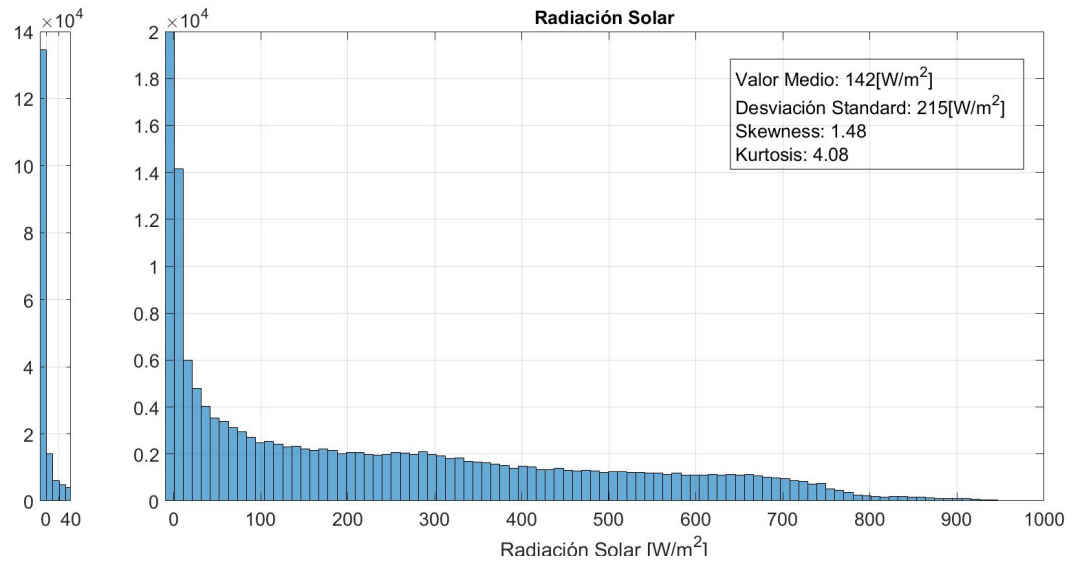


Figura 3.17: Histograma de la radiación solar para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

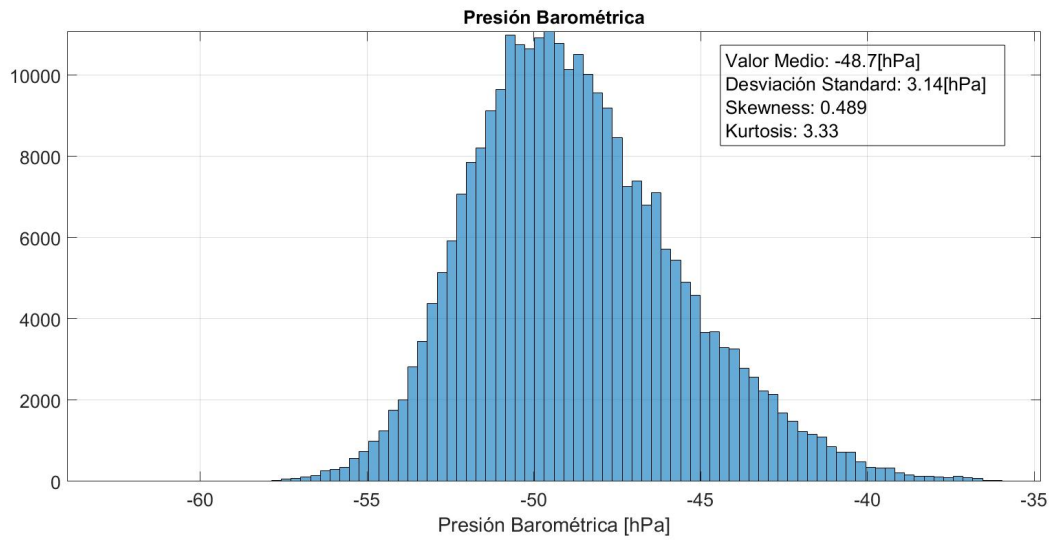


Figura 3.18: Histograma de la presión barométrica para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

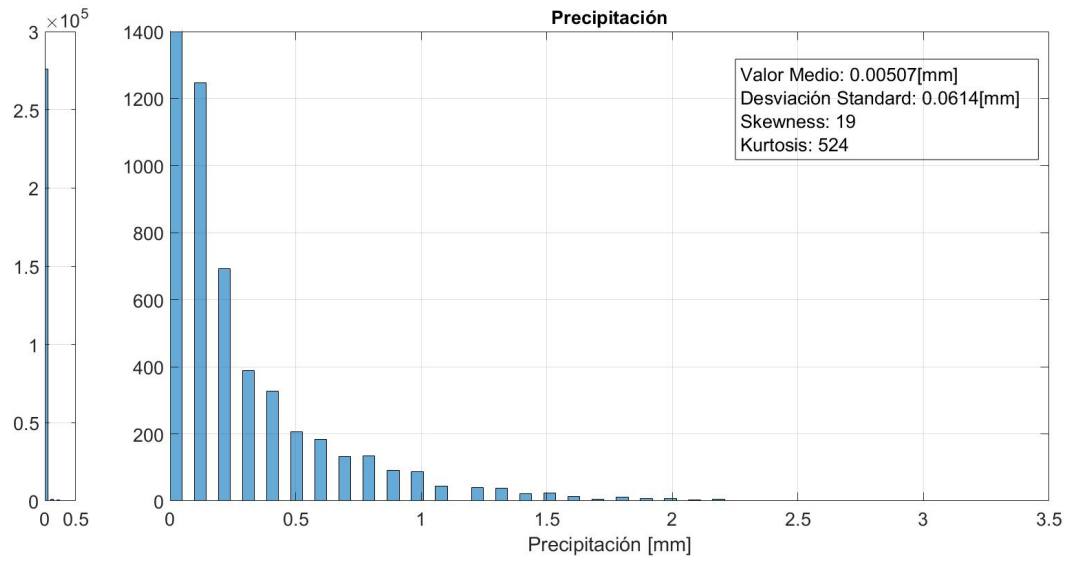


Figura 3.19: Histograma de la precipitación para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

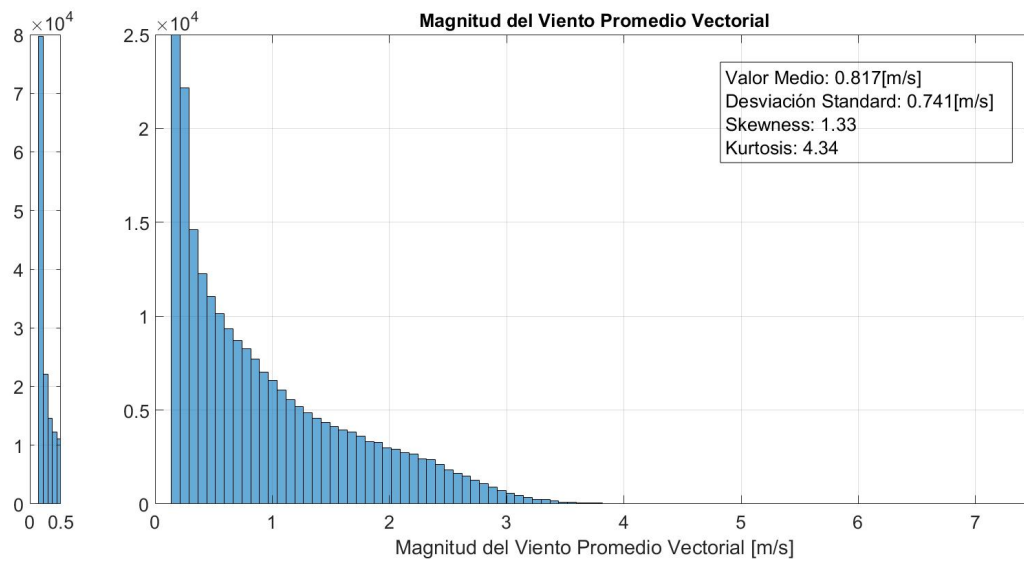


Figura 3.20: Histograma de la magnitud del viento promedio (vectorial) para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

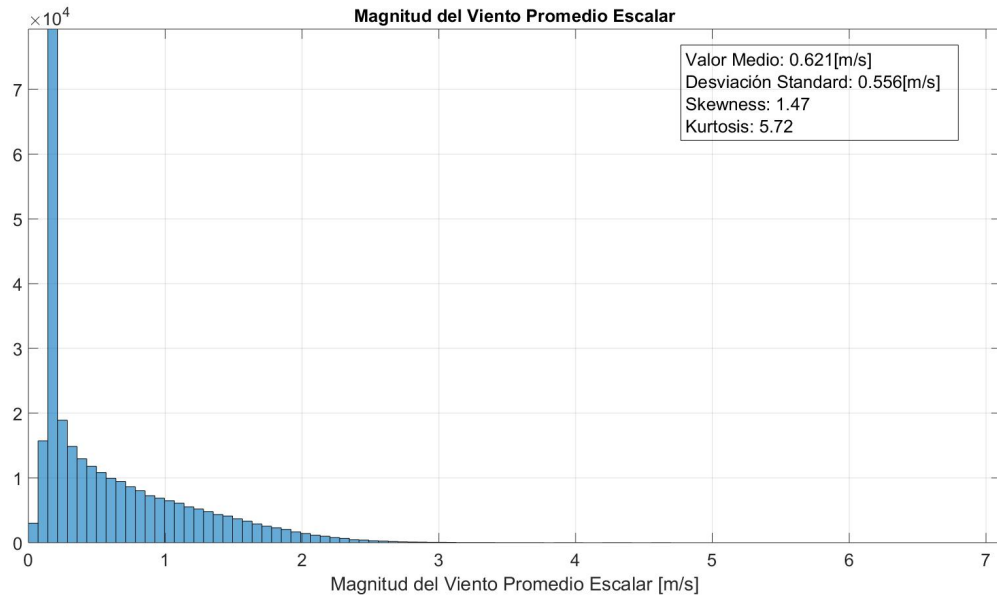


Figura 3.21: Histograma de la magnitud del viento promedio (escalar) para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

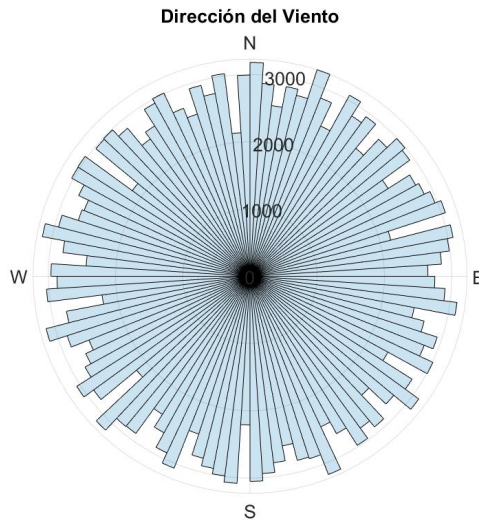


Figura 3.22: Histograma de la dirección del viento para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

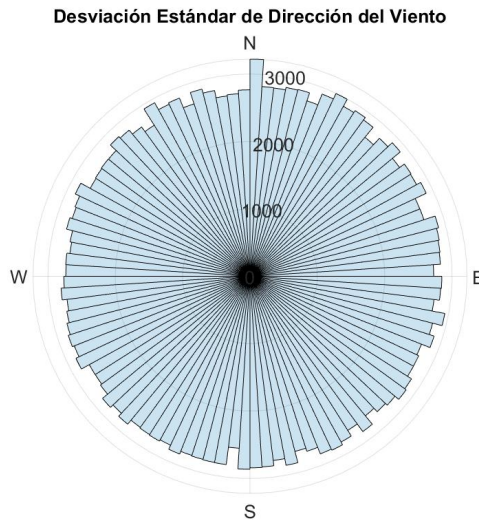


Figura 3.23: Histograma de la desviación estándar de la dirección del viento para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.




Figura 3.24: Histograma de la desviación estándar de la magnitud del viento instantánea para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016. La magnitud de la velocidad del viento sigue una distribución Weibull o Gamma. Los máximos locales del histograma son claramente producto del artefacto instrumental, aunque el origen específico de estos se desconoce.

3.2. CARACTERIZACIÓN DE LAS VARIABLES METEOROLÓGICAS

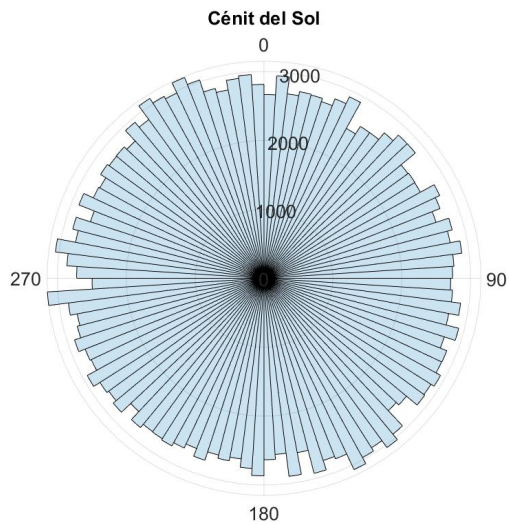


Figura 3.25: Histograma del cenit solar para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.




Figura 3.26: Histograma del asimut solar para el período de tiempo comprendido entre el 1 de enero de 2009 al 31 de diciembre de 2016.

La representación gráfica de la correlación entre todas las variables, desde el año 2009 al año 2016, se muestra en [Fig. 3.27].

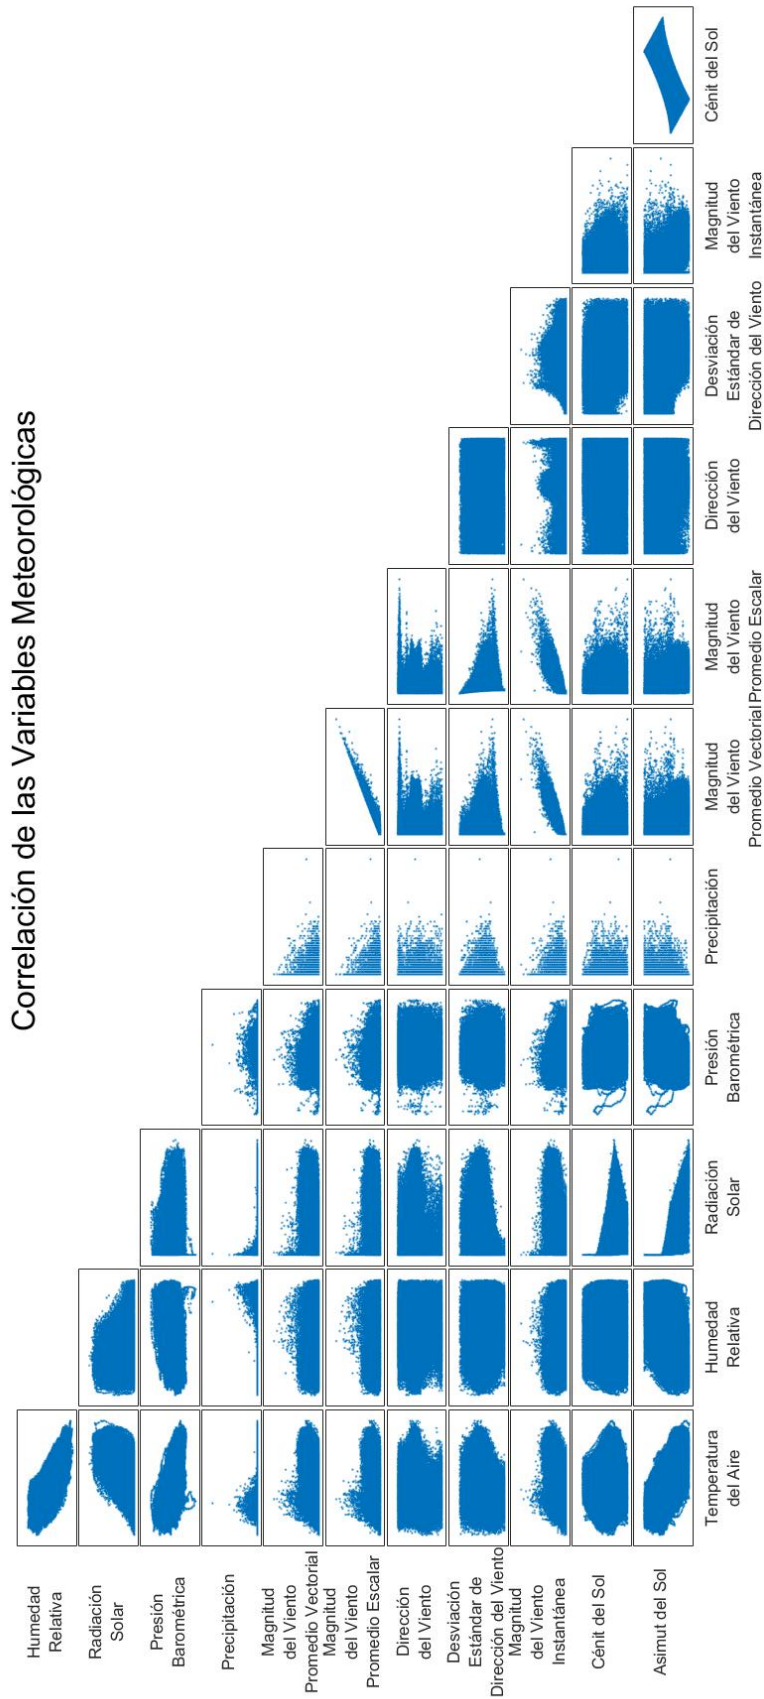


Figura 3.27: Matriz de correlación de todas las variables meteorológicas. Sólo se ha colocado la porción triangular inferior para que la figura sea de fácil entendimiento.

3.3. Caracterización de los Registros de Aceleraciones

3.3.1. Ventanas de Tiempo Empleadas

Para la Identificación se emplearon ventanas de 15 minutos, sin traslapos. Por diversas razones, hubo instantes en los que los equipos no registraron o el registro no quedó bien guardado. Estas son ventanas de tiempo sin mediciones. Además, hubo ventanas de tiempo que se descartaron por tener todos los canales contaminados o por ser más cortas que 3 minutos (caso exclusivo de ventanas previas a un cambio en la frecuencia de muestreo).

En [Tab. 3.4] se indica aquellos intervalos de tiempo sin registros cuya extensión es mayor o igual a una semana (un tiempo menor a este es despreciable).

Inicio	Término	Duración
8 de mayo de 2009 11:30 hrs	20 de mayo de 2009 14:30 hrs	12 días, 3 horas, 0 minutos
31 de enero de 2011 23:45 hrs	22 de marzo de 2011 11:15 hrs	49 días, 11 horas, 29 minutos
11 de marzo de 2012 08:15 hrs	20 de marzo de 2012 00:00 hrs	8 días, 15 horas, 45 minutos
17 de julio de 2015 17:30 hrs	26 de julio de 2015 09:00 hrs	8 días, 15 horas, 30 minutos

Tabla 3.4: Intervalos de tiempo superiores a una semana sin mediciones.

3.3.2. Frecuencia de Muestreo

La frecuencia de muestreo de los equipos fue actualizada ocho veces a lo largo del período de análisis. Desde el año 2013, esta empezó a ser guardada junto a los registros, pero para los años previos es deducida usando los siguientes criterios:

- Que exista una cresta en el periodograma en torno a los 50 Hz (frecuencia de la corriente eléctrica).
- Que el periodograma sea consistente con las frecuencias modales conocidas de la estructura.

La frecuencia de muestreo para todas las fechas se muestra en [Fig.3.28].




Figura 3.28: Registro temporal de la frecuencia de muestreo de los sensores.

3.3.3. Registros de Sismos y de Vibración Ambiente

Se etiqueta como *Sismo* a aquellas ventanas cuyo valor $FC_{10\%}$ [Ec. 3.1] asociado supere 40, valor fijo para todos los canales y fechas ^[2], para al menos un canal por piso.

$$FC_{10\%} = \frac{\max(y)}{RMS_{10\%}(y)} \quad (3.1)$$

Donde $\max(y)$ es el valor máximo del registro de aceleraciones y $RMS_{10\%}(y)$ se obtiene dividiendo el registro en ventanas de un segundo, calculando el valor RMS de cada una, y escogiendo aquel valor de RMS que esté exactamente por sobre el 10% de todas las ventanas.

$RMS_{10\%}(y)$ representa la amplitud normal para el sensor, dependiente entre otras cosas del *hardware*. Normalizar la amplitud máxima $\max(y)$ por este valor es una manera de volver comparativos registros del mismo sensor aún cuando haya habido actualizaciones del equipo entre los dos instantes. Exigir que $FC_{10\%}$ supere 40 para al menos un sensor por piso es necesario para no confundir golpes en los equipos con sismos.

El histograma mensual de ventanas etiquetadas como *Sismo* se muestra en [Fig.3.29].

²Este valor es propio de los registros en el intervalo de interés. Debiera volver a ser definido para cada caso de estudio.




Figura 3.29: Histograma mensual de sismos.

Hay que señalar que la cantidad de ventanas con sismos registrados no es igual a la cantidad de sismos ocurridos, ya que una ventana puede albergar más de uno. Caso ejemplar es Marzo del año 2010, donde las réplicas del terremoto del Maule ocurrido el 27 de Febrero aumentan considerablemente la frecuencia con que un evento sísmico es registrado, hallándose incluso registros con hasta seis eventos sísmicos [24].

También, se indica, el histograma anterior sólo toma en cuenta ventanas sismos registrados en que al menos un canal está activo (no contaminado), lo que también hace diferir este número de la cantidad de sismos ocurridos.

Finalmente, toda ventana que no fue etiquetada como *Sismo* se consideró como registro de vibraciones ambientales.

3.3.4. Canales Activos

La limpieza de canales contaminados se hace de forma automática siempre que sea posible caracterizar su mal comportamiento. Para aquellos intervalos prolongados de tiempo donde, a pesar de superar los criterios automáticos de detección de canales contaminados, sea evidente el mal comportamiento de uno o varios canales (expresado como una cantidad excesiva de ruido en la Identificación), la remoción del canal es manual (ver apéndice A).

Los criterios automáticos de descarte son los siguientes:

- **Para todos los registros:** Se descarta aquellos cuyo periodograma tenga un Factor de

3.3. CARACTERIZACIÓN DE LOS REGISTROS DE ACELERACIONES

Cresta inferior a 4, en que el Factor de Cresta se define como la razón entre el máximo y el valor *RMS* del periodograma. Este es un criterio de buena forma del periodograma. Con él se descartan aquellos canales con un alto nivel de ruido.

- **Para los registros etiquetados como Sismo:** Se descarta aquellos cuyo intensidad de Arias a lo largo del tiempo tenga un ajuste lineal con R^2 (coeficiente de determinación) superior a 0.9 [24].
- **Para los canales basales:** Se descartan estos para todas las ventanas, puesto que en este trabajo se usan algoritmos de Identificación de solo-salida (ver Sección 2.1), y los canales basales representan el movimiento del suelo y no el del sistema.

Los canales activos para todas las fechas se muestran en [Fig 3.30].




Figura 3.30: Canales activos para todas las fechas.

Capítulo 4

Identificación del Sistema

4.1. Preprocesamiento de los registros

Por preprocesamiento se hace referencia al tratamiento de los registros previo a la identificación. Este tuvo los siguientes pasos:

1. Remoción de tendencias provocadas por el ruido eléctrico (remoción directa de tendencias lineales y aplicación de un filtro pasa-altos con límite en los 0.5 Hz).
2. Remuestreo a 20 muestras por segundo.
3. Caracterización del registro como *Sismo* o *Ambiente* (ver Sección 3.3.3).
4. Depuración de canales contaminados (ver Sección 3.3.4).
5. Multiplicación por una ventana Tukey con un 5% del largo total de la ventana igual a partes de coseno a cada extremo del registro. Esto con el propósito de eliminar valores erráticos en el registro dejados por el remuestreo.

4.2. Identificación mediante Diagramas de Estabilización

La metodología de identificación a usar es la propuesta en [2] y validada en [3] para interpretación automática de diagramas de estabilización. El algoritmo de identificación es SSI-COV, tanto para registros de sismos como de vibraciones ambiente. Los órdenes de modelo escogidos para la construcción de diagramas de estabilización son los valores pares entre 50 y 150, incluidos.

Para la primera etapa de limpieza preliminar de polos (ver Sección 2.1), la eliminación de polos espurios se hace según dos tipos de pruebas: criterios fuertes (funciones lógicas) y criterios débiles (funciones con recorrido no limitado a dos valores). La evaluación de los primeros es rápida y sencilla: si no satisface la prueba, el polo es eliminado.

Para los segundos, en cambio, el recorrido de la función debe separarse entre los valores que con seguridad corresponden a modos espurios y aquellos que pueden indicar polos físicos. En [3], para evitar definir un límite rígido entre ambos rangos, se agrupan todos los polos con el algoritmo de *k-means* con $k = 2$ y, de los dos *Clusters* resultantes, se conserva aquel cuya ubicación en el recorrido albergue los valores esperados de un polo físico, *e.g.* si por criterio débil se evalúa cierta propiedad que tiende a valores bajos para polos físicos, entonces tras el agrupamiento por *k-means* se descartará el *Cluster* superior y se conservará el inferior.

En [Tab. 4.1] y [Tab. 4.2] están expuestos los criterios usados para la primera etapa en este trabajo.

Criterios fuertes	
Parámetro	Prueba
Razón de amortiguamiento modal (β)	$0 < \beta < 0.2$
Frecuencia modal (f)	$f < 10Hz$
Valor propio asociado al polo (λ)	debe existir conjugado
Forma modal (ϕ)	debe existir conjugado

Tabla 4.1: Síntesis de criterios fuertes para la limpieza preliminar de polos.

Criterios débiles	
Parámetro	Prueba
$d(\lambda)$	<i>Cluster</i> inferior
$d(MAC)$	<i>Cluster</i> inferior
MPC	<i>Cluster</i> superior
MPD	<i>Cluster</i> inferior

Tabla 4.2: Síntesis de criterios débiles para la limpieza preliminar de polos. En [3], junto con la definición extensiva de estas propiedades, se encuentran otros posibles criterios débiles a usar.

4.2. IDENTIFICACIÓN MEDIANTE DIAGRAMAS DE ESTABILIZACIÓN

$d(\lambda)$ y $d(MAC)$ se definen como la distancia mínima (según la propiedad) entre el modo analizado y los modos asociados al orden de modelo inmediatamente inferior [Ec. 4.1].

$$d(\chi_i^k) = \min_j \left(\frac{|\chi_i^k - \chi_j^{k-1}|}{\max(|\chi_i^k|, |\chi_j^{k-1}|)} \right) \quad (4.1)$$

Donde χ corresponde a la propiedad a evaluar, ya sea λ o la distancia MAC entre un par de modos [Ec. 2.7]. El superíndice indica el orden de modelo asociado al polo; y el subíndice, el polo a analizar.

MPD y MPC son criterios exclusivos para la forma modal, ambos índices del carácter monofásico de esta, *i.e.* qué tan similares son los desfases de todas las componentes del vector. En un sistema cuyo única componente de amortiguamiento es el intrínseco, es esperable que todas sus formas modales tengan un desfase cercano a nulo entre ellas. Este criterio define cuál *Cluster* conservar y cuál descartar.

Para la segunda etapa de *Clustering* de polos, el algoritmo usado en [3], y por lo tanto el usado en este trabajo, es el aglomerativo UPGMA (*Unweighted Pair Group Method with Arithmetic mean*) con la métrica mostrada en [Ec. 4.2].

$$d_{ij} = \frac{|\lambda_i - \lambda_j|}{\max(\lambda_i, \lambda_j)} + 1 - MAC(\phi_i, \phi_j) \quad (4.2)$$

Para la tercera etapa de selección de *Clusters* relevantes, se agrupan los *Clusters* hallados en la etapa anterior, usando el algoritmo de *k-means* con $k = 2$, con métrica la cardinalidad de cada conjunto. Puesto que es de esperarse que un *Cluster* asociado a una columna estable tenga mayor cardinalidad que uno asociado a modos espurios, del resultado de la división se conserva solo el *Cluster* superior.

Para la cuarta etapa de selección del valor representativo, de forma resumida, se asigna como valor representativo al centroide del *Cluster* (en el espacio de frecuencia y amortiguamiento), una vez descartados valores atípicos en este. En [3] se encuentra detallada la explicación formal de esta metodología.

Los resultados de la identificación basada en la metodología descrita anteriormente, para los ocho años de registro, se presenta en [Fig. 4.1] y [Fig. 4.2].

4.2. IDENTIFICACIÓN MEDIANTE DIAGRAMAS DE ESTABILIZACIÓN




Figura 4.1: Frecuencias identificadas para todos los registros existentes.




Figura 4.2: Histograma de frecuencias identificadas.

Se observan resultados consistentes con los presentes en [3] para el período previo a julio del año 2014 (período de análisis de la estructura para ese trabajo). Se detectan diez regiones densas que, por su estabilidad temporal, corresponden a modos físicos [Tab. 4.3]. El terremoto del año 2010 se traduce en un decremento en los valores de todas las frecuencias modales del sistema, consistente con la muy probable degradación de rigidez consecuente (daño al sistema). Esto explica el por qué el décimo (posible) modo sólo es visible después del terremoto, cuando su frecuencia modal ha caído bajo los 10 Hz.

Modo Físico	Frecuencia anterior a Terremoto [Hz]	Frecuencia posterior a Terremoto [Hz]
1	2.2	1.9
2	2.6	2.3
3	3	2.7
4	6.3	5.6
5	7.5	6.8
6	7.9	7.2
7	8.1	7.5
8	9	8.5
9	9.3	8.7
10	-	9.6

Tabla 4.3: Caracterización preliminar de modos físicos. En la tabla se muestra para cada modo el valor aproximado por inspección visual de la frecuencia modal para el período anterior al terremoto del Maule y para el período posterior.

Los modos superiores son identificados con mucha menos frecuencia que los inferiores (como se observa en el histograma de la identificación) y, al mismo tiempo, el error en su caracterización es mayor. No solo la baja cantidad de canales dificulta una caracterización precisa de estos, sino que además son modos poco excitados (también llamados poco energéticos), existiendo además una dificultad física para la metodología. Visualmente, lo anterior se traduce en que, en la historia de la identificación [Fig. 4.2], las regiones densas asociadas a los modos físicos se hacen menos densas a medida que la frecuencia crece. Esta idea es retomada durante la limpieza con algoritmos de *Clustering*.

Puesto que la identificación presenta una cantidad considerable de ruido, mucho mayor que la esperable en una campaña de monitoreo continuo normal, a continuación se hace una limpieza de esta con dos objetivos:

- Eliminar la mayor cantidad posible de ruido.
- Aislar los modos físicos a rastrear, por un período suficiente para entrenar los modelos de estos en función de las variables meteorológicas.

4.3. Limpieza Posterior de la Identificación

La limpieza de la identificación tiene por objetivo eliminar aquellos modos considerados como ruido; modos que si bien son estables según la interpretación hecha del diagrama de estabilización, no son físicos por no poseer propiedades acordes. Para ello, se explotan las siguientes dos propiedades que sólo poseen los modos físicos:

- Una razón de amortiguamiento encasillada en un rango de valores razonable. Específicamente, valores extremadamente bajos del amortiguamiento están asociados a modos producidos por ruido eléctrico.
- Una estabilidad temporal. Si un modo existe solo en un período de tiempo breve, está asociado a ruido.

La limpieza consta de tres etapas consecutivas resumidas a continuación:

Etapas de la limpieza de la identificación		
Limpieza	Basada en	Descripción
Primera	amortiguamiento	cota inferior al amortiguamiento.
Segunda	frecuencia	<i>Clustering</i> por DBSCAN en dos etapas: una para descartar ruido local y la segunda para ruido global.
Tercera	frecuencia y forma modal	<i>Clustering</i> por OPTICS.

Tabla 4.4: Síntesis de etapas de la limpieza posterior de la identificación.

4.3.1. Limpieza Basada en Amortiguamiento

Esta limpieza se limitó a eliminar todo modo cuya razón de amortiguamiento estuviera por debajo de 0.5 %.

4.3. LIMPIEZA POSTERIOR DE LA IDENTIFICACIÓN




Figura 4.3: Frecuencias modales identificadas (limpieza por amortiguamiento).




Figura 4.4: Histograma de frecuencias identificadas (limpieza por amortiguamiento).

En [Fig. 4.3], al comparar con la identificación original [Fig. 4.1], se rescata la efectividad de esta limpieza para remover las cuatro secuencias de modos espurios presentes (a los 3.15 Hz, 6.30 Hz, 7.50 Hz y 9.45 Hz). Tres de estas secuencias ya habían sido caracterizadas como ruido eléctrico en [3], donde se muestra que su razón de amortiguamiento está por debajo de 0.01 %. Los resultados obtenidos por esta limpieza son consistentes con ello.

Como observación adicional, estos modos espurios son estables en un intervalo superior a un año, con una recurrencia en su identificación incluso superior a la de los modos físicos (como se observa en el histograma de la identificación sin procesar [Fig. 4.2]). Un criterio basado en la estabilidad temporal no habría bastado para eliminarlos.

4.3.2. Limpieza Basada en Frecuencia (DBSCAN)

La estabilidad temporal, tanto en frecuencia como en forma modal de una serie, es lo que garantiza que esta represente la evolución de un modo físico. Basándose en esta idea, la herramienta escogida para aislar desde la identificación estas series de tiempo es el *Clustering* basado en densidad.

De entre todos los algoritmos de *Clustering*, el basado en densidad tiene la gran ventaja de no suponer la topología del espacio, lo que permite reconocer aquellos *Clusters* con formas complejas; y además posee **noción de ruido** (es capaz de caracterizar como tales a los puntos no pertenientes a ningún *Cluster*). DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) [25], el algoritmo usado para esta segunda limpieza, tiene la ventaja adicional de ser muy eficiente en memoria.

La segunda limpieza hecha de la identificación, basada exclusivamente en frecuencia, tiene como objetivo eliminar de forma rápida la mayor cantidad posible de ruido (modos espurios), dejando solo el ruido difícil de extraer para la limpieza final, basada en frecuencia y forma modal.

Esta limpieza se lleva a cabo en dos etapas, enfocadas primero a eliminar el ruido reconocible de forma local y luego aquel solo reconocible de forma global. La primera se hace dividiendo el espacio tanto en la dirección del tiempo como en la de frecuencia [Fig. 4.3] con el fin de volver cada división una porción más homogénea que el original. La métrica usada se muestra en [Ec. 4.3].

$$d_{ij} = \begin{cases} \frac{|f_i - f_j|}{\max(f_i, f_j)} & \text{si } |f_i - f_j| < 0.05\text{Hz} \wedge t_i \neq t_j \\ \infty & \text{en caso contrario} \end{cases} \quad (4.3)$$

Donde f indica frecuencia modal; t , la ventana de tiempo a la que pertenece el modo; y el subíndice, el modo al que se refiere. Al automáticamente alejar entre sí los modos pertenecientes a una misma ventana, se busca garantizar que a lo más un modo en cada ventana pertenezca al *Cluster*, lo que guarda significado físico [1].

La distancia en frecuencia normalizada (por el máximo de los dos valores) prueba ser mejor

¹Es necesario precisar que ni DBSCAN ni OPTICS (que se usa durante la tercera limpieza) prohíben que dos modos dentro de una misma ventana queden en un mismo *Cluster*. Siempre puede pensarse que a través de una cadena de puntos denso-alcanzables (*density-reachable* en el original) ambos modos estén denso-conectados (*density-connected*). Sin embargo, al menos para este problema, esto puede considerarse artificioso pues con ninguna combinación de parámetros ocurrió. El ejemplo más claro de un algoritmo de *Clustering* que sí tiene la capacidad de prohibir esto es el aglomerativo de enlace completo.

que la euclidiana para detectar ruido en altas frecuencias. Esto ocurre porque los *Clusters* que representan modos físicos son menos densos a medida que crece la frecuencia, aspecto ya mencionado durante la identificación (ver Sección 4.2). Puesto que esta distancia menosprecia la lejanía en frecuencia si esta ocurre en altas frecuencias (una distancia de 1 % a los 10 Hz es diez veces mayor que a 1 Hz), permite que los modos superiores sean reconocidos como *Clusters* a pesar de ser menos densos.

Por último, el límite absoluto a la frecuencia se encarga de mantener la laxitud, dada por el uso de la distancia normalizada, dentro de límites razonables para un modo físico. Su determinación, así como la de todos los parámetros del algoritmo, es heurística.

El algoritmo de DBSCAN tiene dos parámetros de entrada: *MinPts* y *Eps* (nomenclatura usada en el artículo original). Ambos son usados para caracterizar los **puntos núcleo**; la semilla de lo que el algoritmo reconocerá después como regiones densas. *MinPts* corresponde a la cantidad mínima de objetos necesaria en la vecindad de un punto núcleo para que sea considerado como tal, mientras que *Eps* corresponde al radio de dicha vecindad. Para esta limpieza, los parámetros escogidos son $MinPts = 20$ y $Eps = 0.02$, lo que indica una densidad alta.

Las divisiones de la identificación en la dirección del tiempo son 100 y en la de las frecuencias 10, con una cantidad similar de puntos en cada una para optimizar el uso de memoria.




Figura 4.5: Frecuencias modales identificadas (primera etapa de limpieza por frecuencia).




Figura 4.6: Histograma de frecuencias identificadas (primera etapa de limpieza por frecuencia).

En [Fig. 4.7] se muestra el resultado de la primera etapa de la limpieza por frecuencia. Esta resulta apropiada para eliminar ruido en zonas poco densas y muy alejadas de los modos físicos. También es una característica importante de esta que aquellas zonas que en la dirección de las frecuencias sean muy densas permanezcan casi intactas. Estas regiones reconocibles como ruido solo de forma global son tratadas en la segunda etapa de esta limpieza.

La segunda etapa de la limpieza usa como métrica la distancia euclidiana, con la salvedad que, al igual que en la primera etapa, se fuerza la lejanía entre modos que comparten la misma ventana de tiempo [Ec. 4.4].

$$d_{ij} = \begin{cases} |f_i - f_j| & \text{si } t_i \neq t_j \\ \infty & \text{en caso contrario} \end{cases} \quad (4.4)$$

En esta etapa la única división necesaria del espacio es en el terremoto del año 2010, por la gran diferencia de puntos que existe en los *Clusters* anteriores respecto a los posteriores (del período anterior se cuenta con menos de un año de mediciones, mientras que del posterior se cuenta con casi siete años). Aun así se divide en bandas de frecuencia, pero solo para disminuir el tiempo de procesamiento, nunca truncando los *Clusters* con la división. Los parámetros para DBSCAN son $Eps = 0.05$ (para ambas divisiones), $MinPts = 500$ para el período anterior al terremoto y $MinPts = 2500$ para el posterior.




Figura 4.7: Frecuencias modales identificadas (segunda etapa de limpieza por frecuencia).




Figura 4.8: Histograma de frecuencias identificadas (segunda etapa de limpieza por frecuencia).

Como se ve en [Fig. 4.8], gran parte del ruido alejado de los modos físicos es eliminado. Excepción a esto es la división previa al terremoto del año 2010, donde la baja cantidad de puntos presentes (comparado a la región posterior al terremoto) obliga a mantener $MinPts$ bajo, haciendo que grupos de modos espurios no sean catalogados como ruido [2].

²Al ver el efecto de esta limpieza en el gráfico temporal [Fig. 4.7], y sobre todo en el histograma [Fig. 4.8], puede pensarse que este proceso es equivalente a haber limpiado el histograma de aquellas particiones con pocos elementos. Si bien para negar esto puede argumentarse que la distancia usada no es propiamente una distancia euclidiana, existen motivos más profundos de por qué las dos metodologías no son equivalentes. Primero, en un histograma las divisiones del espacio son determinadas por el usuario; y segundo, cada división tiene una geometría determinada (específicamente la de bola truncada). En DBSCAN ninguna de las anteriores ocurre.

4.3.3. Limpieza Basada en Frecuencia y Forma Modal (OPTICS)

Como se describe en la sección 4.2, la evolución de los modos físicos vista en la identificación [Fig. 4.2] puede verse como una región densa en el tiempo, rodeada de ruido (modos espurios). Esta descripción es análoga a la que se da de una columna estable en algoritmos de interpretación automática de diagramas de estabilización y, por lo mismo, parece apropiado usar la misma herramienta en ambos casos para aislar los modos físicos: algoritmos de *Clustering*. Para la limpieza basada en frecuencia y forma modal, además, se utiliza una métrica similar a la de la metodología mencionada.

La segunda limpieza, basada en frecuencia, tiene por fin únicamente remover de la identificación el ruido fácil de remover, alejado de los modos físicos (ver Sección 4.3.2). Esta tercera limpieza, en cambio, tiene por fin no solo eliminar este ruido cercano, sino también *encapsular* cada modo físico en un *Cluster* independiente de los otros modos, con miras a convertir la identificación en datos de entrenamiento para modelos de frecuencia modal.

OPTICS (*Ordering Points To Identify the Clustering Structure*) es un algoritmo de análisis de *Clusters* basado en DBSCAN y que, a diferencia de este, permite la detección de *Clusters* con densidad variable [26]. Esto se consigue generalizando el concepto de punto núcleo, eliminando el parámetro *Eps* como entrada del algoritmo (ver Sección 4.3.2). El conjunto de modos físicos, como ya se ha indicado, tiene la característica de tener densidades menores mientras más alta sea la frecuencia modal (ver Sección 4.2). Por esto, el algoritmo de OPTICS es idóneo para ser usado en esta etapa.

OPTICS, en lugar de entregar directamente los *Clusters*, entrega un orden particular de puntos (en la forma de *Reachability plot*) que luego es interpretado para extraer los *Clusters*, fijando el usuario qué tan fina debe ser esta interpretación (qué tan baja debe ser la mínima densidad relevante). En este trabajo se usa el algoritmo de **ExtractClusters** para esta etapa, propuesto en el mismo artículo que OPTICS.

La manera que tiene este último algoritmo de detectar *Clusters* es mediante el parámetro ξ , usado para caracterizar aquellas regiones del *Reachability plot* asociadas a *Clusters* (regiones nombradas formalmente como ξ -*Clusters*). Mientras más pequeño sea el valor del parámetro ξ (con 0 como cota inferior a su dominio), más fina será la detección.

Métrica del Espacio

Al definir una métrica, el objetivo es medir la cercanía entre dos modos en distintos instantes de tiempo, como criterio para decidir si agruparlos o no como estados del mismo modo físico.

Esta cercanía debe ser tanto en frecuencia como en forma modal para que el agrupamiento esté correcto. Para poder un algoritmo de *Clustering* para el agrupamiento, se escoge una única métrica que incorpore simultáneamente frecuencia y forma modal [3], modificada de la empleada en la interpretación automática de diagramas de estabilización [Ec. 4.5] (ver Sección 2.4).

$$d_{i,i+1} = \frac{|f_i - f_{i+1}|}{f_i} + (1 - MAC(\phi_i, \phi_{i+1})) \quad (4.5)$$

Donde f indica frecuencia modal, ϕ forma modal y el subíndice el instante de tiempo asociado. Esta expresión es la suma de una distancia en frecuencia d_{ij}^f y una en forma modal d_{ij}^ϕ , ambas normalizadas para ser comparables en magnitud. A continuación, se explican los motivos que justifican la modificación de esta distancia a la usada propiamente para el *Clustering* por OPTICS.

En primer lugar, la expresión en [Ec. 4.5] supone que ambos términos son igualmente influyentes, pero la realidad es más compleja. La interacción entre ambos términos está influida por dos condiciones:

- Cuando se tiene pocos canales (como el caso de estudio) o estos están mal ubicados, la forma modal tiende a ser mal estimada, por lo que la tolerancia a la distancia modal debe crecer con la disminución de canales activos.
- La frecuencia modal varía debido a oscilaciones de las variables meteorológicas, mientras que la forma modal permanece casi intacta. En tal caso, la tolerancia a la distancia en frecuencia debiera ser mayor [4].

Ambos efectos no necesariamente se contrarrestan y no se puede saber *a priori* cuál es el más preponderante. En este trabajo se incorpora a la expresión [Ec. 4.5] un peso α que indica la relevancia de la distancia en forma modal en el total [Ec. 4.6].

$$d_{ij} = (1 - \alpha) \cdot d_{ij}^f + \alpha \cdot d_{ij}^\phi \quad (4.6)$$

³En [22], en cambio, se opta por evaluar dos métricas por separado. El inconveniente de utilizar una única métrica es que existe la posibilidad de que la cercanía en uno solo de los dos parámetros implique el emparejamiento de los modos.

⁴Una vez Normalizada la frecuencia, nuevamente la variación en forma modal supera a la variación en frecuencia, por lo que esta condición solo ocurre por no haber Normalizado primero.

Puesto que mientras más canales activos existan, la forma modal es mejor estimada, es razonable que el ponderador α sea creciente con la cantidad de canales activos. Sin embargo, se debe hacer la precisión de que la magnitud relevante para determinar α es la cantidad de canales activos comunes a las dos ventanas de tiempo donde fueron identificados los dos modos entre los que se calculará la distancia. Así, tras probar varias formas para α , la presente en [Fig. 4.9] probó ser la mejor.

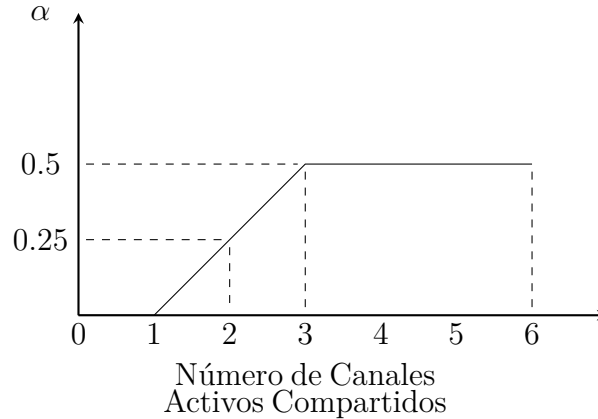


Figura 4.9: Parámetro α en función de la cantidad de canales activos que tengan en común las ventanas donde fueron identificados los dos modos entre los que se está evaluando la distancia.

En segundo lugar, la distancia en frecuencia normalizada en [Ec. 4.6], como se advierte durante la limpieza basada exclusivamente en frecuencia (ver Sección 4.3.2), tienen la característica de menospreciar la lejanía en frecuencia si esta ocurre en altas frecuencias. Esto resulta ventajoso si el algoritmo de *Clustering* es DBSCAN, pues permite detectar densidades distintas valiéndose de la métrica. Sin embargo, como OPTICS es un algoritmo capaz de detectar densidad variable, una distancia como las usadas antes no solo es redundante, sino que entorpece la detección de *Clusters* al volverlos aún menos densos de lo que realmente son (forzando que la detección deba ser muy fina). Además, se distorsiona la relación entre distancias dada por α en [Ec. 4.6], aspecto nuevo debido a la incorporación de la forma modal al análisis.

Por lo anterior, el término de distancia en frecuencia sí se normaliza, pero por el valor constante $\Delta_{\text{máx}}^f$, igual a la mayor distancia en frecuencia de todos los puntos del espacio [Ec. 4.7].

$$d_{ij}^f = \frac{|f_i - f_j|}{\Delta_{\text{máx}}^f} \quad (4.7)$$

Además, al igual que para la limpieza basada exclusivamente en frecuencia, se incorpora un límite absoluto a la frecuencia y el alejamiento automático de modos dentro de una misma ventana de tiempo [Ec. 4.8].

$$d_{ij} = \begin{cases} (1 - \alpha) \cdot \frac{|f_i - f_j|}{\Delta_f^{\text{máx}}} + \alpha \cdot (1 - MAC_{ij}) & \text{si } |f_i - f_j| < 0.05\text{Hz} \wedge t_i \neq t_j \\ \infty & \text{en caso contrario} \end{cases} \quad (4.8)$$

En tercer lugar, la expresión en [Ec. 4.8], al ser simétrica, vuelve la metodología más robusta frente al ordenamiento inicial de los puntos.

El límite absoluto a la frecuencia usado durante la segunda limpieza (ver Sección 4.3.2) se conserva para esta métrica para limitar la relación de cercanía entre modos, previendo, por ejemplo, que modos físicos queden asociados a modos espurios si sus formas modales son similares.

Clustering con OPTICS

Cada modo está contenido en un único *Cluster* y, si bien OPTICS puede trabajar con densidades variables, los modos físicos presentan distinta densidad en las dos direcciones de frecuencia y tiempo (ver Sección 4.2), mientras que la métrica escogida, al ignorar la dimensión temporal, solo permite al algoritmo detectar las distintas densidades en la dirección de frecuencia. La manera de abordar este problema es dividiendo el espacio en la dirección del tiempo, en porciones donde sea correcto asumir que la densidad del *Cluster* en esa dirección es constante [5].

La división temporal es cada 2000 ventanas (aproximadamente 20 días), con una división obligatoria en el terremoto del año 2010, totalizando 121 divisiones; con parámetros diferentes para el *Clustering* de cada partición (ver Apéndice B).

Para el algoritmo de detección automática de *Clusters* ExtractClusters, el parámetro ξ se fija en $1 \cdot 10^{-5}$ para todas las divisiones, indicativo de una detección muy fina.

Finalmente, los resultados de esta limpieza se muestran en [Fig. 4.10] y [Fig. 4.11].

⁵Por supuesto, si la métrica escogida considerara la dimensión temporal, el algoritmo de *Clustering* podría detectar también densidades variables en esa dirección. Sin embargo, aún sería necesario dividir los objetos por gestión de la memoria del computador (OPTICS, a diferencia de DBSCAN, requiere almacenar en la memoria la distancia entre todos los pares posibles de puntos).




Figura 4.10: Frecuencias modales identificadas (limpieza por frecuencia y forma modal).




Figura 4.11: Histograma de frecuencias identificadas (limpieza por frecuencia y forma modal).

Para la mayoría de divisiones puede aislarse cada modo en un *Cluster* distinto [Fig. 4.12]. Sin embargo, existen dos consecuencias de haber hecho un *Clustering* con parámetros permisivos: primero, que aún está presente cierto nivel de ruido junto a cada modo físico; y segundo, que no siempre los modos físicos pueden separarse. El caso extremo de esto último es la incapacidad de separar modos físicos cuyas frecuencias se cruzan en el tiempo, atribuible a la baja cantidad de sensores en la estructura [Fig. 4.13].




Figura 4.12: Resultado de separación de modos físicos en grupos distintos tras *Clustering* por OPTICS.




Figura 4.13: Efecto de uso de parámetros permisivos en *Clustering* por OPTICS. La figura corresponde al *Clustering* hecho entre los días 4 de septiembre de 2010 y 15 de septiembre del mismo año. Como puede verse, la oscilación atribuible a variables meteorológicas provoca en algunos días el entrecruzamiento de los modos seis y siete.

El uso de parámetros permisivos se debe no solo a la variación temporal de la frecuencia por variables meteorológicas, sino también a la mala estimación de la forma modal producto de una baja cantidad de sensores en el sistema. Incluso en condiciones donde la variación por variables meteorológicas puede despreciarse (como cuando se está comparando dos estados sucesivos del mismo modo físico), esta mala estimación puede provocar que varíe de forma importante la forma modal, aspecto que es revisitado durante la evaluación de metodologías de Seguimiento Modal.

Capítulo 5

Entrenamiento de Modelos de Frecuencia

5.1. Frecuencias para Entrenamiento de Modelos

En esta etapa se aísla de la identificación (ver Capítulo 4) las frecuencias modales de los nueve modos físicos escogidos para seguimiento modal. El período escogido es el posterior al terremoto del año 2010, puesto que solo de este se tiene suficientes datos como para construir los modelos.

Para entrenamiento se escoge la ventana de tiempo comprendida entre el 1 de abril del año 2011 y el 1 de abril del año 2012 (un año), para validación se escoge la ventana comprendida entre el 1 de abril del año 2012 y el 1 de abril del año 2013 (un año). En el caso de redes neuronales se escoge además la ventana comprendida entre el 1 de abril del año 2013 y el 1 de abril del año 2014 (un año) para prueba de modelos. El motivo para ignorar el año 2010 para entrenamiento se debe a que el efecto del terremoto en la frecuencia modal se extiende por aproximadamente seis meses posteriores al evento mismo (el tiempo que demora el suelo en recuperar su rigidez natural), siendo este período no representativo del estado normal del sistema. Adicionalmente a esto, ocurre que el sistema de monitoreo falló en el período de enero a abril del año 2011 (ver Sección 3.3.1), siendo imposible entonces incorporar al período inmediatamente posterior al terremoto frecuencias asociadas al verano (necesario para capturar la estacionalidad con el modelo).

De la identificación ya clasificada por OPTICS (ver Sección 4.3.3), se seleccionan manualmente los modos físicos a lo largo de las ventanas de entrenamiento, validación y prueba [Fig. 5.1].




Figura 5.1: Selección manual desde la Identificación de las frecuencias modales para entrenamiento, validación y prueba de los modelos. Los datos de prueba sólo se usan para verificar la red neuronal con información no sesgada. Para todos los otros modelos, como los parámetros se obtienen de una solución analítica del problema, no hay posibilidad de sobrealimentación, por lo que son los datos de validación los que se usan para escoger el óptimo de cada uno.

Como preprocesamiento de las series de tiempo, estas son sometidas a las siguientes etapas de forma secuencial:

1. Eliminación de frecuencias obtenidas en ventanas etiquetadas como *Sismo* (ver Sección 3.3.3).
2. *Clustering* por DBSCAN para eliminar ruido adicional (ver Apéndice C).
3. Suavizado de la curva para terminar de remover el ruido.

La última etapa de suavizado se hace con el algoritmo de regresión local robusta (robusta frente a valores anómalos) ^[1] de MATLAB [Fig 5.3]. El efecto local de este se puede ver en [Fig. 5.2] para la primera frecuencia modal. En esta figura se observa que el suavizado es capaz de omitir valores anómalos sin afectar la tendencia de la curva.

¹función *rlowess* en MATLAB.




Figura 5.2: Suavizado por método *rlowess* de la frecuencia. En azul se muestra la serie de tiempo obtenida de la limpieza con DBSCAN, mientras que en rojo se muestra la serie de tiempo posterior al suavizado.




Figura 5.3: Preprocesamiento de frecuencias modales para entrenamiento, validación y prueba de los modelos. Nótese que algunas frecuencias tienen ventanas de tiempo de tamaño considerable sin resultados.

Finalmente, es necesario mencionar que los tramos de frecuencia influidos por lluvia, al igual que el ruido y los puntos asociados a sismos, alteran el entrenamiento de los modelos. Esto por dos motivos: primero, estos puntos son una fracción muy pequeña del total (no representan el comportamiento normal del sistema); y segundo, el efecto de la lluvia (cuando ocurre) es dominante sobre el de todas las otras variables meteorológicas, afectando la significancia de todas las variables. Sobre lo último, en [27] se muestra que el fenómeno de saturación del suelo por capilaridad (consecuencia de la lluvia) rigidiza el sistema y esto se expresa como

un incremento abrupto de la frecuencia modal [Fig. 5.4]. Entonces, el efecto de la lluvia es una modificación de las condiciones de borde del sistema.




Figura 5.4: Efecto de la lluvia en la primera frecuencia modal. La precipitación acumulada mostrada se calcula acumulando la precipitación medida y separando eventos si entre ellos no ha llovido por un día o más. El evento mostrado corresponde a la primera lluvia del año 2012, lo que explica su marcado efecto. Nótese que en un intervalo muy pequeño de tiempo la frecuencia tiene un gran incremento que demora algunos días en atenuarse.

A pesar de lo anterior, no se eliminan estos puntos pues, como ya se ha mencionado, son despreciables y no debieran afectar mayormente el desempeño de los modelos.

5.2. Variables Meteorológicas Significativas

La significancia de las variables meteorológicas se determina mediante el enfoque de PLS (ver Sección 2.3). En [Fig. 5.5] se muestra la plantilla de vectores de carga para la primera frecuencia modal como variable objetivo (puesto que la influencia de las variables meteorológicas sobre las demás frecuencias es similar, solo se muestra la plantilla para la primera frecuencia). Para este análisis, las variables se han normalizado para evitar que las distintas dimensiones en que son expresadas afecten las conclusiones. Esta normalización consiste en sustraer la media y dividir por el máximo valor absoluto (tanto para variables meteorológicas como frecuencia).

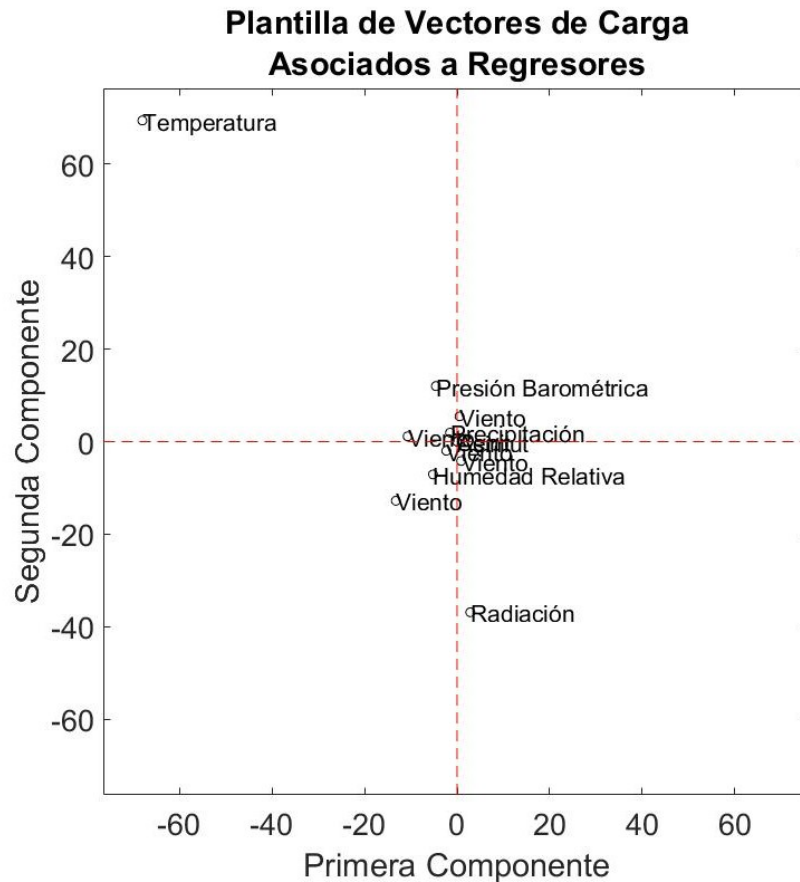


Figura 5.5: Plantilla de vectores de carga asociados a las variables meteorológicas. Las cinco variables asociadas al viento, como son irrelevantes, solo se etiquetan como "Viento".

De este análisis, la temperatura del aire es la variable que tiene una mayor significancia, mismo resultado obtenido en trabajos similares (ver Sección 2.2). El resto de las variables aparecen muy cercanas al origen de la plantilla, acusando poca significancia.

Eventualmente, la radiación solar también puede ser considerada como relevante, aunque mucho menos que la temperatura. Para verificar esto, se entrenan dos modelos lineales de la primera frecuencia modal: el primero en función exclusivamente de la temperatura del aire; y el segundo en función de la temperatura y la radiación solar [Fig. 5.6]. De la comparación de ambos, se concluye que la influencia de la radiación solar es mínima y, por lo tanto, puede despreciarse sin incurrir en errores importantes.

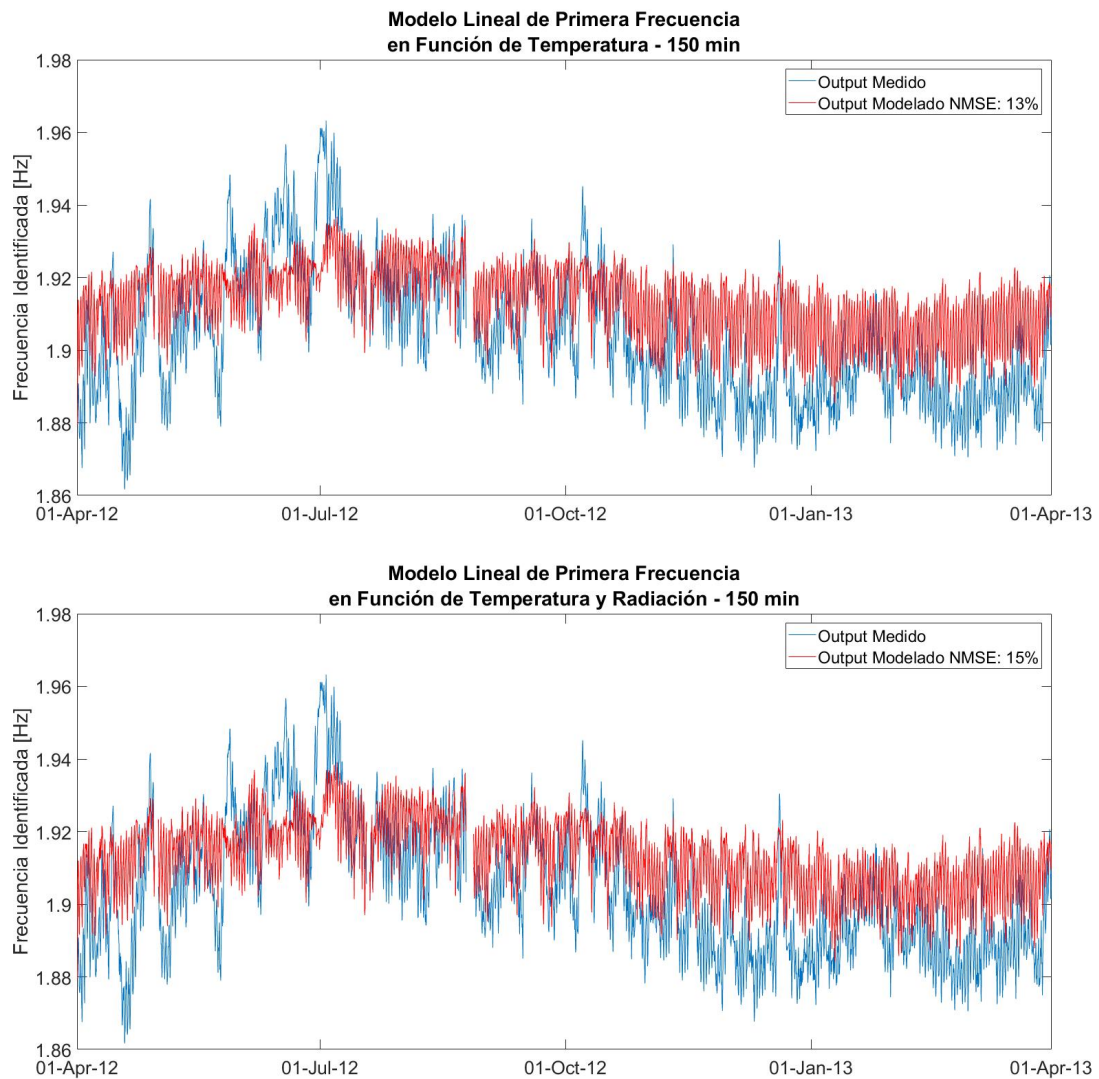


Figura 5.6: Significancia de la radiación solar en la frecuencia. En la imagen, se muestran modelos lineales multiparamétricos de la primera frecuencia modal. El desfase temporal indicado en el título corresponde al que prueba dar un mejor ajuste para cualquier valor entre 0 y 12 horas hacia el pasado. Esto último solo cierto si se asume desfase constante a lo largo de todo el año.

Respecto a la dirección desde la que inciden los rayos solares (cénit y asimut solar), aunque la plantilla de vectores de carga accuse una significancia casi nula, esta tiene directa relación con la evolución de las condiciones de borde del sistema a lo largo del día, en teoría otorgando mayor sentido a la temperatura. Considerando esto es que se realiza la prueba con dos modelos lineales multiparamétricos: uno considerando únicamente la temperatura y el otro la temperatura, el cénit y asimut solar [Fig. 5.7].

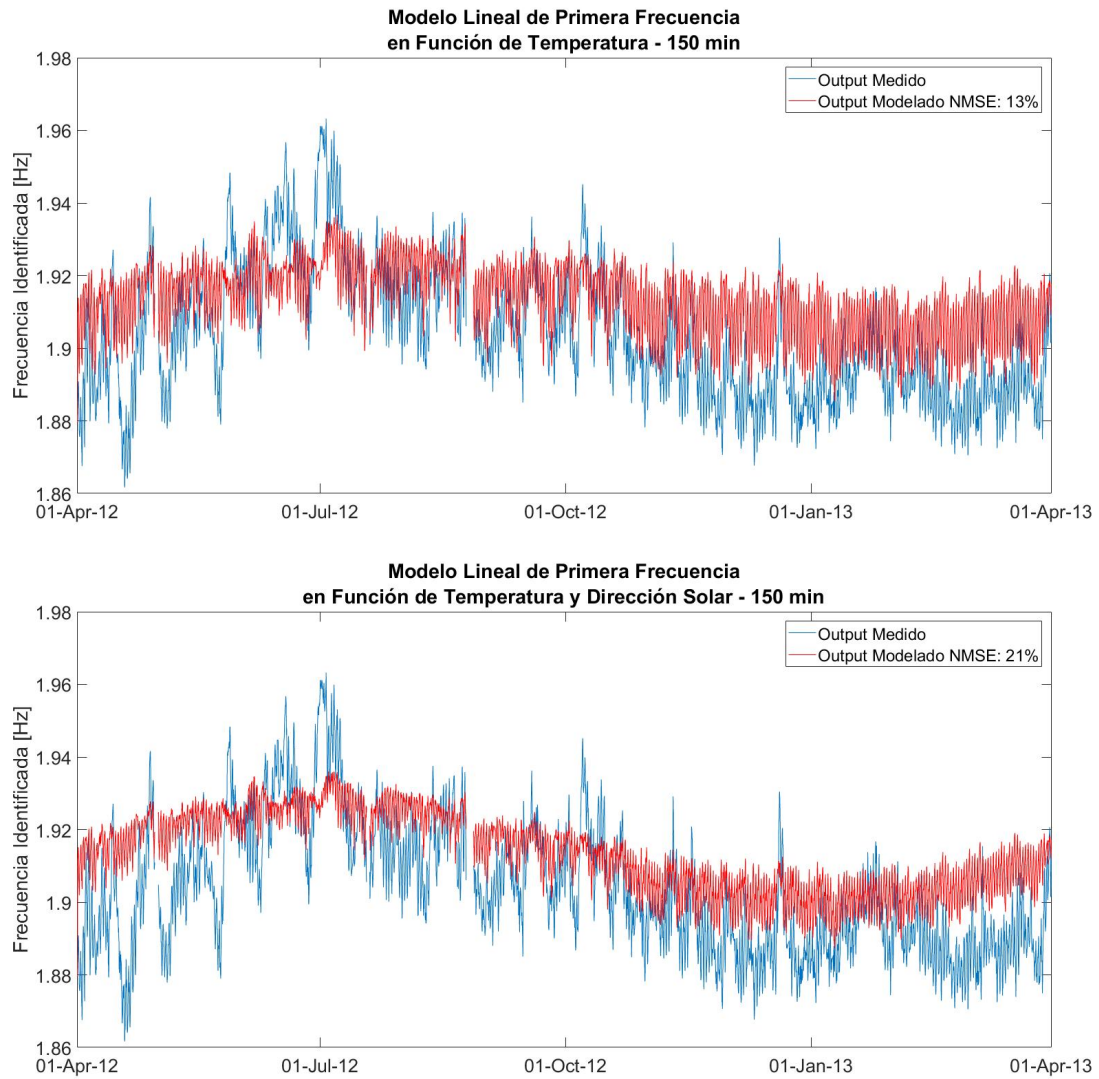


Figura 5.7: Significancia de la dirección del sol en la frecuencia. En la imagen, se muestran modelos lineales multiparamétricos de la primera frecuencia modal. El desfase temporal indicado en el título corresponde al que prueba dar un mejor ajuste para cualquier valor entre 0 y 12 horas hacia el pasado.

Finalmente, los regresores a utilizar son la temperatura del aire, el cénit y el asimut solar.

5.3. Regresión Lineal

Para el entrenamiento de modelos lineales, se evalúa el desfase entre la entrada y la salida para valores entre 0 y 12 horas, en espacios de 30 minutos (24 modelos por modo) y se escoge aquel modelo que maximice el $NMSE$ (ver Sección 2.3.1) con los datos de validación.

En [Fig 5.8] a [Fig. 5.16] se muestra el modelo de mejor ajuste para cada frecuencia modal.




Figura 5.8: Modelo lineal de primera frecuencia modal.






Figura 5.9: Modelo lineal de segunda frecuencia modal.






Figura 5.12: Modelo lineal de quinta frecuencia modal.






Figura 5.13: Modelo lineal de sexta frecuencia modal.






Figura 5.16: Modelo lineal de novena frecuencia modal.

De todos los modelos, los asociados a los modos seis y siete tienen un ajuste $NMSE$ inferior a 0; indicio de un modelo deficiente (ver Sección 2.3). Esto es atribuible exclusivamente a la mala caracterización que se tiene de esta frecuencia para el entrenamiento [Fig. 5.3]. Este, se adelanta, es un tema recurrente para todos los modelos entrenados.

5.4. Regresión Lineal con Historia de Regresores

Por historia de los regresores se entiende el registro pasado de los regresores. La entrada del modelo lineal ya no es un valor instantáneo, sino que es una porción de la serie de tiempo que representa a los regresores [Ec. 5.1].

$$y_i = \sum_{n=1}^{N_b} b_n \cdot u_{(i-N_k)-n} + \nu_i \quad (5.1)$$

En que u_i es el conjunto de regresores en el instante i , N_k indica el desfase temporal entre la entrada y la salida, y N_b los pasos previos a considerar hacia el pasado desde N_k . Para el entrenamiento de estos modelos, se evalúa el desfase N_k para valores entre 2 y 48 (entre media hora y 12 horas hacia el pasado); y N_b , para valores entre N_k y 48 (12 horas). De esta manera, se está permitiendo que la porción escogida de la historia de los regresores sea cualquiera de las 12 horas previas al instante a predecir. El modelo óptimo se escoge como aquel que maximice el $NMSE$ (ver Sección 2.3.1) con los datos de validación.

5.4. REGRESIÓN LINEAL CON HISTORIA DE REGRESORES

En [Fig. 5.17] a [Fig. 5.25] se muestra el modelo de mejor ajuste para cada frecuencia modal.




Figura 5.17: Modelo lineal con historia de regresores de primera frecuencia modal.




Figura 5.18: Modelo lineal con historia de regresores de segunda frecuencia modal.

5.4. REGRESIÓN LINEAL CON HISTORIA DE REGRESORES




Figura 5.19: Modelo lineal con historia de regresores de tercera frecuencia modal.




Figura 5.20: Modelo lineal con historia de regresores de cuarta frecuencia modal.

5.4. REGRESIÓN LINEAL CON HISTORIA DE REGRESORES




Figura 5.21: Modelo lineal con historia de regresores de quinta frecuencia modal.




Figura 5.22: Modelo lineal con historia de regresores de sexta frecuencia modal.

5.4. REGRESIÓN LINEAL CON HISTORIA DE REGRESORES




Figura 5.23: Modelo lineal con historia de regresores de séptima frecuencia modal.




Figura 5.24: Modelo lineal con historia de regresores de octava frecuencia modal.




Figura 5.25: Modelo lineal con historia de regresores de novena frecuencia modal.

Como es de esperarse, estos modelos tienen mejor ajuste que la regresión lineal simple (ya que solo se han agregado términos al polinomio, sin excluir ninguno de los usados en esta última), excepto para los modos seis y siete, en que el valor $NMSE$ sigue acusando modelos deficientes.

5.5. ARX

Para el entrenamiento de modelos ARX, se evalúan los órdenes autorregresivo (N_a) y exógeno (N_b) para valores entre 2 y 48 (entre media hora y 12 horas hacia el pasado), en espacios de 30 minutos, totalizando 24 valores posibles para cada orden y 576 modelos a evaluar por frecuencia modal. El modelo óptimo se escoge como aquel que maximice el $NMSE$ (ver Sección 2.3.1) con los datos de validación.

En [Fig 5.26] a [Fig. 5.34] se muestra el modelo de mejor ajuste para cada frecuencia modal.




Figura 5.26: Modelo ARX de primera frecuencia modal.










Figura 5.27: Modelo ARX de segunda frecuencia modal.










Figura 5.34: Modelo ARX de novena frecuencia modal.

El modelo ARX presenta un mejor ajuste que la regresión lineal simple (descontando los modos seis y siete), aunque esto no sigue siendo cierto para todos los modos al hacer la comparación con la regresión lineal con historia de regresores.

Aparenta ser ventajoso considerar la frecuencia modal como una señal dependiente de sus valores previos, aunque debido a que en todos los modelos anteriores se han considerado solo relaciones lineales, existiendo modelos lineales con historia de regresores con mejor ajuste que su contraparte ARX, es imposible concluir si esta dependencia de valores previos es real o producto de no considerar las relaciones correctas con los regresores.

Por último, para casi todos los modos se nota al comienzo y al final del período de tiempo una divergencia del modelo respecto de la frecuencia de validación. Este aspecto es retomado durante el seguimiento modal auxiliado por modelos ARX, donde se hace necesario predecir varios pasos a futuro con ayuda de los modelos (ver Sección 7.5).

5.6. MLP

El modelo MLP a usar es una red cuya entrada considere 12 horas hacia el pasado de los regresores (los 48 pasos previos). A diferencia de los modelos anteriormente entrenados, para la red neuronal no es necesario evaluar distintas ventanas de tiempo como entrada; si por usar una ventana holgada de tiempo se tuviera más datos de los relevantes (por ejemplo, si la ventana de tiempo relevante fuera de 10 horas en lugar de 12), el resultado del entrenamiento de la red sería uno en que los pesos asociados a las entradas sobrantes habrían convergido a cero. Por lo tanto, solo una red es entrenada por modo.

El grafo de la red consiste en dos capas ocultas con 50 neuronas cada una. Para ambas capas la función de activación es una tangente hiperbólica [2]. El algoritmo de entrenamiento de la red es el de **descenso de gradiente con impulso** (*gradient descent with momentum and adaptive learning rate backpropagation*) [3].

En [Fig 5.35] a [Fig. 5.43] se muestra el modelo de mejor ajuste para cada frecuencia modal. Para el caso del modelo MLP, la verificación de buen ajuste se hace con los datos de prueba y no con los de validación (ver Sección 5.1).




Figura 5.35: Modelo MLP autorregresivo de primera frecuencia modal.

²La tangente hiperbólica muestra un mejor desempeño que la función sigmoidea. Esto posiblemente se deba al carácter cíclico de la señal a modelar (los ciclos diarios de ascenso y descenso de la frecuencia modal).

³función *traindx* en MATLAB




Figura 5.36: Modelo MLP autorregresivo de segunda frecuencia modal.




Figura 5.37: Modelo MLP autorregresivo de tercera frecuencia modal.




Figura 5.38: Modelo MLP autorregresivo de cuarta frecuencia modal.




Figura 5.39: Modelo MLP autorregresivo de quinta frecuencia modal.




Figura 5.40: Modelo MLP autorregresivo de sexta frecuencia modal.




Figura 5.41: Modelo MLP autorregresivo de séptima frecuencia modal.




Figura 5.42: Modelo MLP autorregresivo de octava frecuencia modal.




Figura 5.43: Modelo MLP autorregresivo de novena frecuencia modal.

Finalmente, de todos los modelos evaluados, el MLP tiene la capacidad de lograr el mejor ajuste. Sin embargo, como se ve en [Fig. 5.40], [Fig. 5.41] y [Fig. 5.43], este modelo es mucho más sensible a un entrenamiento deficiente, *i.e.* cuando los datos de entrenamiento cuentan con ventanas de tamaño considerable sin mediciones [Fig. 5.3].

Capítulo 6

AFDD-T

6.1. AFDD-T para el Caso de Estudio

Del algoritmo de AFDD-T (ver Sección 2.4.1) interesa evaluar su desempeño tanto frente a variaciones pequeñas producidas por el ambiente como frente a variaciones bruscas por daño. Para ello, se evalúa el algoritmo en tres períodos distintos:

- Para el período anterior al terremoto del año 2010.
- Para el período posterior al terremoto.
- Durante el terremoto, donde se obtienen los modos de referencia de una ventana anterior al evento y se evalúa el algoritmo en ventanas posteriores.

La selección de modos de referencia se hace con el algoritmo de FDD y obtención de picos por inspección visual al igual que en [1], para una única ventana de 15 minutos. Para los dos primeros casos, la ventana escogida corresponde a la primera del período con seis canales activos (la cantidad máxima posible). Para el tercer caso, se escoge también una ventana con seis canales activos, a una distancia prudente del terremoto. La idea de usar solo ventanas con seis canales activos es evitar que una mala estimación de la forma modal afecte el desempeño del algoritmo.

Para la identificación, los registros de aceleraciones son preprocesados de la misma forma que para la identificación por el algoritmo de SSI-COV (ver Sección 4.1). Se promedian ventanas de un minuto de duración con 30 segundos de traslapo y se multiplican por una ventana de Hanning.

Para los tres períodos a evaluar se impone un límite inferior de 0.95 al gráfico de MAC vs. f para hallar la banda de filtro dinámico.

6.2. Seguimiento para el Período Anterior al Terremoto

Para el período anterior al terremoto del Maule se identifica un total de 6 modos de referencia [Fig. 6.1]. La ventana identificada es la del 7 de abril del año 2009 a las 00:05 hrs.




Figura 6.1: FDD para período previo al terremoto. El gráfico corresponde al primer valor singular de la matriz de periodograma cruzado y las frecuencias identificadas por algoritmo FDD para ventana del 7 de abril del año 2009 a las 00:05 hrs.

Para este período y para los sucesivos, la cantidad de modos identificados es menor que la hallada usando el algoritmo SSI-COV y diagramas de estabilización, donde se identifica hasta diez modos físicos (ver Sección 4.2) por la limitación que conlleva la interpretación visual en [Fig. 6.1].

6.2. SEGUIMIENTO PARA EL PERÍODO ANTERIOR AL TERREMOTO

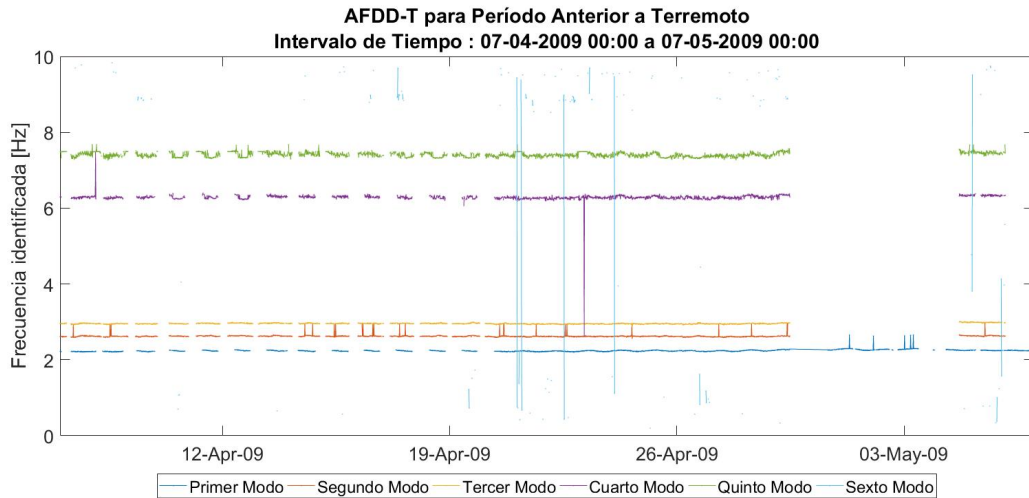


Figura 6.2: AFDD-T para período previo al terremoto. La figura muestra las frecuencias modales rastreadas para el intervalo de tiempo desde el 7 de abril del año 2009 a las 00:00 hrs hasta el 7 de mayo del año 2009 a las 00:00 hrs.

En [Fig. 6.2] se ve las frecuencias rastreadas a lo largo de un mes, con los modos de referencia seleccionados al inicio del período. El sexto modo es escasamente rastreado, habiendo instantes donde es confundido con ruido. En [Fig. 6.3] se aprecia el efecto del ruido en el primer vector singular de la matriz de periodograma cruzado. Teóricamente, solo en la vecindad de la sexta frecuencia modal debiera existir valores altos para el MAC . Sin embargo, este tiene valores altos en todo el rango de frecuencias de interés. Si bien solo en la vecindad de la sexta frecuencia modal el MAC tiene sostenidamente valores altos (a diferencia del resto de las frecuencias, donde los valores altos son todos aislados), este en ningún punto supera los 0.95. El valor alto aislado cercano a 1 Hz es el que provoca que el sexto modo sea confundido con ruido para esta ventana.

6.2. SEGUIMIENTO PARA EL PERÍODO ANTERIOR AL TERREMOTO




Figura 6.3: Gráfico de MAC vs. f contaminado por ruido. El gráfico evidencia el efecto de la baja cantidad de sensores en el rastreo del sexto modo. El límite en rojo indica el límite inferior del gráfico para el algoritmo.

Este mismo fenómeno se repite de forma local para todos los modos. Tomando, por ejemplo, el primer modo [Fig. 6.4], se ve que la estimación de la frecuencia es discontinua, aunque es consistente con la tendencia dada por la identificación usando el algoritmo SSI-COV y diagramas de estabilización.




Figura 6.4: AFDD-T para el primer modo de referencia. La frecuencia está superpuesta con la primera frecuencia modal obtenida por SSI-COV y diagrama de estabilización. Para esta última, el primer modo ha pasado por la etapa de preprocesamiento para entrenamiento de modelos predictivos de frecuencia (ver Sección 5.1).

6.3. Seguimiento para el Período Posterior al Terremoto

Para el período posterior al terremoto se identifica un total de 6 modos de referencia [Fig. 6.5]. La ventana identificada es la del 27 de febrero del año 2010 a las 04:15 hrs, aproximadamente 45 minutos después del terremoto del Maule. El motivo para escoger una ventana tan cercana a este evento es que, a partir del 1 de marzo del año 2010, se descarta el sensor E4 de la identificación (ver Sección 3.3.4), dejando todas las ventanas con a lo más cinco canales activos.




Figura 6.5: FDD para período posterior al terremoto. El gráfico corresponde al primer valor singular de matriz de periodograma cruzado y las frecuencias identificadas por algoritmo FDD para ventana del 27 de febrero del año 2010 a las 04:15 hrs.

En [Fig. 6.6] se ve las frecuencias rastreadas a lo largo de un mes, con los modos de referencia seleccionados al inicio del período. Nuevamente se ve el efecto del ruido en la estimación de las frecuencias, así como la incapacidad de rastrear el segundo y el quinto modo.




Figura 6.6: AFDD-T para período previo al terremoto. La figura muestra las frecuencias modales rastreadas para el intervalo de tiempo desde el 27 de febrero del año 2010 a las 04:15 hrs hasta el 27 de marzo del año 2010 a las 04:15 hrs.

6.4. Seguimiento Durante el Terremoto

Para el período inmediatamente anterior al terremoto se identifica un total de 6 modos de referencia [Fig. 6.7]. La ventana Identificada es la del 26 de febrero del año 2010 a las 00:00, aproximadamente 27 horas antes del terremoto del Maule.




Figura 6.7: FDD para período que incorpora al terremoto. El gráfico corresponde al primer valor singular de matriz de periodograma cruzado y las frecuencias identificadas por algoritmo FDD para ventana del 26 de febrero del año 2010 a las 00:00 hrs.

En [Fig. 6.8] se ven las frecuencias rastreadas a lo largo de un mes, con los modos de referencia seleccionados al inicio del período. AFDD-T es capaz de rastrear modos durante el terremoto; su desempeño no es significativamente peor que en los dos períodos anteriores por haber sido dañada la estructura de forma abrupta. Esto, claramente, es un indicio que el daño producido por el terremoto no se tradujo en una variación significativa de la forma modal, aun cuando la frecuencia sí varió considerablemente.




Figura 6.8: AFDD-T para período que incorpora al terremoto. La figura muestra las frecuencias modales rastreadas para el intervalo de tiempo desde el 26 de febrero del año 2010 a las 00:00 hrs hasta el 26 de marzo del año 2010 a las 00:00 hrs.

La idea detrás del algoritmo de AFDD-T es que la forma modal es una propiedad conservada entre ventanas de tiempo y, que por ello, puede usarse para predecir los nuevos estados del sistema. Los resultados anteriores son consistentes globalmente con esta idea: el algoritmo puede capturar (débilmente) la tendencia dejada por las variaciones meteorológicas en la frecuencia [Fig. 6.2] [Fig. 6.6] y también puede rastrear modos frente a un episodio de daño abrupto [Fig. 6.8].

A pesar de lo anterior, el desempeño visto no es satisfactorio. En muchos instantes de tiempo, la frecuencia es mal estimada o incluso no es estimada. Sobre esto, en [Fig. 6.3] hay indicios que señalan a la baja cantidad de sensores activos como causa de los altos niveles de ruido. Más aun, en [1] este efecto está predicho mediante una simulación computacional.

De las pruebas anteriores hechas, se concluye que el algoritmo de AFDD-T, al apoyarse exclusivamente en la forma modal, requiere de un arreglo de sensores apropiado para la tarea: con una cantidad suficiente de canales activos y una buena distribución de estos en el sistema. Para casos de estudio donde estas condiciones no se satisfagan, será necesario apoyarse en otras propiedades, como la frecuencia modal.

Capítulo 7

Seguimiento Modal Auxiliado por Modelos de Frecuencia

7.1. Condiciones para el Seguimiento Modal

Durante el seguimiento modal, dada una nueva ventana de tiempo, el nuevo estado del sistema es encontrado asociando el modo de referencia al modo identificado más cercano (ver Sección 2.4.2). El objetivo de la incorporación de modelos predictivos de la frecuencia es actualizar en cada nueva ventana la frecuencia de referencia para poder reducir la distancia existente entre la referencia y el estado actual (ver Sección 2.4.3). La frecuencia de referencia pasa a ser la frecuencia predicha por el modelo en la ventana de tiempo a rastrear.

Para poder usar modelos autorregresivos (específicamente, el modelo ARX) para estimar la frecuencia modal, es necesario resolver dos problemas asociados a la metodología: primero, que los modelos autorregresivos requieren de las N_a mediciones anteriores de la señal (ver Sección 2.3.2); y segundo, que puesto que en determinadas ventanas un modo puede no ser identificado, no siempre se contará con todas estas mediciones.

El primer problema se resuelve realizando un seguimiento modal previo que ignore la variación por factores ambientales. Este tiene como único objetivo obtener la cantidad de frecuencias necesarias para la entrada de los modelos. Se asume que estas frecuencias están comprendidas en un intervalo de tiempo lo suficientemente pequeño como para que su variación sea despreciable y no sea necesario incorporar el uso de modelos a la metodología.

El segundo problema se resuelve usando la predicción a varios pasos a futuro; tantos pasos como mediciones de la señal haya faltantes entre la última medición y el instante a predecir. En el caso de los modelos autorregresivos, esto significa alimentar la entrada autorregresiva con la salida del modelo en instantes previos. Un esquema de esto puede verse en [Fig. 7.1].

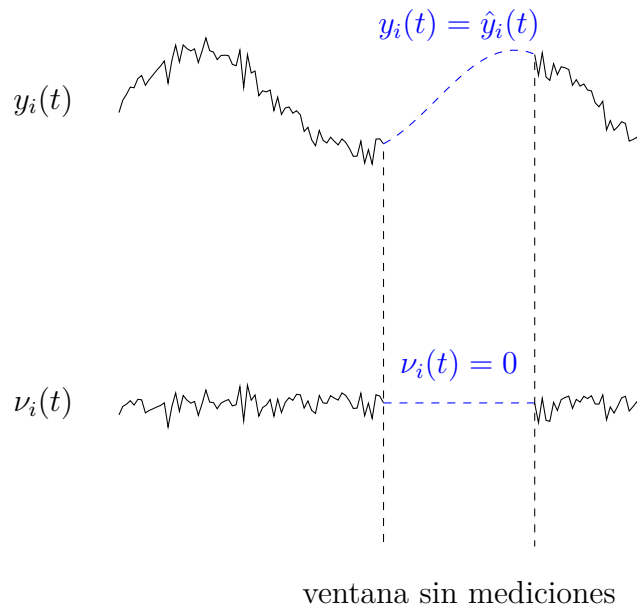


Figura 7.1: Uso de modelos para compensar lagunas en mediciones. La imagen muestra que el proceso es equivalente a asumir que en una ventana sin mediciones la frecuencia real es igual a la modelada, o de forma equivalente, que el error del modelo es cero (predicción a N pasos).

7.2. Metodología de Seguimiento para el Período Posterior al Terremoto

La evaluación de la metodología se hace para el período posterior al terremoto del año 2010 (ver Sección 5.1). Específicamente, la ventana de análisis corresponde a la comprendida entre el día 7 de abril del año 2011 (día que coincide con el comienzo de la ventana para entrenamiento de los modelos) y el 31 de diciembre del año 2016 (la última ventana de la que se cuenta con registros). Los modos de referencia son estimados al principio de esta ventana, con un seguimiento preliminar para verificar que estos sean buenas estimaciones de los parámetros de los modos físicos.

7.2.1. Métrica del Espacio

La métrica definida para el seguimiento modal, similar a la usada para *Clustering* con OP-TICS de la identificación (ver Sección 4.3.3), se muestra en [Ec. 7.1].

$$d_{ref,i} = \begin{cases} 0.7 \cdot \frac{|f_{ref}-f_i|}{f_{ref}} + 0.3 \cdot (1 - MAC(\phi_{ref}, \phi_i)) & \text{2 o más canales activos} \\ \frac{|f_{ref}-f_i|}{f_{ref}} & \text{en caso contrario} \end{cases} \quad (7.1)$$

En que f_{ref} y ϕ_{ref} denotan la frecuencia y forma modal del modo de referencia; y f_i y ϕ_i , la frecuencia y forma modal del modo i -ésimo perteneciente a la ventana analizada. Al igual que durante la limpieza de la identificación, por cantidad de canales activos se hace referencia a la cantidad de canales en común entre la ventana asociada al modo de referencia y la ventana analizada.

Nótese que, puesto que los modos físicos se encuentran caracterizados (a través de los modos de referencia), para esta métrica sí tiene sentido que el término asociado a distancia en frecuencia no sea simétrico, pues está asociado a la variación relativa a la frecuencia de referencia (una discusión detallada de este aspecto se da en la Sección 4.3.3).

Al incorporar modelos de frecuencia modal al seguimiento modal, se espera que la distancia entre frecuencia real y frecuencia de referencia sea pequeña. Por esto, en [Ec. 7.1] se le da una significancia preponderante al término asociado a distancia en frecuencia.

Para esta metodología, una vez evaluada la distancia entre todos los modos identificados en la ventana analizada y el modo de referencia, para que el modo más cercano a la referencia sea considerado el nuevo estado del modo físico, este debe cumplir con los siguientes tres criterios de manera simultánea:

- Que en [Ec. 7.1] el término asociado a la distancia en frecuencia no supere el 5%.
- Que en [Ec. 7.1] el término asociado a la distancia en forma modal no supere el 70%.
- Que la distancia absoluta en frecuencia con la referencia no supere los 0.2 Hz.

7.2.2. Selección de Modos de Referencia

Los modos de referencia son escogidos a partir de un día de identificación y son validados haciendo un seguimiento modal de estos a lo largo de cuatro días. El día escogido para extraer los modos de referencia corresponde al 7 de abril del año 2011 [Tab. 7.1] y la ventana de seguimiento de prueba es la comprendida entre el 6 de abril del año 2011 a las 00:00 hrs y el 10 de abril del año 2011 a las 00:00 hrs.

Modo Físico	Ventana
1	07-04-2011 00:30
2	07-04-2011 00:30
3	07-04-2011 00:00
4	07-04-2011 00:00
5	07-04-2011 00:15
6	07-04-2011 00:15
7	07-04-2011 02:15
8	07-04-2011 02:00
9	07-04-2011 08:15

Tabla 7.1: Selección de modos de referencia para el año 2011. Los modos escogidos corresponden a una buena estimación de los modos físicos porque con ellos se logra capturar una cantidad importante de repeticiones de estos en la ventana de prueba escogida.

7.3. Seguimiento Modal con Modelo Lineal

A continuación se muestran los resultados del seguimiento modal auxiliado con los modelos lineales entrenados (ver Sección 5.3). En [Fig. 7.2] y [Fig. 7.3] se muestran el resultado para cada modo de referencia, contrastado con la identificación, y la evolución de la frecuencia de referencia en el tiempo, respectivamente.

7.3. SEGUIMIENTO MODAL CON MODELO LINEAL




Figura 7.2: Resultado del seguimiento modal auxiliado por modelos lineales de la frecuencia para la ventana del 8 de abril del año 2011 al 31 de diciembre del año 2016.




Figura 7.3: Evolución de la frecuencia de referencia obtenida por modelos lineales. En la imagen se contrasta esta con la serie de tiempo obtenida del seguimiento modal.

De [Fig. 7.2], se ve que la metodología logra capturar con un desempeño aceptable la evolución de los dos primeros modos, mientras que para los modos restantes, por períodos su evolución se pierde y luego es hallada nuevamente. De [Fig. 7.3], sin embargo, se ve que la tendencia temporal de la frecuencia sí es capturada. Por lo tanto, este fenómeno es atribuido a una mala estimación de la forma modal durante la etapa de identificación.

7.4. Seguimiento Modal con Modelo Lineal con Historia de Regresores

A continuación se muestran los resultados del seguimiento modal auxiliado con los modelos lineales con historia de los regresores entrenados (ver Sección 5.4). En [Fig. 7.4] y [Fig. 7.5] se muestran el resultado para cada modo de referencia, contrastado con la identificación, y la evolución de la frecuencia de referencia en el tiempo, respectivamente.




Figura 7.4: Resultado del seguimiento modal auxiliado por modelos lineales con historia de regresores de la frecuencia para la ventana del 8 de abril del año 2011 al 31 de diciembre del año 2016.




Figura 7.5: Evolución de la frecuencia de referencia obtenida por modelos lineales con historia de regresores. En la imagen se contrasta esta con la serie de tiempo obtenida del seguimiento modal.

De la implementación de modelos lineales dependientes de la historia de los regresores, sorprende que los resultados sean idénticos a los obtenidos usando modelos lineales, a pesar del mejor ajuste de los primeros respecto a los segundos (ver Sección 5.4). Las ventanas de tiempo en que la evolución temporal de los modos es capturada son las mismas para ambos casos, reforzando la idea de que la pérdida de la evolución de estos modos es producto de la mala estimación de las formas modales.

7.5. Seguimiento Modal con Modelo ARX

Para modelos ARX, ocurre que estos son incapaces de predecir muchos pasos a futuro. Alimentar el modelo con la frecuencia predicha en lugar de la medida provoca que estos rápidamente diverjan [Fig. 7.6]. Este fenómeno, denominado *memoria de corto plazo del modelo*, ocasiona que estos modelos no puedan ser usados para esta metodología, donde se sabe que la serie de tiempo que representa a la frecuencia es discontinua en el tiempo.




Figura 7.6: Evolución de la frecuencia de referencia obtenida por modelos ARX. El primer tramo de valores (sin frecuencia de referencia indicada) corresponde al Seguimiento preliminar hecho sin considerar modelo de frecuencia (ver Sección 7.1).

Los modos dos y tres son perdidos rápidamente luego de los primeros cuatro instantes de seguimiento modal, donde este fue efectivo. Para los demás modos, si bien la frecuencia predicha se mantiene estable por más instantes, la metodología pierde validez de forma mucho más temprana que su contraparte implementada junto a modelos lineales.

La incapacidad de un modelo autorregresivo de predecir varios pasos a futuro es frecuentemente un indicio de divergencia. Para el caso más general, en que los parámetros del modelo son números complejos, para verificar la convergencia de este basta con confirmar si todos estos se ubican dentro de la circunferencia unitaria con centro en el origen, en el *plano de Argand*. Para el caso particular de los modelos entrenados en este trabajo, puesto que tanto la entrada como la salida toman solo valores reales, los parámetros del modelo son reales y basta con confirmar si su módulo es inferior a la unidad.

En [Fig. 7.7] se encuentran representados los parámetros de todos los modelos ARX entrenados (ver Sección 5.5). Para todos ellos existen únicamente dos parámetros que exceden en módulo a la unidad, pertenecientes a la componente autorregresiva del modelo. Esto puede ser una causa de la divergencia explicada anteriormente.




Figura 7.7: Módulo de parámetros de modelos ARX para todas las frecuencias modales. La representación se hace en una escala logarítmica de los módulos.

7.6. Seguimiento Modal con Modelo MLP

A continuación se muestran los resultados del seguimiento modal auxiliado con los modelos MLP entrenados (ver Sección 5.6). En [Fig. 7.8] y [Fig. 7.9] se muestran el resultado para cada modo de referencia, contrastado con la identificación, y la evolución de la frecuencia de referencia en el tiempo, respectivamente.




Figura 7.8: Resultado del seguimiento modal auxiliado por modelos MLP de la frecuencia para la ventana del 8 de abril del año 2011 al 31 de diciembre del año 2016.




Figura 7.9: Evolución de la frecuencia de referencia obtenida por modelos MLP. En la imagen se contrasta esta con la serie de tiempo obtenida del Seguimiento Modal.

Nuevamente, el resultado para los modos modelados correctamente es idéntico al obtenido usando modelos lineales. Para los modos seis, siete y nueve, cuyo entrenamiento fue deficiente, los resultados son marginalmente peores.

7.7. Comportamiento del Amortiguamiento Modal

Para evaluar la cercanía entre dos estados del mismo modo físico, la métrica definida considera frecuencia y forma modal, ignorando la razón de amortiguamiento. El motivo de esto es la presunción de que el amortiguamiento estimado no es una propiedad que pueda asumirse constante, como la forma modal; o cuya variación temporal pueda atribuirse solo a factores ambientales, como la frecuencia.

En [Fig. 7.10] se muestra la evolución temporal de la razón de amortiguamiento y de la frecuencia modal para el primer modo, obtenidas del seguimiento modal con modelo lineal. De esta figura, se concluye que la razón de amortiguamiento no tiene relación alguna con la frecuencia (los picos de ambas no se relacionan, ni positiva, ni negativamente); además, la primera tiene un comportamiento errático superior a la segunda, indicio de un error mayor asociado a su estimación.

7.7. COMPORTAMIENTO DEL AMORTIGUAMIENTO MODAL




Figura 7.10: Evolución del amortiguamiento en el tiempo. En la figura, para facilitar la interpretación del gráfico, se incluye también una curva suavizada los resultados del Seguimiento Modal.

En [Fig. 7.11] se muestra la relación entre la razón de amortiguamiento del primer modo y la temperatura del aire para un año de mediciones. De esta figura, se ve que la temperatura no es un buen predictor del amortiguamiento, pues la correlación entre ambos (positiva) es insignificante. Este resultado es consistente con el obtenido en [8], donde también se observa una baja correlación positiva entre ambas variables.




Figura 7.11: Relación entre el amortiguamiento y la temperatura para el primer modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año). En el gráfico, con el propósito de facilitar su interpretación, se ha incluido el ajuste lineal de la nube de puntos.

7.7. COMPORTAMIENTO DEL AMORTIGUAMIENTO MODAL

La baja correlación con la temperatura es un aspecto recurrente para todos los modos, como se muestra en [Fig. 7.12] a [Fig. 7.19].




Figura 7.12: Relación entre el amortiguamiento y la temperatura para el segundo modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).




Figura 7.13: Relación entre el amortiguamiento y la temperatura para el tercer modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).

7.7. COMPORTAMIENTO DEL AMORTIGUAMIENTO MODAL




Figura 7.14: Relación entre el amortiguamiento y la temperatura para el cuarto modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).




Figura 7.15: Relación entre el amortiguamiento y la temperatura para el quinto modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).

7.7. COMPORTAMIENTO DEL AMORTIGUAMIENTO MODAL




Figura 7.16: Relación entre el amortiguamiento y la temperatura para el sexto modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).




Figura 7.17: Relación entre el amortiguamiento y la temperatura para el séptimo modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).

7.7. COMPORTAMIENTO DEL AMORTIGUAMIENTO MODAL




Figura 7.18: Relación entre el amortiguamiento y la temperatura para el octavo modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).




Figura 7.19: Relación entre el amortiguamiento y la temperatura para el noveno modo. Los datos graficados corresponden a los resultados del seguimiento modal para el año de mediciones comprendido entre el 8 de abril del año 2011 y el 8 de abril del año 2012 (un año).

En todas las figuras se puede observar la cota inferior al amortiguamiento impuesta durante la primera etapa de la limpieza de la identificación (ver Sección 4.3.1). Además, se observa que la relación entre amortiguamiento y temperatura no es siempre creciente para todos los modos, pero sí en todos se encuentra minimizada por la dispersión de la nube de puntos. Por esto, no parece apropiado proyectar una caracterización del sistema a partir de la relación lineal determinada; no se incurre en un error apreciable si se asume que la variación del amortiguamiento estimado no guarda relación con la temperatura externa.

7.8. Comportamiento de la Forma Modal

En el Capítulo 6 se prueba el algoritmo de AFDD-T durante el terremoto del año 2010, con modos de referencia escogidos de una ventana anterior a este evento (ver Sección 6.4). De esta evaluación queda en evidencia que el daño generado por el terremoto en el sistema no se traduce en una variación apreciable de las formas modales. Sin embargo, aún queda la interrogante de qué otros factores pueden alterar esta propiedad.

Para responder la pregunta anterior, se rastrea en el tiempo la evolución del valor MAC entre el modo de referencia, para cada modo físico, y el resultado del seguimiento modal hecho a partir de este. El resultado se muestra en [Fig. 7.20] a [Fig. 7.28].




Figura 7.20: Evolución temporal de la distancia MAC para el primer modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.21: Evolución temporal de la distancia MAC para el segundo modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.22: Evolución temporal de la distancia MAC para el tercer modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.23: Evolución temporal de la distancia MAC para el cuarto modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.24: Evolución temporal de la distancia MAC para el quinto modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.25: Evolución temporal de la distancia MAC para el sexto modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.26: Evolución temporal de la distancia MAC para el séptimo modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.27: Evolución temporal de la distancia MAC para el octavo modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.




Figura 7.28: Evolución temporal de la distancia MAC para el noveno modo. En el gráfico se muestra el valor MAC entre el modo de referencia usado para el seguimiento modal (ver Sección 7.2.1) y la evolución capturada del modo físico.

De las figuras anteriores, es claro el efecto del descarte manual de canales detallado en el apéndice A. Progresivamente, a medida que distintos canales son considerados (y descartados) para la identificación, la similitud de la forma modal con la referencia se va perdiendo. Sobre la pérdida de la trazabilidad de los modos ocurrida en los años 2015 y 2016, no se tiene una justificación clara. Sin embargo, observando el efecto abrupto que significa deshacerse de un canal en el seguimiento modal, se intuye que la causa se encuentra en una manipulación de los sensores.

Para evaluar la influencia del ambiente sobre la forma modal, se escoge el período de tiempo entre agosto de 2011 y julio de 2012, donde ningún canal se descarta manualmente (aunque sí de manera automática). En [Fig. 7.29] a [Fig. 7.37] se muestra la correlación entre esta porción de datos y la temperatura del aire en el mismo período, recogida en un ajuste lineal de ambos.




Figura 7.29: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el primer modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).

7.8. COMPORTAMIENTO DE LA FORMA MODAL




Figura 7.30: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el segundo modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).




Figura 7.31: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el tercer modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).

7.8. COMPORTAMIENTO DE LA FORMA MODAL




Figura 7.32: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el cuarto modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).




Figura 7.33: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el quinto modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).

7.8. COMPORTAMIENTO DE LA FORMA MODAL




Figura 7.34: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el sexto modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).




Figura 7.35: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el séptimo modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).




Figura 7.36: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el octavo modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).




Figura 7.37: Relación entre la distancia MAC respecto al modo de referencia y la temperatura para el noveno modo. Los datos graficados corresponden a los obtenidos por seguimiento modal auxiliado de modelos lineales para el intervalo de tiempo comprendido entre el 1 de agosto de 2011 y el 1 de julio de 2012 (11 meses).

De las figuras anteriores, se aprecia la insensibilidad del valor MAC a variaciones en la temperatura: el ajuste lineal es horizontal dentro de una precisión razonable dada la trazabilidad conseguida. La única excepción son aquellos modos cuyo rastreo es tan deficiente que no se puede construir una relación estadística certera entre las magnitudes [Fig. 7.32] [Fig. 7.36].

7.8. COMPORTAMIENTO DE LA FORMA MODAL

Con la información anterior, se tiene indicios de la insensibilidad de la forma modal frente a episodios de daño y variaciones de factores ambientales.

Capítulo 8

Comentarios Finales

En este trabajo se han caracterizado las metodologías de seguimiento modal escogidas tras la revisión bibliográfica (AFDD-T y seguimiento asociativo auxiliado por modelos predictivos de la frecuencia) y se ha probado la efectividad de involucrar el efecto de los factores ambientales en la frecuencia modal para estas.

Sobre la identificación realizada

Respecto a la identificación hecha de la estructura (ver Capítulo 4), los resultados obtenidos son consistentes con los presentes en [3] y, aunque con un nivel alto de ruido presente, el algoritmo captura secuencias temporales de modos que, por su comportamiento estacional, pueden considerarse como modos físicos. Sin embargo, la baja cantidad de sensores en la estructura provoca que la forma modal sea mal estimada. Incluso en el seguimiento modal probado en el Capítulo 7, donde se admiten errores del 70 % en la distancia $1 - MAC$ [Ec. 2.7], existen ventanas de tiempo donde la evolución de los modos físicos no puede ser capturada.

Sin embargo, la baja cantidad de sensores no explica por completo la falta de trazabilidad de algunos modos. Durante la evaluación del algoritmo de AFDD-T, admitiendo solo un 5 % de diferencia en la distancia MAC entre dos estados sucesivos del mismo modo físico, se logra obtener un esbozo de la tendencia temporal de varios modos. En cambio, en el rastreo auxiliado por modelos de frecuencia, el resultado no es dramáticamente mejor, a pesar de que el error admisible es varias veces superior al primero. Esto es un indicio de que las formas modales obtenidas por FDD son más estables temporalmente que las estimadas con diagramas de estabilización.

Del algoritmo de identificación con diagramas de estabilización usado, la etapa de determinación del valor representativo de cada columna estable parece una fuente de error probable que explique el fenómeno antes descrito (ver Sección 4.2). En ella, tomar en cuenta el amortiguamiento para determinar el centroide del *Cluster*, sin considerar la forma modal, con seguridad induce a valores erráticos de esta última a lo largo del tiempo. La capacidad de recuperar la

trazabilidad en el tiempo de los modos físicos puede considerarse como un criterio adicional de validación de un algoritmo de identificación, así como un criterio para discernir entre errores en la estimación de los modos atribuibles al arreglo de sensores y errores atribuibles a la metodología de identificación.

Otro aspecto interesante de la precisión de la forma modal obtenida se encuentra en la implementación del algoritmo de AFDD-T; en el gráfico de MAC vs. f [Fig. 6.3], y en cómo este muestra la relación entre la baja cantidad de sensores y el error en su estimación. La baja cantidad de sensores implica directamente que el conjunto de valores posibles del primer vector singular de la matriz de periodograma cruzado tiene una cardinalidad muy baja y, como resultado de esto, el estimador de la forma modal de un modo físico tendrá una alta probabilidad de ser similar al de un modo espurio.

El gráfico de MAC vs. f asociado al algoritmo de AFDD-T es una herramienta práctica y eficaz para caracterizar la calidad del arreglo de sensores. En la sección 6.2 este es usado para mostrar el efecto sobre la Identificación de la baja cantidad de sensores, pero en [1] también se utiliza para mostrar el efecto de una mala distribución de los mismos. En principio, durante la campaña preliminar de monitoreo, será ventajoso estudiar el sistema de monitoreo desde la perspectiva de este gráfico.

Sobre los modelos de frecuencia entrenados

Como se expone en la revisión bibliográfica (ver Sección 2.2), y también como es comprobado en este trabajo (ver Sección 5.2), el comportamiento estacional de los modos físicos es fuertemente explicado por la temperatura. Adicionalmente, la dirección solar (cénit y asimut solar) prueba mejorar sustancialmente el ajuste de los modelos, aun cuando la metodología de PLS para distinguir variables significativas indique que esta es irrelevante para la frecuencia modal. Esto constituye un indicio, se concluye, de que la relación entre la frecuencia y la dirección solar es altamente no lineal. La razón para haber decidido evaluar la significancia de esta variable y luego haberla incorporado al modelo se debe, como se ha mencionado en este trabajo (ver Sección 5.2), a que la relación entre ambas tiene una explicación física, lo que es verificado estadísticamente por un análisis posterior al de PLS. Aun así, PLS prueba ser una excelente herramienta para detectar variables significativas de entre un grupo grande de candidatos. En tanto método de análisis preliminar al entrenamiento de los modelos, debe entenderse como un criterio simple y robusto de limpiar de regresores insignificantes el fenómeno a modelar.

Sobre las variables significativas, queda la tarea pendiente de incorporar el efecto de la lluvia sobre la frecuencia modal. Como ya se comentó en la Sección 5.2, este efecto ocurre en determinados momentos del año (cuando ocurre la lluvia), pero este, cuando ocurre, es dominante sobre la influencia de todas las otras variables. En este trabajo se caracteriza la lluvia a partir de eventos de precipitación, separados entre sí si entre ellos hay un día o más sin precipitación registrada; esto con el único fin de aislar el efecto de cada evento sobre la frecuencia y no de modelar el efecto en sí mismo. Para esto último, la primera tarea será determinar la

variable que mejor describa la *lluvia relevante*, *i.e.* una variable derivada de la precipitación medida y que acuse significancia estadística para la frecuencia. Si el objetivo es, por ejemplo, caracterizar el comportamiento normal del sistema, o bien mejorar el ajuste de los modelos estadísticos, la incorporación de la lluvia será una contribución importante a la metodología.

En este trabajo se entrenan modelos considerados simples dentro de sus propios ámbitos. Incluso el modelo MLP, el más complejo escogido, es el más simple de los modelos ANN (redes neuronales). La razón de esto es que, a pesar de los indicios de que la frecuencia se ve influenciada de su historia pasada, no se pudo resolver cómo incorporar la historia de la frecuencia al modelo (incorporar una componente autorregresiva a este). La frecuencia modal tiene la peculiaridad de ser una señal discontinua en el tiempo: no siempre es medida y, por lo tanto, existen vacíos que deben ser tratados de alguna forma. Entonces, sobre los modelos predictivos de la frecuencia, queda la tarea pendiente de buscar aquellos que puedan proveer un mejor ajuste dadas las características de la señal descritas antes. Especialmente para redes neuronales, quedan modelos más robustos que el MLP por implementar, como el RNN (*Recursive Neural Networks*) y el LSTM (*Long-Short Term Memory*), ambas soluciones al modelamiento de señales dependientes de sus valores previos en el ámbito del *deep learning*.

También se hace notar que aún quedan medidas pendientes por tomar para mejorar el ajuste de los modelos entrenados. En primer lugar, en este trabajo no se evalúa si los datos de entrenamiento son una representación uniforme de todas las etapas del fenómeno, por lo que podría ocurrir que unos estados queden más representados que otros y la regresión tienda a ajustarse a estos por sobre los demás. En segundo lugar, los modelos no tienen incorporada la *ciclicidad* del fenómeno de ninguna manera. Siendo que las mediciones durante el mes de diciembre describen un estado homólogo a las del mes de enero, en el tratamiento de los datos esta información no es considerada de ninguna manera. Finalmente, en este trabajo no se prueban modelos que ajusten separadamente el fenómeno estacional (la tendencia anual) con el fenómeno diario, aspecto que podría fortalecer considerablemente el ajuste del modelo.

Sobre los modelos ARX entrenados, existen posibles rumbos que tomar para evitar su divergencia, dados los indicios mostrados en las Secciones 5.5 y 7.5. En primer lugar, puede optarse por normalizar las variables de entrada y salida, como se hace para el análisis de significancia por PLS (ver Sección 5.2), o también transformando el espacio al normal estándar. En segundo lugar, si después de la normalización aún existieran parámetros de módulo superior a la unidad, se debiera optar por resolver el problema de minimización del error cuadrático medio (de donde proviene la solución de mínimos cuadrados por la que se obtienen usualmente los parámetros), instaurando la restricción mencionada al módulo de cada parámetro.

Sobre el seguimiento modal realizado

El mayor inconveniente al que se enfrenta la metodología de seguimiento modal evaluada en este trabajo es la mala trazabilidad de la forma modal. Como se ha mostrado en este trabajo, aparentemente la forma modal es insensible a episodios de daño (ver Sección 6.4) y a variaciones cotidianas de factores ambientales (ver Sección 7.8), lo que en principio justifica

la elección de una única forma modal de referencia y que esta no sea actualizada en el tiempo.

A pesar de lo anterior, el descarte manual de canales sí parece generar una disimilitud abrupta con la referencia escogida. Si bien el descarte de canales se justifica en la idea de que los canales contaminados con ruido empeoran la estimación de los parámetros modales (mejora la identificación), dados los resultados vistos en la Sección 7.8, se pone en duda si esto compensa la pérdida de trazabilidad del modo al perder una dimensión del estimador de la forma modal (empeora el seguimiento). Queda como tarea pendiente evaluar su efecto en el monitoreo automático del sistema, más allá de la identificación de este.

El seguimiento modal cuando es auxiliado por modelos como los entrenados en este trabajo, que requieren de mediciones de las variables ambientales, es mucho más exigente en recursos que, por ejemplo, la aproximación por AFDD-T o seguimiento asociativo del problema. Para el entrenamiento de los modelos es necesario medir las variables meteorológicas en tiempo real (contar con sensores de, al menos, temperatura en la estructura), no siempre siendo esto posible. Sin embargo, una posible alternativa, si no se contara con estas mediciones, sería construir modelos de frecuencia en función de la dirección solar. Esta última puede ser deducida a partir de ecuaciones basadas exclusivamente en la geometría del movimiento de la tierra respecto al sol. Esta perspectiva escapa al alcance de este trabajo y por ello no es evaluada, quedando como una tarea pendiente la caracterización de la relación entre la frecuencia y la dirección solar exclusivamente. Incluso si presentase un peor ajuste que modelos con la temperatura como regresor, hay que tener en cuenta que la exigencia sobre el sistema de monitoreo es mucho menor respecto a los modelos que incorporan la temperatura.

Bibliografía

- [1] C. Rainieri, G. Fabbrocino, and E. Cosenza. Near real-time tracking of dynamic properties for standalone structural health monitoring systems. *Mechanical Systems and Signal Processing*, 25(8):3010–3026, 2011.
- [2] J. & De Roeck G. Reynders, E. & Houbrechts. Fully automated (operational) modal analysis. *Mechanical Systems and Signal Processing*, 29:228–250, 2012.
- [3] J. Bilbao Nieva. Interpretacion automatica de diagramas de estabilizacion, 2014. Disponible en <http://www.repositorio.uchile.cl/handle/2250/130414>.
- [4] L. & Andersen P. Brincker, R. & Zhang. Modal identification of output-only systems using frequency domain decomposition. *Smart materials and structures*, 10(3):441, 2001.
- [5] G. Reynders, E. & De Roeck. Reference-based combined deterministicstochastic subspace identification for experimental and operational modal analysis. *Mechanical Systems and Signal Processing*, 22(3):617–637, 2008.
- [6] B. Peeters and G. De Roeck. One-year monitoring of the z 24-bridge: environmental effects versus damage events. *Earthquake engineering & structural dynamics*, 30(2): 149–171, 2001.
- [7] R. Boroschek, F. Tamayo, and R. Aguilar. Evaluation of the environmental effects on a medium rise building. *EWSHM-7th European Workshop on Structural Health Monitoring*, 2014.
- [8] Magalhães F. Caetano E. & Cunha A. Amador, S. Analysis of the influence of environmental factors on modal properties of the braga stadium suspension roof. *Proceedings of EVACES.*, 2011.
- [9] Cunha A. & Caetano E. Magalhães, F. Vibration based structural health monitoring of an arch bridge: from automated oma to damage detection. *Mechanical Systems and Signal Processing*, 28:212–228, 2012.
- [10] J. P. Santos, C. Crémona, L. Calado, P. Silveira, and A. D. Orcesi. Online unsupervised detection of early damage. *Structural Control and Health Monitoring*, 2015.
- [11] G. De Boe P. & Golinval J. C. Yan, A. M. & Kerschen. Structural damage diagnosis under varying environmental conditionspart i: a linear analysis. *Mechanical Systems and Signal Processing*, 19(4):847–864, 2005.

- [12] S. De Jong. Simpls: an alternative approach to partial least squares regression. *Chemo-metrics and intelligent laboratory systems*, 18(3):251–263, 1993.
- [13] F. Tamayo Vasquez. Metodos de extraccion de efectos ambientales en procesos de identificacion de sistemas, 2014. Disponible en <http://www.repositorio.uchile.cl/handle/2250/117122>.
- [14] J. Basoalto Albornoz. Analisis del efecto de las condiciones ambientales en las propiedades modales de un edificio de hormigon armado, 2013. Disponible en <http://www.repositorio.uchile.cl/handle/2250/115257>.
- [15] A. & Caetano E. Magalhaes, F. & Cunha. Online automatic identification of the modal parameters of a long span arch bridge. *Mechanical Systems and Signal Processing*, 23(2):316–329, 2009.
- [16] Kohei Ohtsu, Hui Peng, and Genshiro Kitagawa. *Time Series Modeling for Analysis and Control. Advanced Autopilot and Monitoring Systems*. Springer Japan, first edition, 2015.
- [17] B Peeters. *System identification and damage detection in civil engeneering*. PhD thesis, Katholieke Universiteit Leuven, 2000.
- [18] Robert H. Shumway and David S. Stoffer. *Time Series Analysis and Its Applications With R Examples*. Springer-Verlag New York, third edition, 2011.
- [19] Y. Zhu. Estimation of nonlinear arx models. *Decision and Control, 2002, Proceedings of the 41st IEEE Conference*, 2:2214–2219, 2002.
- [20] Ben Krose and Patrick van der Smagt. *An Introduction to Neural Networks*. University of Amsterdam, eighth edition, 1996.
- [21] C. Rainieri. *Operational Modal Analysis for seismic protection of structures*. PhD thesis, Università degli Studi di Napoli Federico II, 2008.
- [22] A. Cabboi, F. Magalhães, C. Gentile, and Á. Cunha. Automated modal identification and tracking: Application to an iron arch bridge. *Structural Control and Health Monitoring*, 2016.
- [23] J. J. Michalsky. The astronomical almanac’s algorithm for approximate solar position (1950 to 2050). *Solar energy*, 40(3):227–235, 1988.
- [24] P. León Alfaro. Variación de propiedades dinámicas de la torre central debido a factores sísmicos, 2013. Disponible en <http://www.repositorio.uchile.cl/handle/2250/113430>.
- [25] H. P. & Sander J. & Xu X. Ester, M. & Kriegel. A density-based algorithm for discovering clusters in large spatial databases with noise. *Kdd*, 96(34):226–231, aug 1996.
- [26] M. M. & Kriegel H. P. & Sander J. Ankerst, M. & Breunig. Optics: ordering points to identify the clustering structure. *ACM Sigmod record*, 28(2):49–60, 1999.
- [27] G. Verdugo Varoli. Estudio del efecto de los cambios de humedad del suelo en la frecuencia natural de una estructura, 2009. Disponible en <http://www.repositorio.uchile.cl/handle/2250/103426>.

Apéndice A

Limpieza Manual de Canales

En [Tab. A.1] se muestran los canales eliminados y el período en que fueron descartados. Este descarte está basado en el criterio usado en [3]. En este, dadas ventanas grandes de tiempo (meses), se descartan aquellos registros cuyo *RMS* sea anómalo (muy grande respecto a períodos anteriores o respecto a los otros registros en el mismo período). Esto se verifica comparando los niveles de ruido en la Identificación antes y después de haber eliminado este canal.

Inicio	Fin	Canal Eliminado
1 de marzo de 2010	31 de julio de 2011	E4
1 de julio de 2012	31 de enero de 2013	E5

Tabla A.1: Descarte Manual de Canales.

En [Fig. A.1] a [Fig. A.4] se muestra el valor *RMS* del registro de cada canal a lo largo de los años 2010 a 2013.




Figura A.1: *RMS* de registros para el año 2010.




Figura A.2: *RMS* de registros para el año 2011.




Figura A.3: *RMS* de registros para el año 2012.




Figura A.4: *RMS* de registros para el año 2013.

En [Fig. A.5] y [Fig. A.6] se muestra el efecto en la Identificación de la eliminación de los canales E4 y E5, respectivamente, en los períodos de tiempo indicados en [Tab. A.1].




Figura A.5: Eliminación manual de canal E4.





Figura A.6: Eliminación manual de canal E5.

Apéndice B

Parámetros para *Clustering* por OPTICS de Identificación

Partición	Inicio	Fin	<i>MinPts</i>
1	07-04-2009	27-04-2009	125
2	27-04-2009	26-06-2009	125
3	26-06-2009	17-07-2009	140
4	17-07-2009	11-08-2009	125
5	11-08-2009	01-09-2009	125
6	01-09-2009	26-09-2009	125
7	26-09-2009	17-10-2009	125
8	17-10-2009	11-11-2009	170
9	11-11-2009	02-12-2009	170
10	02-12-2009	24-12-2009	195
11	24-12-2009	13-01-2009	195
12	14-01-2010	04-02-2010	195
13	04-02-2010	25-02-2010	195
14	27-02-2010	23-03-2010	125
15	23-03-2010	14-04-2010	125
16	14-04-2010	05-05-2010	125

Partición	Inicio	Fin	<i>MinPts</i>
17	05-05-2010	26-05-2010	125
18	26-05-2010	16-06-2010	80
19	16-06-2010	07-07-2010	110
20	07-07-2010	29-07-2010	180
21	29-07-2010	19-08-2010	130
22	19-08-2010	10-09-2010	150
23	10-09-2010	01-10-2010	120
24	01-10-2010	23-10-2010	120
25	23-10-2010	12-11-2010	120
26	12-11-2010	03-12-2010	120
27	03-12-2010	24-12-2010	120
28	24-12-2010	18-01-2011	120
29	18-01-2011	05-04-2011	120
30	05-04-2011	30-04-2011	80
31	30-04-2011	22-05-2011	120
32	22-05-2011	14-06-2011	120
33	14-06-2011	07-07-2011	120
34	07-07-2011	29-07-2011	120
35	29-07-2011	22-08-2011	120
36	22-08-2011	13-09-2011	120
37	13-09-2011	04-10-2011	120
38	04-10-2011	25-10-2011	120
39	25-10-2011	15-11-2011	120
40	15-11-2011	08-12-2011	120
41	08-12-2011	29-12-2011	120
42	29-12-2011	19-01-2012	120

Partición	Inicio	Fin	<i>MinPts</i>
43	19-01-2012	09-02-2012	120
44	09-02-2012	05-03-2012	120
45	05-03-2012	03-04-2012	80
46	03-03-2012	24-02-2012	70
47	24-04-2012	17-05-2012	80
48	17-05-2012	07-06-2012	70
49	07-06-2012	28-06-2012	80
50	28-06-2012	22-07-2012	80
51	22-07-2012	12-08-2012	80
52	12-08-2012	07-09-2012	80
53	07-09-2012	29-09-2012	70
54	29-09-2012	21-10-2012	45
55	21-10-2012	11-11-2012	80
56	11-11-2012	03-12-2012	55
57	03-12-2012	24-12-2012	50
58	24-12-2012	15-01-2013	50
59	15-01-2013	08-02-2013	55
60	08-02-2013	02-03-2013	45
61	02-03-2013	23-03-2013	20
62	23-03-2013	14-04-2013	15
63	14-04-2013	06-05-2013	15
64	06-05-2013	28-05-2013	20
65	28-50-2013	20-06-2013	20
66	20-06-2013	12-07-2013	5
67	12-07-2013	03-08-2013	45
68	03-08-2013	25-08-2013	30

Partición	Inicio	Fin	<i>MinPts</i>
69	25-08-2013	18-09-2013	45
70	18-09-20113	10-10-2013	60
71	10-10-2013	01-11-2013	60
72	01-11-2013	23-11-2013	50
73	23-11-2013	15-12-2013	50
74	15-12-2013	06-01-2014	50
75	06-01-2014	07-02-2014	50
76	07-02-2014	04-03-2014	50
77	04-03-2014	02-04-2014	45
78	02-04-2014	27-04-2014	35
79	27-04-2014	20-05-2014	20
80	21-05-2014	13-06-2014	10
81	13-06-2014	05-07-2014	30
82	05-07-2014	04-08-2014	70
83	04-08-2014	28-08-2014	45
84	28-08-2014	21-09-2014	50
85	21-09-2014	14-10-2014	55
86	14-10-2014	13-11-2014	45
87	13-11-2014	05-12-2014	30
88	05-12-2014	27-12-2014	65
89	27-12-2014	17-01-2015	65
90	17-01-2015	07-02-2015	45
91	08-02-2015	01-03-2015	25
92	01-03-2015	22-03-2015	15
93	22-03-2015	13-04-2015	10
94	13-04-2015	05-05-2015	15

Partición	Inicio	Fin	<i>MinPts</i>
95	05-05-2015	26-05-2015	15
96	26-05-2015	17-06-2015	20
97	17-06-2015	08-07-2015	20
98	08-07-2015	07-08-2015	15
99	07-08-2015	28-08-2015	15
100	28-08-2015	19-09-2015	10
101	19-09-2015	13-10-2015	20
102	13-10-2015	04-11-2015	30
103	04-11-2015	30-11-2015	25
104	30-11-2015	21-12-2015	25
105	21-12-2015	12-01-2016	25
106	12-01-2016	05-02-2016	25
107	05-02-2016	26-02-2016	25
108	26-02-2016	18-03-2016	35
109	18-03-2016	08-04-2016	25
110	08-04-2016	29-04-2016	20
111	29-04-2016	26-05-2016	30
112	26-05-2016	16-06-2016	30
113	16-06-2016	07-07-2016	45
114	07-07-2016	28-07-2016	35
115	28-07-2016	18-08-2016	40
116	18-08-2016	08-09-2016	10
117	08-09-2016	08-09-2016	20
118	29-09-2016	24-10-2016	45
119	24-10-2016	15-11-2016	45
120	15-11-2016	06-12-2016	70

Partición	Inicio	Fin	<i>MinPts</i>
121	06-12-2016	27-12-2016	50

Tabla B.1: Parámetros de OPTICS usados en limpieza de Identificación.

Apéndice C

Parámetros para *Clustering* por DBSCAN en Preprocesamiento de Datos de Entrenamiento de Modelos

Parámetros de DBSCAN		
Modo	MinPts	Eps
Primero	2000	0.03
Segundo	2000	0.03
Tercero	2000	0.03
Cuarto	1250	0.03
Quinto	1250	0.03
Sexto	1250	0.03
Séptimo	1250	0.03
Octavo	1250	0.03
Noveno	1000	0.03

Tabla C.1: Parámetros de DBSCAN para preprocesamiento de frecuencias.