

ESCUELA POLITÉCNICA NACIONAL

FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

EVALUACIÓN PREDICTIVA DE ESTABILIDAD TRANSITORIA EN TIEMPO REAL MEDIANTE APRENDIZAJE AUTOMÁTICO Y LA IDENTIFICACIÓN DE PATRONES DEL MÁXIMO EXPONENTE DE LYAPUNOV

TRABAJO DE TITULACIÓN PREVIO A LA OBTENCIÓN DEL TÍTULO DE MAGISTER EN ELECTRICIDAD MENCIÓN REDES ELÉCTRICAS INTELIGENTES

ING. ESTEBAN SEBASTIÁN VACA BARRAGÁN

DIRECTOR: DR.-ING. JAIME CRISTÓBAL CEPEDA CAMPAÑA

CODIRECTOR: DR.-ING. PAÚL FABRICIO VÁSQUEZ MIRANDA

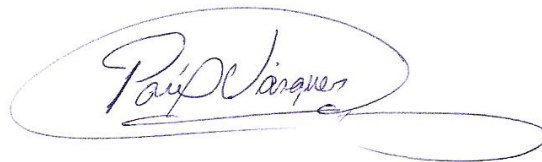
Quito, febrero 2023

AVAL

Certificamos que el presente trabajo fue desarrollado por Esteban Sebastián Vaca Barragán, bajo nuestra supervisión.



DR.-ING. JAIME CRISTÓBAL CEPEDA CAMPAÑA
DIRECTOR DEL TRABAJO DE TITULACIÓN



DR.-ING. PAÚL FABRICIO VÁSQUEZ MIRANDA
CODIRECTOR DEL TRABAJO DE TITULACIÓN

DECLARACIÓN DE AUTORÍA

Yo, Esteban Sebastián Vaca Barragán, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentado para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento.

A través de la presente declaración dejo constancia de que la Escuela Politécnica Nacional podrá hacer uso del presente trabajo según los términos estipulados en la Ley, Reglamentos y Normas vigentes.



Esteban Sebastián Vaca Barragán

DEDICATORIA

En la vida ni se gana ni se pierde,

ni se fracasa

ni se triunfa.

En la vida se aprende,

se crece,

se descubre;

se escribe,

se borra y

se reescribe otra vez;

se hila,

se deshila y

se vuelve a hilar.

Un día comprendí

que el fin de un viaje

es solo el inicio de otro,

y que lo único que me voy a llevar

es lo que vivo. Así empecé a

vivir lo que me quiero llevar.

¡Dedicado a todas aquellas personas que hacen mágica mi vida!

AGRADECIMIENTO

A mi familia, por ser el motor de mi vida y motivarme cada día a ser mejor.

A aquellos maestros de la Escuela Politécnica Nacional, quienes hicieron de mí un estudiante diferente...

*A Jaime Cepeda, quien siempre debate mis deducciones y alienta en mí un espíritu investigador.
Su amistad y ejemplo por seguir valoraré siempre.*

A todos mis amigos, quienes han sido un apoyo esencial para hacerme entender que ¡sí puedo!

¡Gracias de todo corazón!

ÍNDICE DE CONTENIDO

AVAL	I
DECLARACIÓN DE AUTORÍA.....	II
DEDICATORIA.....	III
AGRADECIMIENTO.....	IV
ÍNDICE DE CONTENIDO.....	V
RESUMEN	X
ABSTRACT	XI
1. INTRODUCCIÓN.....	1
1.1. Pregunta de investigación.....	3
1.2. Objetivo General	3
1.3. Objetivos Específicos.....	3
1.4. Alcance	4
2. MARCO TEÓRICO	5
2.1. Estabilidad de Sistemas Eléctricos de Potencia	5
2.1.1. Clasificación de la Estabilidad de Sistemas Eléctricos de Potencia	5
2.1.1.1. Estabilidad de Ángulo	6
2.1.1.2. Estabilidad de Frecuencia	9
2.1.1.3. Estabilidad de Voltaje	9
2.1.2. Análisis de Estabilidad Transitoria	9
2.1.2.1. Simulaciones en el Dominio del Tiempo	10
2.1.2.2. Métodos del Plano de Fase	10
2.1.2.3. Funciones de Lyapunov.....	10
2.1.2.4. Criterio de Igualdad de Áreas	11
2.1.2.5. Criterio de Igualdad de Áreas Extendido.....	11
2.1.2.6. Método SIME.....	11
2.1.2.7. Enfoques de Aprendizaje Automático	12
2.1.2.8. Exponentes de Lyapunov	12
2.2. Funcionalidad del esquema WAMPAC para el desarrollo de aplicaciones de Evaluación de Vulnerabilidad Dinámica	13
2.2.1. Evaluación de la Vulnerabilidad Dinámica de SEP	13
2.2.1.1. Vulnerabilidad de un SEP	13
2.2.1.2. Evaluación de Vulnerabilidad.....	14
2.2.1.3. Planteamientos de Evaluación de Vulnerabilidad Dinámica.....	18
2.2.1.4. Aplicaciones de la Evaluación de Vulnerabilidad Dinámica	20
2.2.2. Sistemas de Medición de Área Extendida.....	20

2.2.2.1.	Tecnología de Medición Sincrofasorial	21
2.2.2.2.	Aplicaciones del WAMS.....	22
2.2.3.	Esquema funcional del WAMPAC para desarrollar DVA.....	23
2.2.3.1.	Retardo de tiempo del WAMPAC.....	24
2.2.3.2.	Arquitectura de comunicaciones del WAMPAC	25
2.2.4.	Experiencias del WAMPAC	25
2.3.	Estabilidad y Exponentes de Lyapunov	28
2.3.1.	Definición analítica de los Exponentes de Lyapunov	29
2.3.2.	Nuevas perspectivas de análisis.....	30
2.3.3.	Formulación matemática del LLE para series de tiempo.....	31
2.3.3.1.	Teorema de Oseledec y primera estimación del LLE.....	31
2.3.3.2.	Ventana de Theiler y trayectorias contiguas	32
2.3.3.3.	Teorema de Takens y simplificación del cálculo	33
2.3.3.4.	Métodos de estimación de la pendiente expresada como LLE	34
2.3.4.	Perspectivas de aplicación del LLE	36
2.4.	Minería de Datos.....	37
2.4.1.	Generación de datos mediante el Método de Montecarlo	37
2.4.2.	Técnicas de Minería de Datos	38
2.4.2.1.	Análisis Exploratorio de Datos	38
2.4.2.2.	Ingeniería de Características	39
2.4.2.3.	Reducción de dimensionalidad y simplificación de modelos	40
2.4.2.4.	Visualización de datos.....	42
2.5.	Aprendizaje Automático	45
2.5.1.1.	Modelos de Aprendizaje Automático.....	45
2.5.1.2.	Algoritmos de Aprendizaje Automático	47
2.5.1.3.	K-fold cross-validation	53
2.5.1.4.	Métricas de calidad.....	53
2.5.1.5.	Optimización bayesiana de hiperparámetros	54
3.	METODOLOGÍA DE EVALUACIÓN PREDICTIVA DE ESTABILIDAD	
	TRANSITORIA	57
3.1.	Descripción general de la metodología propuesta	57
3.2.	Generación o Adquisición de datos	58
3.2.1.	Simulación en el dominio del tiempo.....	59
3.2.2.	Estimación del Máximo Exponente de Lyapunov.....	60
3.2.3.	Preparación y estructura de datos de Montecarlo.....	62
3.3.	Análisis Exploratorio de Datos	64

3.4.	Aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria.....	67
3.4.1.	Evolución dinámica del LLE.....	68
3.4.2.	Análisis de la magnitud del LLE.....	70
3.4.3.	Relación entre el LLE y la Estabilidad Transitoria.....	72
3.4.4.	Número de muestras de análisis del LLE.....	75
3.4.5.	Análisis del LLE en un sistema multimáquina.....	79
3.5.	Minería de datos del Máximo Exponente de Lyapunov.....	82
3.5.1.	Funciones Empíricas Ortogonales.....	83
3.5.2.	Ingeniería de Características.....	85
3.5.3.	Visualización de Datos.....	87
3.5.3.1.	Visualización de Coordenadas Paralelas.....	87
3.5.3.2.	Visualización de las Curvas de Andrews.....	88
3.5.3.3.	Visualización Multidimensional del Algoritmo de RadViz.....	90
3.5.4.	Equilibrio de Clases.....	91
3.5.5.	Correlación de Información.....	94
3.5.6.	Comparación entre las EOF del LLE y las EOF del ángulo del rotor.....	95
3.6.	Conclusiones de la aplicación del LLE y del uso de Minería de Datos.....	95
3.7.	Evaluación Predictiva de Estabilidad Transitoria.....	96
3.7.1.	Datos de entrada.....	97
3.7.1.1.	Enfoques de evaluación.....	97
3.7.1.2.	Información suplementaria.....	98
3.7.1.3.	Tratamiento de datos.....	99
3.7.1.4.	División del conjunto de datos en entrenamiento y prueba.....	99
3.7.2.	Resultados de Evaluación Predictiva.....	100
3.8.	Análisis de desempeño de algoritmos de Aprendizaje Automático....	103
3.8.1.	Comparación entre algoritmos de clasificación.....	103
3.8.2.	Optimización Bayesiana de hiperparámetros.....	104
3.9.	Resumen de la metodología.....	111
4.	RESULTADOS Y DISCUSIÓN.....	113
4.1.	Análisis Exploratorio de Datos.....	114
4.2.	Aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria.....	119
4.2.1.	Evolución dinámica del LLE.....	119
4.2.2.	Número de muestras de análisis del LLE.....	121
4.2.3.	Análisis del LLE en el sistema IEEE 39-Bus System.....	124

4.3.	Minería de Datos.....	127
4.3.1.	Funciones Empíricas Ortogonales.....	127
4.3.2.	Ingeniería de Características.....	130
4.3.3.	Visualización de Datos.....	130
4.3.3.1.	Visualización de Coordenadas Paralelas.....	130
4.3.3.2.	Visualización de las Curvas de Andrews.....	131
4.3.3.3.	Visualización Multidimensional del Algoritmo de RadViz.....	132
4.3.4.	Equilibrio de Clases.....	134
4.3.5.	Correlación de Información.....	135
4.4.	Evaluación Predictiva de Estabilidad Transitoria.....	135
4.5.	Análisis del desempeño de algoritmos de Aprendizaje Automático ...	139
4.5.1.	Comparación entre algoritmos de clasificación.....	139
4.5.2.	Optimización Bayesiana de hiperparámetros.....	140
4.6.	Discusión.....	146
4.6.1.	Análisis Exploratorio de Datos.....	147
4.6.2.	Aplicación del Máximo Exponente de Lyapunov.....	148
4.6.3.	Minería de Datos.....	149
4.6.4.	Evaluación Predictiva de Estabilidad Transitoria.....	151
4.6.5.	Análisis del desempeño de algoritmos de Aprendizaje Automático.....	153
5.	CONCLUSIONES Y RECOMENDACIONES.....	156
5.1.	Conclusiones.....	156
5.2.	Recomendaciones.....	158
5.3.	Trabajos Futuros.....	159
6.	REFERENCIAS BIBLIOGRÁFICAS.....	161
7.	ANEXOS.....	169
ANEXO A.	EJEMPLO DE APLICACIÓN DEL MÁXIMO EXPONENTE DE LYAPUNOV A-1	
ANEXO B.	DATOS DE LOS SISTEMAS DE PRUEBA.....	B-1
ANEXO C.	CURVAS DE DEMANDA DIARIA.....	C-1
ANEXO D.	MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM.....	D-1
ANEXO E.	RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM.....	E-1
ANEXO F.	MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM.....	F-1

ANEXO G. MÉTRICAS DE EVALUACIÓN PREDICTIVA – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM.....	G-1
ANEXO H. RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM.....	H-1

RESUMEN

Durante el desarrollo actual de las Redes Eléctricas Inteligentes (REI) ha crecido el interés por desplegar metodologías que permitan evaluar en tiempo real, con rapidez y precisión, la vulnerabilidad del Sistema Eléctrico de Potencia (SEP) frente a diversos fenómenos críticos, entre ellos, los problemas de Estabilidad Transitoria. Esto con el fin de definir estrategias de control y protección inteligentes para la mitigación oportuna de perturbaciones y la mejora de la operación de los SEP. En este trabajo se desarrolla una metodología para la Evaluación Predictiva de Estabilidad Transitoria de SEP en tiempo real; mediante el uso de herramientas matemáticas y computacionales novedosas. Se considera la aplicación de técnicas de Minería de Datos para la identificación de patrones del Máximo Exponente de Lyapunov (LLE, por sus siglas en inglés), el cual se constituye como un indicador de la estabilidad del SEP poscontingencia. La estimación del LLE propuesta es robusta al ser independiente del modelo analítico del sistema. Además, se plantea el uso de algoritmos de Aprendizaje Automático para la evaluación predictiva basada en los patrones identificados y para la determinación de modelos óptimos adaptados a sistemas en particular. La metodología propuesta es validada en el sistema de prueba IEEE 39-Bus System, en donde se demuestra su aplicabilidad con prestaciones de rapidez, precisión y flexibilidad. De este modo, la metodología se muestra como una contribución innovadora que plantea mejoras a investigaciones recientes, solucionando limitantes, garantizando así mejores resultados, y también exhibe la potencialidad de ser aplicada en el Sistema Nacional Interconectado (SNI) ecuatoriano para la ejecución de acciones de control y protección apropiadas.

PALABRAS CLAVE: Aprendizaje Automático, Estabilidad Transitoria, Máximo Exponente de Lyapunov, Minería de Datos, Redes Eléctricas Inteligentes.

ABSTRACT

During the current Smart Grids development stage, the interest in deploying methodologies to assess the real time Power System vulnerability has increased. Such methodologies should focus on evaluating the system condition, quickly and accurately towards critical phenomena, including Transient Stability issues. The aim is indeed to define intelligent control and protection strategies for timely mitigation of disturbances and the improvement of the Power System operation. In this work, a methodology for real time Transient Stability Predictive Assessment of Electric Power Systems, applying novel mathematical and computational tools, is developed. The application of Data Mining techniques is included for pattern recognition in the Largest Lyapunov Exponent (LLE), which is used as an indicator of post-contingency stability. The proposed LLE estimation is robust since it is independent of the system's analytical model. In addition, the use of Machine Learning algorithms for predictive assessment, based on the identified patterns, is proposed; and the determination of optimal models, adapted to particular systems, is deployed. The proposed methodology is validated on the IEEE 39-Bus System, where its applicability is demonstrated with speed, precision, and flexibility features. In this way, the proposed methodology constitutes an innovative contribution since entails improvements to recent research, solves limitations while guarantees better results, and also exhibits the potential to be applied in the Ecuadorian National Interconnected System for the execution of appropriate control and protection actions.

KEYWORDS: Data Mining, Largest Lyapunov Exponent, Machine Learning, Smart Grids, Transient Stability.

1. INTRODUCCIÓN

Los esquemas de Monitoreo, Control y Protección de Área Extendida (WAMPAC, por sus siglas en inglés) de los Sistemas Eléctricos de Potencia (SEP) permiten atenuar el impacto de la ocurrencia de diferentes tipos de perturbaciones; al facilitar, en lo posible, la continuidad del funcionamiento normal de los SEP, la minimización de la extensión y duración de eventos o la prevención de colapsos. En el contexto de las Redes Eléctricas Inteligentes (REI) y el desarrollo de los WAMPAC, se han propuesto enfoques modernos de control y protección que se ajustan dependiendo del progreso en tiempo real de los eventos del sistema [1]. Esto, asociado con estrategias de protección inteligentes para la mitigación oportuna de perturbaciones, permite una mejora de la seguridad del suministro de energía eléctrica en los SEP. A fin de permitir el funcionamiento adecuado de estos esquemas, se requiere de la provisión temprana y confiable de información que posibilite detectar en tiempo real el estado de vulnerabilidad de un sistema y la necesidad de tomar acciones de control apropiadas.

Con respecto al problema de Estabilidad Transitoria, recientes investigaciones han mostrado la potencialidad de la tecnología de medición sincrofasorial, y del uso de herramientas computacionales y matemáticas modernas, para evaluar la vulnerabilidad del sistema frente a este tipo de estabilidad. Comúnmente, para esta evaluación, se han planteado metodologías que consideran la identificación de patrones obtenidos de mediciones del sistema. No obstante, el planteamiento de estas propuestas sigue siendo un campo de investigación abierto y desafiante, considerando que la identificación temprana y precisa de patrones es complicada por la constante variabilidad de los SEP, la complejidad de su dinámica y la multiplicidad de interacciones. En este sentido, las REI ha incrementado el interés por desarrollar metodologías que permitan evaluar en tiempo real, con rapidez y precisión, la vulnerabilidad relacionada con problemas de Estabilidad Transitoria.

Entre las investigaciones relacionadas, se presentan novedosas propuestas para la evaluación de Estabilidad Transitoria en tiempos reducidos y con niveles de precisión atractivos para su aplicabilidad en casos reales [1], [2]. Sin embargo, de manera general, estas investigaciones aún requieren ser mejoradas en varios aspectos. Por ejemplo, la identificación de señales adicionales que enriquezcan el análisis, la reducción de tiempos de evaluación, mejor selección u optimización de los algoritmos utilizados, entre otros aspectos, los cuales permitirían incrementar el nivel de confianza de la aplicación de estas

metodologías. Por otro lado, en investigaciones adicionales se ha identificado que las propuestas presentadas adolecen de varias restricciones y desventajas que dificultan, e inclusive imposibilitan, su aplicabilidad. Por ejemplo, se plantean metodologías basadas en el monitoreo del Máximo Exponente de Lyapunov que no son lo suficientemente precisas. Esto porque están basadas en hipótesis formuladas en sistemas simplificados, y no pueden ser extendidas con generalidad hacia sistemas complejos [3], [4], [5]. En otras metodologías, la evaluación de estabilidad no se consigue oportunamente, por lo que éstas no se encuentran lo suficientemente acondicionadas para la evaluación en tiempo real. Las propuestas de [5], [6], [7] logran identificar condiciones de estabilidad transitoria en tiempos mayores a 1 segundo, lo cual es inaceptable en los SEP actuales. En otros casos, se presentan planteamientos basados en el cómputo analítico de los Exponentes de Lyapunov y el modelo explícito del sistema, los cuales son altamente complejos de ser aplicados al considerar la magnitud de los SEP actuales [8], [9].

Con este antecedente, persiste la necesidad de desarrollar metodologías alternativas capaces de solventar las problemáticas mencionadas o proponer mejoras a las investigaciones que ya han mostrado planteamientos factibles. Al no contar con metodologías apropiadas para la evaluación predictiva de estabilidad, los SEP y sus sistemas WAMPAC no pueden contar con información necesaria para tomar acciones inteligentes de control correctivo frente a la ocurrencia de perturbaciones. Esto expone al SEP directamente a una condición de funcionamiento de alto riesgo, la cual es inaceptable desde una perspectiva técnica y económica, lo que limita el desarrollo de las REI.

En virtud de lo expresado, en el presente trabajo se propone una metodología para la Evaluación Predictiva de Estabilidad Transitoria de SEP en tiempo real que emplea herramientas de Aprendizaje Automático y técnicas de Minería de Datos para la identificación de patrones del Máximo Exponente de Lyapunov. La metodología proporciona resultados con características de rapidez, precisión y flexibilidad, adecuadas para brindar resultados en tiempo real, dentro del periodo de evolución de la estabilidad transitoria. Además, brinda la posibilidad de ser aplicado en esquemas WAMPAC de sistemas reales para el desarrollo de REI.

Este documento se organiza de la siguiente manera. En el Capítulo 2 se exponen los conceptos teóricos que sustentan el desarrollo del trabajo de titulación, con énfasis en la descripción de la Funcionalidad del esquema WAMPAC para el desarrollo de aplicaciones de Evaluación de la Vulnerabilidad Dinámica (DVA por sus siglas en inglés) y las definiciones principales de estabilidad y Exponentes de Lyapunov. Luego, en el Capítulo 3

se presenta la estructura de la metodología propuesta en este trabajo. Se incluye la explicación de la aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria en SEP, junto con el uso de las herramientas matemáticas de Minería de Datos y Aprendizaje Automático consideradas. Posteriormente, en el Capítulo 4 se exponen los resultados más relevantes de la aplicación de la metodología propuesta en el sistema de prueba IEEE 39-Bus System y una discusión de los hallazgos encontrados. Finalmente, en el Capítulo 5 se presentan las principales conclusiones y recomendaciones identificadas en este trabajo.

1.1. Pregunta de investigación

¿Cómo evaluar la Estabilidad Transitoria de un Sistema Eléctrico de Potencia usando mediciones, de forma predictiva, mediante Aprendizaje Automático y la identificación de patrones del Máximo Exponente de Lyapunov?

1.2. Objetivo General

Desarrollar una metodología para la Evaluación Predictiva de Estabilidad Transitoria de Sistemas Eléctricos de Potencia en tiempo real mediante Aprendizaje Automático y la identificación de patrones del Máximo Exponente de Lyapunov.

1.3. Objetivos Específicos

- Describir la funcionalidad del esquema de Monitoreo, Protección y Control de Área Extendida (WAMPAC) para el desarrollo de aplicaciones de Evaluación de la Vulnerabilidad Dinámica en tiempo real en Redes Eléctricas Inteligentes.
- Analizar la aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria en Sistemas Eléctricos de Potencia (SEP).
- Aplicar técnicas de Minería de Datos sobre señales del Máximo Exponente de Lyapunov obtenido de simulación de un SEP para identificar patrones que permitan la evaluación predictiva de Estabilidad Transitoria.
- Estructurar una metodología para evaluar predictivamente la Estabilidad Transitoria de un SEP mediante la identificación de patrones de señales del Máximo Exponente de Lyapunov.
- Examinar el desempeño de diferentes algoritmos de Aprendizaje Automático para la evaluación predictiva de Estabilidad Transitoria de un SEP.

1.4. Alcance

El trabajo de titulación contempla inicialmente la descripción de la funcionalidad de los Sistemas de Monitoreo, Protección y Control de Área Extendida (WAMPAC) para el desarrollo de aplicaciones de Evaluación de la Vulnerabilidad Dinámica en tiempo real en Redes Eléctricas Inteligentes.

Se desarrollará una revisión bibliográfica y análisis acerca de la aplicación del Máximo Exponente de Lyapunov (LLE) para el estudio de Estabilidad Transitoria en Sistemas Eléctricos de Potencia (SEP), sus características, ventajas y potencialidad de uso en aplicaciones en tiempo real.

Se revisarán distintas técnicas de Minería de Datos y su aplicación sobre señales del LLE obtenidas a partir de series de tiempo de un modelo de un SEP. En este modelo se considerará la generación de datos mediante Simulaciones de Montecarlo. Esto, con la finalidad de analizar patrones embebidos en el LLE e identificar información para evaluar, de manera predictiva, la Estabilidad Transitoria de un SEP.

Se estructurará una metodología basada en Aprendizaje Automático para evaluar predictivamente la Estabilidad Transitoria de un SEP mediante los resultados obtenidos de la Minería de Datos aplicada sobre señales del LLE. La metodología será expuesta a través de un modelo simulado de un SEP.

Finalmente, se propondrá la comparación del desempeño de diferentes algoritmos de Aprendizaje Automático para evaluar de manera predictiva la Estabilidad Transitoria de un SEP. Esta comparación se desarrollará en torno al análisis de métricas de calidad de los algoritmos considerados. Además, se considerará la optimización de hiperparámetros de los algoritmos, con la finalidad de encontrar aquellos más adecuados para el problema analizado.

El entorno computacional considerado para la simulación de Sistemas de Potencia será el programa PowerFactory de DlgSILENT. La implementación de los análisis de técnicas de Minería de Datos y algoritmos de Aprendizaje Automático considerará el lenguaje de Programación Python de código abierto.

2. MARCO TEÓRICO

El presente capítulo expone los conceptos básicos que sustentan el desarrollo de este trabajo de titulación. En primer lugar, se presenta el marco de la teoría de Estabilidad de SEP. Luego, se explica la Funcionalidad del esquema WAMPAC para el desarrollo de aplicaciones de DVA. Posteriormente, se describen los conceptos de la Estabilidad y Exponentes de Lyapunov. Finalmente, se explican las herramientas matemáticas de Minería de Datos y Aprendizaje Automático utilizadas en este trabajo.

2.1. Estabilidad de Sistemas Eléctricos de Potencia

La Estabilidad de los Sistemas Eléctricos de Potencia (SEP) ha sido reconocida desde el siglo XX como un problema prioritario en el contexto de operación segura de los sistemas. Han sido varios colapsos en la red, ocurridos a nivel mundial, y causados por eventos de inestabilidad, los que han ilustrado la importancia de este fenómeno [10]. Históricamente, la inestabilidad transitoria se constituyó como el fenómeno dominante en la mayoría de los casos y fue el centro de atención en muchos países. No obstante, a medida que los sistemas han evolucionado, han surgido diferentes tipos de inestabilidades. Por ejemplo, las relacionadas con estabilidad de voltaje, frecuencia y las oscilaciones en el sistema [11].

La estabilidad de un SEP, dada una condición inicial de operación, se define como la capacidad del sistema para alcanzar un estado de equilibrio operativo después de haber estado sujeto a una perturbación. Esto con la mayoría de las variables del sistema acotadas de modo que todo el sistema permanezca intacto. La estabilidad depende de la condición de operación inicial, así como de la naturaleza de la perturbación. De manera particular, un SEP se constituye como un sistema dinámico no lineal, que opera en un entorno lleno de perturbaciones. Estas se deben, por ejemplo: a la variación estocástica de las cargas, la entrada y salida de generación, maniobras operativas intencionales o contingencias.

Las perturbaciones en un SEP pueden ser categorizadas como pequeñas y grandes. Las pequeñas las constituyen, por ejemplo, los cambios de carga. Las grandes, por su parte, pueden deberse a cortocircuitos en líneas de transmisión o la pérdida significativa de generación. Una gran perturbación puede provocar cambios topológicos por la desconexión de elementos fallados. De todos modos, el SEP debe ser capaz de adaptarse a las condiciones cambiantes y operar satisfactoriamente posterior a las perturbaciones.

2.1.1. Clasificación de la Estabilidad de Sistemas Eléctricos de Potencia

La clasificación de la estabilidad de SEP se basa en las siguientes consideraciones :

- La naturaleza física del fenómeno de inestabilidad y la variable del sistema asociada en la que se puede observar esta inestabilidad con mayor repercusión.
- El tamaño de la perturbación considerada, el cual influye en los métodos matemáticos de análisis de la estabilidad.
- Los dispositivos, procesos y la ventana de tiempo de análisis que se debe tener en cuenta para evaluar la estabilidad.

Se debe notar que la creciente penetración de generación con interfaz de convertidores (CIG, por sus siglas en inglés), en combinación con la generación tradicional, conduce a nuevos tipos de problemas de estabilidad de SEP. Estos problemas surgen debido al diferente comportamiento dinámico de los CIG en comparación con los generadores sincrónicos convencionales. Los problemas de estabilidad surgen principalmente debido a las interacciones entre los controles CIG, la reducción de la inercia total en el SEP y la contribución limitada de corriente de cortocircuito de los CIG durante fallas. En la Figura 2.1 se observa la clasificación de la estabilidad de SEP [11], [12], [13], en donde se han añadido la estabilidad de Resonancia y la estabilidad de Converter-driven en el esquema clásico de estabilidad. A continuación, se describen las estabildades de ángulo, frecuencia y voltaje, por cuestiones de mayor atención en el país.

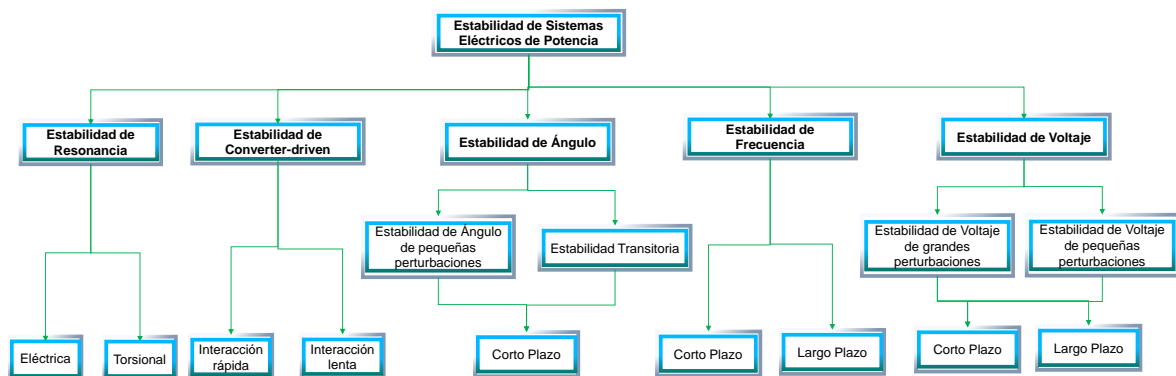


Figura 2.1. Clasificación de la Estabilidad de Sistemas Eléctricos de Potencia [13]

2.1.1.1. Estabilidad de Ángulo

La Estabilidad del Ángulo del rotor se refiere a la capacidad de las máquinas síncronas de un SEP para alcanzar y mantener una condición de sincronismo después de haber sido sometidas a una perturbación. Esto depende de la capacidad para mantener o restaurar el equilibrio entre el torque electromagnético y el torque mecánico de cada máquina síncrona del sistema. Esta inestabilidad se manifiesta en forma de una evolución dinámica creciente

(inclusive oscilatoria) del ángulo del rotor de algunos generadores que conduce a su pérdida de sincronismo con otros generadores.

De manera general, este problema de inestabilidad implica el estudio de las oscilaciones electromecánicas que existen de forma inherente en los SEP. Además, se estudia la forma en que la potencia eléctrica de las máquinas sincrónicas varía a medida que cambian los ángulos del rotor correspondientes.

Idealmente, frente a una condición de estado estacionario, debe existir un equilibrio entre el torque mecánico de entrada y el torque electromagnético de salida de cada generador. Esto permite que la velocidad permanezca constante y se sincronice entre todas las unidades de generación. Cuando se presenta una perturbación en el sistema, este equilibrio puede verse alterado, dando como resultado la aceleración o desaceleración de los rotores de las máquinas de acuerdo con las leyes de movimiento rotacional.

Si un generador funciona temporalmente más rápido que otro, la posición angular de su rotor en relación con la de la máquina más lenta avanzará. La diferencia angular resultante transfiere parte de la carga de la máquina lenta a la máquina rápida, según la relación potencia-ángulo de las máquinas. Esto tiende a reducir la diferencia de velocidad y por lo tanto la separación angular, manteniendo una condición de sincronismo. No obstante, se debe tener presente que la relación potencia-ángulo es altamente no lineal. En este contexto, existe cierto umbral, por sobre el cual, un aumento en la separación angular va acompañado de una disminución en la transferencia de potencia, de modo que la separación angular aumenta aún más. Para este caso, se produce inestabilidad si el sistema no puede absorber la energía cinética correspondiente a estas diferencias de velocidad del rotor.

El cambio en el torque electromagnético de una máquina sincrónica, después de una perturbación, se puede descomponer en dos componentes:

$$\Delta T_e = T_S \Delta \delta + T_D \Delta \omega \quad (2.1)$$

Donde el término $T_S \Delta \delta$ se denomina torque sincronizante, siendo T_S el coeficiente de torque sincronizante. El término $T_D \Delta \omega$ representa el torque de amortiguamiento, en el cual T_D es el coeficiente del torque de amortiguamiento [11]. La inestabilidad es el resultado de la deficiencia de uno o ambos componentes de torque. La falta de suficiente torque de sincronización da como resultado una inestabilidad aperiódica o no oscilatoria (estudiada como Estabilidad Transitoria de un SEP), mientras que la falta de torque de amortiguamiento da como resultado una inestabilidad de tipo oscilatoria.

2.1.1.1.1. *Estabilidad de pequeñas perturbaciones o de pequeña señal*

Este tipo de estabilidad considera la capacidad del SEP para mantener sincronismo frente a pequeñas perturbaciones. En este caso, se toman en cuenta perturbaciones que son lo suficientemente pequeñas como para permitir la linealización de las ecuaciones diferenciales del sistema alrededor de un punto de operación en particular [12].

Esta estabilidad depende de las condiciones operativas iniciales. La inestabilidad se puede manifestar de dos formas: como un aumento en el ángulo del rotor a través de un modo no oscilatorio o aperiódico debido a la falta de torque sincronizante, o de forma oscilatoria creciente debido a la falta de torque de amortiguamiento. En la actualidad, el problema aperiódico se ha eliminado en gran medida y lo más usual es que la presencia del fenómeno ocurra por la falta de amortiguamiento.

Por otro lado, se debe resaltar que los problemas de este tipo de estabilidad pueden ser locales o globales. Los problemas locales involucran una pequeña parte del SEP y generalmente están asociados con las oscilaciones del ángulo del rotor de una sola unidad o planta contra el resto del SEP. Los problemas globales son causados por interacciones entre grandes grupos de generadores o áreas del sistema.

Las ventanas de tiempo para el análisis de estabilidad de pequeña señal son del orden de 10 a 20 segundos después de una perturbación.

2.1.1.1.2. *Estabilidad Transitoria*

La estabilidad del ángulo del rotor ante grandes perturbaciones o Estabilidad Transitoria se relaciona con la capacidad del SEP para mantener el sincronismo cuando se somete a una perturbación grande. Los problemas de inestabilidad se manifiestan a través de variaciones excesivas en los ángulos de rotor de los generadores, las cuales están influenciadas por la relación no lineal de potencia y ángulo. Comúnmente, el ángulo de referencia usual para la determinación de inestabilidad transitoria es de 180 grados. Es decir, una incursión dinámica por encima de 180 grados en el ángulo del rotor es un indicativo de pérdida de estabilidad. No obstante, esta consideración idealizada cambia en sistemas multimáquina complejos, en donde la pérdida de estabilidad puede ocurrir mucho antes de que existan incursiones dinámicas angulares de 180 grados.

La Estabilidad Transitoria depende tanto de las condiciones iniciales del SEP, como de la severidad de la perturbación. La inestabilidad se presenta en forma de una separación angular aperiódica debido a un insuficiente torque sincronizante. Esto manifestado comúnmente como inestabilidad para la primera oscilación de la evolución dinámica del

ángulo del rotor. No obstante, en los SEP actuales, dada su complejidad, la inestabilidad transitoria no siempre puede ocurrir como una inestabilidad de primera oscilación. Se puede presentar la superposición de dinámicas complejas altamente no lineales e inclusive comportamientos caóticos que provoquen desviaciones del ángulo del rotor más allá de la primera oscilación [8], [11].

La ventana de tiempo de análisis usual en los estudios de Estabilidad Transitoria suele ser de 3 a 5 segundos después de la perturbación. Esta ventana puede extenderse de 10 a 20 segundos para sistemas muy grandes con oscilaciones dominantes entre áreas.

2.1.1.2. Estabilidad de Frecuencia

La Estabilidad de Frecuencia consiste en la capacidad de un SEP para conservar una frecuencia constante y delimitada luego de enfrentar una perturbación que resulte en un desequilibrio significativo entre la generación y la demanda. Esta estabilidad depende de la capacidad para mantener y restablecer el equilibrio entre la generación y la demanda del sistema. Esto bajo la premisa de permitir una pérdida de carga involuntaria mínima (deslastre de carga). La inestabilidad de frecuencia se manifiesta por decaimiento (o crecimiento) descontrolado de la frecuencia o en forma de oscilaciones de frecuencia sostenidas que pueden provocar la desconexión de las unidades de generación o de las cargas del SEP [1].

2.1.1.3. Estabilidad de Voltaje

La Estabilidad de Voltaje se refiere a la capacidad de un SEP para mantener voltajes constantes y delimitados en todas las barras del sistema después de haber estado sujeto a una perturbación. La fortaleza del sistema frente a este tipo de inestabilidad depende de la capacidad para mantener o restaurar el equilibrio entre la demanda y la generación del SEP y se relaciona con la disponibilidad de potencia reactiva. Esta inestabilidad se puede manifestar como el decaimiento o crecimiento progresivo de los voltajes de algunas barras. Como consecuencia, pueden presentarse deslastres de carga, o la desconexión de líneas de transmisión y otros elementos, lo que provocaría eventos en cascada [12].

2.1.2. Análisis de Estabilidad Transitoria

El carácter no lineal y caótico de la Estabilidad Transitoria [8], su rápida evolución y sus graves consecuencias prácticas la convierten en uno de los temas más importantes y a la vez más problemáticos de evaluar y de controlar en los SEP actuales [14]. En este contexto, se han desarrollado múltiples técnicas para la Evaluación de Estabilidad Transitoria (TSA, por sus siglas en inglés), muchas de las cuales han tenido cierta acogida hasta el día de

hoy por la simplicidad de su formulación [14]. Sin embargo, existen otras con importantes desventajas que han dificultado su aplicabilidad en casos reales. A continuación, se presentan los enfoques de TSA más populares en el estado del arte relacionado.

2.1.2.1. Simulaciones en el Dominio del Tiempo

Los métodos de Simulación en el Dominio del Tiempo (TDS, por sus siglas en inglés) constituyen una de las estrategias más precisas para TSA, que requieren de la información completa del sistema y de las perturbaciones involucradas. Estos métodos requieren de la implementación de algoritmos de integración numérica para la solución de las ecuaciones diferenciales que describen al SEP. Bajo esta perspectiva, se convierten en métodos computacionalmente exigentes y poco flexibles para su aplicabilidad en una situación de TSA en tiempo real para grandes sistemas [15], [16].

2.1.2.2. Métodos del Plano de Fase

Este método se trata de un análisis gráfico para determinar si la evolución dinámica de un sistema será estable o no. Esto se realiza mediante la inspección de las curvas del sistema en el plano de fase $\omega - \delta$. En este caso, se han desarrollado múltiples criterios que siguieren la existencia de ciertos patrones en la evolución de las curvas del sistema. Esto con base en la identificación de las características cóncavas, convexas, cruces por cero, tasas de cambio, etc., de la trayectoria de las curvas del sistema posterior a la falla. No obstante, debido a la complejidad de los SEP actuales, el método se encuentra restringido porque resulta imposible visualizar curvas de sistemas de orden superior [3], [6], [15].

2.1.2.3. Funciones de Lyapunov

Las Funciones de Lyapunov se constituyen en una teoría de la estabilidad de sistemas dinámicos que se desprende de la tesis de Aleksandr Lyapunov desarrollada en 1892 [17]. El uso de estas funciones conforma un método directo¹, en el que se introduce una función de energía (llamada Función de Lyapunov) que se anula en un punto de equilibrio y, en otro caso, es positiva, y disminuye (o no aumenta) a lo largo de una trayectoria genérica.

En este contexto, sea una función de Lyapunov V (función escalar) y el vector de estado del sistema (X). El objetivo de estas funciones es omitir la necesidad de simulaciones en el dominio del tiempo. El principio de aplicación consiste en evaluar si el sistema posfalla es estable o no. Esto se desarrolla construyendo la función de Lyapunov del sistema posfalla y calculando el valor de la función en este estado $V(X(t_{clear}))$, donde t_{clear} es el tiempo de

¹ Los métodos directos (en análisis de estabilidad de sistemas) son aquellos que no requieren de la solución del conjunto de ecuaciones diferenciales que describen el modelo dinámico del sistema analizado.

despeje de la perturbación. El valor estimado se compara con un límite V_L que separa las condiciones de estabilidad o inestabilidad.

La evaluación de estabilidad implica comparar la diferencia entre la energía cinética y potencial con un valor de referencia para una perturbación particular. Este método tiene varios inconvenientes cuando se aplica a un sistema multimáquina, debido a la inevitable simplificación requerida del modelo. Además, se tienen diferentes condicionantes para su aplicabilidad. En primer lugar, se requiere la definición de una Función de Energía que permita resultados lo suficientemente precisos, el modelo analítico aproximado del sistema, la delimitación de un espacio de fase para la identificación de una frontera entre eventos estables e inestables y, por último, la estimación o cálculo de la función de energía en tiempo real. Estas condiciones enfrentan limitaciones para su aplicabilidad en casos reales, por los requerimientos imperantes de velocidad y precisión para TSA [17].

2.1.2.4. Criterio de Igualdad de Áreas

El Criterio de Igualdad de Áreas (EAC, por sus siglas en inglés) es un método simplificado que considera una máquina equivalente conectada a una barra infinita y la transferencia de energía de aceleración y desaceleración en la relación potencia vs. ángulo. En sistemas multimáquina se considera el desarrollo de un equivalente del sistema para la aplicación del criterio. El método proporciona una forma de TSA sin resolver ecuaciones algebraico-diferenciales (DAE, por sus siglas en inglés). A pesar de que el método EAC presenta flexibilidad de formulación y visualización, se introducen aproximaciones que pueden no abordar apropiadamente la dinámica compleja de los SEP actuales [12].

2.1.2.5. Criterio de Igualdad de Áreas Extendido

El Criterio de Igualdad de Áreas Extendido (EEAC, por sus siglas en inglés) consiste en la aplicación del criterio EAC para sistemas multimáquina, en donde se combina TDS y Funciones de Lyapunov. Este método es menos preciso que la simulación en el dominio del tiempo, pero computacionalmente más eficiente. Además, proporciona la posibilidad de estimación de márgenes de estabilidad transitoria [14], [18].

2.1.2.6. Método SIME

El Equivalente de una sola máquina o Single Machine Equivalent (SIME) es un método híbrido que combina el análisis en el dominio del tiempo con el criterio EAC [19]. En este método se requiere de información en tiempo real del sistema en estudio, y el EAC se aplica a un equivalente del sistema de una sola máquina conocido como equivalente Una Máquina-Barra Infinita (OMIB, por sus siglas en inglés). Esta combinación requiere de dos

pasos básicos: la identificación de las máquinas críticas (es decir, los generadores responsables de la pérdida de sincronismo) y la evaluación de márgenes de estabilidad.

El método SIME se basa en las siguientes dos proposiciones: 1) La pérdida de sincronismo se origina en la separación de sus máquinas en dos grupos (máquinas críticas y no críticas); 2) La Estabilidad Transitoria de un OMIB puede evaluarse en términos de sus márgenes de estabilidad, definidos como el exceso de energía de desaceleración sobre su energía de aceleración.

2.1.2.7. Enfoques de Aprendizaje Automático

Los enfoques planteados en este contexto abordan dos grandes tipos de Aprendizaje: supervisado y no supervisado. El aprendizaje supervisado, generalmente, tiene como objetivo construir un modelo que relacione características de entrada, por ejemplo, mediciones en tiempo real del SEP con una salida, por ejemplo índices de estabilidad [1] (prescindiendo del modelo del SEP). Por otro lado, el aprendizaje no supervisado plantea la identificación o agrupamiento de similitudes entre escenarios de seguridad del SEP [14].

En la actualidad, con el advenimiento de avanzadas técnicas de inteligencia artificial (IA, por sus siglas en inglés) y la disponibilidad de información del SEP en tiempo real a través de Unidades de Medición Fasorial (PMU, por sus siglas en inglés), los métodos de Aprendizaje Automático, como los Árboles de Decisión, las Máquinas de Soporte Vectorial, K nearest neighbors y conceptos de Redes Neuronales han demostrado ser factibles para el desarrollo de tareas de TSA [1], [16]. No obstante, considerando que el rendimiento de los algoritmos de Aprendizaje Automático depende en gran medida de las características o de las representaciones de los datos de entrada, estos métodos requieren de una ingeniería cuidadosa y de experiencia por parte del científico de datos para diseñar modelos lo suficientemente precisos y generalizables.

2.1.2.8. Exponentes de Lyapunov

Los Exponentes de Lyapunov (LE, por sus siglas en inglés) son uno de los enfoques de análisis de estabilidad propuesto por Aleksandr Lyapunov (junto con las Funciones de Lyapunov) [17]. El uso de estos exponentes constituye un método directo que ha sido adaptado en investigaciones recientes para el análisis de Estabilidad de SEP [5], [7], [8]. De manera general, los exponentes de Lyapunov describen la dinámica de un sistema a través de la caracterización de la evolución convergente o divergente de trayectorias de variables de estado. En este sentido, se utiliza información en tiempo real de un SEP para actualizar la estimación de estos exponentes y establecer criterios de estabilidad con base

en el signo de la magnitud y demás patrones que se manifiestan en estos exponentes [6]. En las siguientes secciones se aborda en detalle la aplicación de estos exponentes.

2.2. Funcionalidad del esquema WAMPAC para el desarrollo de aplicaciones de Evaluación de Vulnerabilidad Dinámica

Los esquemas WAMPAC de los SEP permiten reducir el impacto de la ocurrencia de diferentes tipos de perturbaciones; al facilitar, en lo posible, la continuidad del funcionamiento normal de los SEP, la minimización de la extensión y duración de eventos o la prevención de colapsos parciales o totales [1]. Además de estas prestaciones, los WAMPAC han permitido lograr soluciones rentables para mejorar la planificación, operación, mantenimiento y comercio de energía del sistema [20].

En el contexto de las Redes Eléctricas Inteligentes (REI), los WAMPAC han permitido el desarrollo de aplicaciones para la Evaluación de la Vulnerabilidad Dinámica (DVA, por sus siglas en inglés) del sistema, contribuyendo al desarrollo de Redes de Transmisión Inteligentes (Smart Transmission Grids). En este sentido, se han propuesto novedosos enfoques de protección y control correctivo que se ajustan dependiendo del progreso en tiempo real de los eventos del sistema, en complemento a la operación basada en ajustes convencionales [1]. Esto ha hecho factible definir estrategias de protección inteligentes para la mitigación oportuna de perturbaciones y la mejora de la seguridad de los SEP.

2.2.1. Evaluación de la Vulnerabilidad Dinámica de SEP

Los WAMPAC permiten constituir una estructura inteligente para el control y la protección de los SEP. Esta estructura se basa en la DVA, la cual tiene como función detectar la necesidad de realizar acciones de control global para evitar la ocurrencia de colapsos frente a eventos que condicionen la vulnerabilidad del sistema. En esta sección se describen conceptos principales acerca de la vulnerabilidad de un SEP, con un enfoque en la Evaluación de Vulnerabilidad Dinámica, objeto de este subcapítulo.

2.2.1.1. Vulnerabilidad de un SEP

La vulnerabilidad de un SEP se traduce en una medida de la debilidad del sistema frente a la ocurrencia de eventos en cascada. Un sistema vulnerable es aquel que opera con un nivel de seguridad lo suficientemente reducido para ser propenso a efectos acumulados de perturbaciones moderadas o a la ocurrencia de eventos en cascada [21]. La vulnerabilidad puede analizarse a partir del nivel de seguridad del sistema (seguridad estática y dinámica) y de la tendencia a alcanzar una condición crítica (condición al borde del colapso). Una

condición crítica puede generarse frente a la ocurrencia de eventos anormales en segmentos vulnerables o en condiciones de operación de alto estrés en el sistema.

Con base en lo expresado en [1], la vulnerabilidad se define como: *El nivel de riesgo que presenta un SEP (durante una condición de operación estática o dinámica) frente a la ocurrencia de eventos en cascada.*

La vulnerabilidad del sistema se manifiesta principalmente a través de cuatro síntomas de estrés del sistema, tales como: inestabilidad de ángulo, inestabilidad de voltaje, inestabilidad de frecuencia y sobrecarga en elementos. De este modo, la vulnerabilidad se evalúa con respecto a estos síntomas de estrés del sistema.

2.2.1.2. Evaluación de Vulnerabilidad

Los resultados de la Evaluación de Vulnerabilidad de un SEP constituyen un insumo esencial para las funcionalidades del WAMPAC, considerando que esta evaluación permite identificar indicios preliminares de proximidad al colapso. Por esta razón, se necesita que esta evaluación cuente con características de precisión, rapidez y flexibilidad. Es así como la Evaluación de Vulnerabilidad requiere de modelos matemáticos específicos capaces de caracterizar apropiadamente los fenómenos de inestabilidad y relacionarlos con las interacciones entre los componentes del sistema.

Los modelos matemáticos necesarios deben considerar la variedad de fenómenos involucrados en una condición de vulnerabilidad (ver Figura 2.1), así como ventanas de tiempo de análisis que sean consistentes con la evolución particular de cada fenómeno [1]. En la Tabla 2.1 se muestran los marcos de tiempo típicos de diferentes eventos de un SEP.

Tabla 2.1. Marcos de Tiempo típicos para el análisis de eventos de un SEP [1]

Evento	Marco de Tiempo
Transitorios electromagnéticos	$\mu s - ms$
Sobrevoltaje de maniobra	ms
Ajuste de protecciones locales	$100 ms$
Efectos electromagnéticos en devanados de máquinas	$ms - s$
Transitorios electromecánicos-estabilidad	$ms - s$
Oscilaciones electromecánicas	$ms - min$
Control de Frecuencia	$1s - 10s$
Sobrecargas	$5s - h$
Despacho económico	$10s - 1h$
Efectos termodinámicos	$s - h$
Aplicaciones de Sistemas de Gestión de Energía	Estado estacionario

De acuerdo con la potencial implementación en Centros de Control, las técnicas de Evaluación de Vulnerabilidad se pueden clasificar en métodos Off-line, Online y en tiempo real, según se esquematiza en la Figura 2.2 [22].

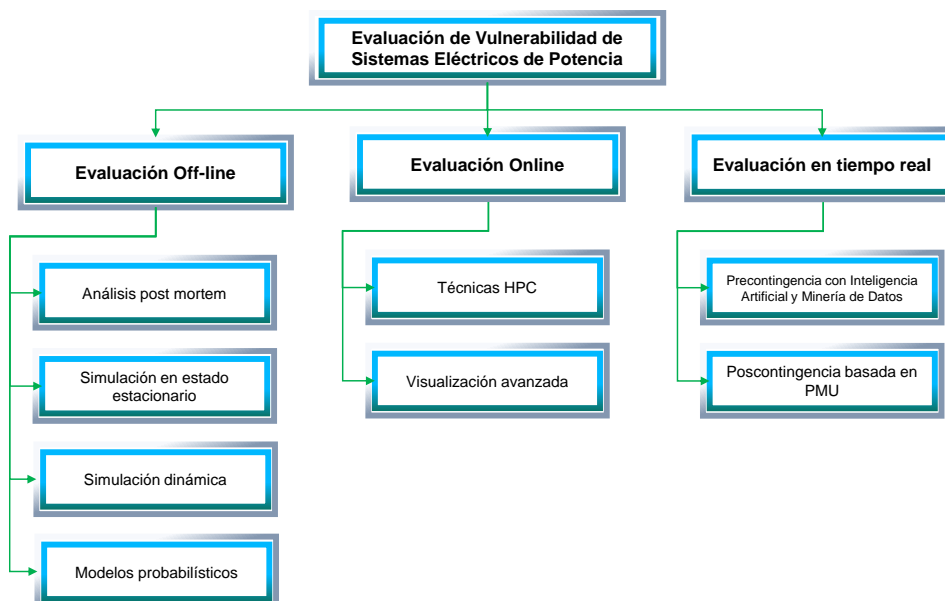


Figura 2.2. Métodos de Evaluación de Vulnerabilidad de Sistemas de Potencia [1]

2.2.1.2.1. Evaluación Off-line

Los métodos off-line se basan en modelos complejos que requieren tiempos de cómputo significativos, lo que restringe su uso en tiempo real. Estos métodos se encuentran orientados a un análisis estadístico de resultados de eventos, en donde el tiempo computacional no es un factor determinante. Por ejemplo, en etapas de planificación de mediano y largo plazo de operación de SEP o en el análisis de eventos históricos. En la Tabla 2.2 se proporciona un resumen de los enfoques de las metodologías [1], [12].

2.2.1.2.2. Evaluación Online

En estos métodos se emplea información del SEP disponible en SCADA/EMS, en donde los datos de entrada, obtenidos de IED, PMU o WAMS, se actualizan conforme el estado en tiempo real de la red. No obstante, la evaluación no se obtiene con una rapidez similar, por lo que no se pueden considerar como métodos en tiempo real [1]. En este caso, se tienen principalmente dos estrategias de evaluación: 1) Técnicas Computacionales de Alto Rendimiento (HPC, por sus siglas en inglés) y 2) Visualización Avanzada.

Con relación a la primera técnica, se debe tener en cuenta que la evaluación de vulnerabilidad de un SEP convencional implica un esfuerzo computacional significativo y el manejo de un número elevado de casos de simulación. Bajo esta perspectiva, se han desarrollado técnicas HPC, tales como procesamiento distribuido o paralelo, así como mejoras en hardware a través de computadores multiprocesador. Estos desarrollos han permitido reducir los tiempos computacionales y manejar extensos volúmenes de datos.

Tabla 2.2. Metodologías de Evaluación Off-line de un SEP [1]

Evaluación Off-line	Metodología
Análisis post mortem	Se trata de un enfoque determinista que consiste en simular, con el detalle necesario, los eventos que llevaron a un colapso real del sistema, es decir, después de ocurrido el evento. En este caso, se emplean las herramientas computacionales necesarias y los modelos estáticos y dinámicos del sistema para un análisis de eventos paso a paso que permita averiguar con claridad las causas que dieron origen a un evento.
Simulación en estado estacionario	Se desarrollan análisis a través de flujos de potencia, sensibilidad, cortocircuitos, etc., que impliquen el modelo estático de la red. Es decir, que no se incluye en el análisis la respuesta dinámica, sino solo la respuesta estacionaria. Estos enfoques se basan en la hipótesis de que una contingencia típica provoca cambios menores en el SEP, por lo que solo se migra de un estado estacionario a otro. Este enfoque se denomina Evaluación de Seguridad Estática (SSA, por sus siglas en inglés).
Simulación dinámica	Este método considera simulaciones en el dominio del tiempo; y el modelo estático y dinámico del SEP. Sin embargo, la complejidad de la modelación y los cálculos matemáticos exigen tiempos computacionales elevados. Este enfoque generalmente se denomina Evaluación de Seguridad Dinámica (DSA, por sus siglas en inglés). En este caso es posible la simulación de cualquier tipo de fenómeno de inestabilidad del sistema.
Modelos probabilísticos	El enfoque probabilístico consiste en simular eventos en el SEP considerando el carácter estocástico de los fenómenos del sistema. Por ejemplo, la tasa de falla en elementos, la variación aleatoria de la demanda, la generación del sistema, etc. El enfoque es atractivo porque al considerar el carácter variable de los eventos del sistema, los análisis y conclusiones de la evaluación se acercan más al comportamiento real del sistema. Es así como se evita la sobreestimación de posibles eventos críticos, cuya probabilidad es muy baja y pueden ser ignorados desde la perspectiva de riesgo y probabilidad.

Con estas prestaciones, es posible la ejecución de tareas de SSA y DSA. No obstante, los enfoques propuestos aún no permiten ser utilizados en aplicaciones en tiempo real.

En relación con la técnica de Visualización Avanzada, se ha conseguido la mejora de la conciencia situacional sobre el SEP a través de tecnologías de comunicaciones basadas en Sistemas de Información Geográfica (GIS, por sus siglas en inglés). En este caso, es posible el análisis de los estados de la red (normal, alerta, emergencia, restauración y en colapso) a través de representaciones gráficas particulares.

2.2.1.2.3. *Evaluación en Tiempo Real*

Esta evaluación considera información reciente de las condiciones del sistema, la cual es analizada en tiempo real, de manera que se proporcionan conclusiones en muy poco tiempo, el cual debería ajustarse al tiempo de evolución del fenómeno de interés. En este caso, este tipo de evaluación brinda la capacidad de desarrollar acciones de control preventivo y correctivo en el SEP [1].

La disponibilidad de equipos como las PMU ha permitido el desarrollo de enfoques modernos para la Evaluación de Vulnerabilidad, los cuales pueden llevarse a cabo en tiempo real, es decir, prácticamente de manera simultánea e inclusive de forma predictiva con respecto a la evolución real de los eventos. Además, se han planteado en este contexto

métodos matemáticos novedosos para el procesamiento de datos a través de la identificación de indicadores o patrones que reflejan condiciones de vulnerabilidad del sistema. Esto a través del uso de Inteligencia Artificial y técnicas de Minería de Datos.

Las herramientas basadas en Inteligencia Artificial permiten analizar patrones del desempeño dinámico del SEP en tiempo real, utilizando conocimiento adquirido mediante entrenamiento Off-line. Por otro lado, las técnicas de Minería de Datos permiten descubrir valiosa información inmersa en las señales eléctricas, la cual puede presentar ciertas regularidades (patrones) que alerten sobre una condición posiblemente vulnerable.

Este tipo de evaluación se concibe para dos tipos de análisis: 1) Exploración de datos de estado cuasiestacionario precontingencia (es decir, DSA en tiempo real para tomar acciones de control preventivo); y 2) Análisis de datos dinámicos poscontingencia (es decir, DVA poscontingencia para el desarrollo de acciones de control correctivo).

- *Evaluación precontingencia.*- Esta evaluación tiene como fin proporcionar requerimientos de control preventivo en el SEP, luego de haber determinado que existen condiciones inseguras de funcionamiento, es decir, que el sistema se encuentra en una situación propensa a la inestabilidad cuando se presente una perturbación. En esta evaluación se presentan varias propuestas en cuanto a la aplicación de herramientas de Inteligencia Artificial y Minería de Datos para realizar DSA precontingencia. Este tipo de métodos comúnmente utiliza datos en tiempo real de estado cuasiestacionario de sistemas como el SCADA/EMS [23].

De manera general, las técnicas de Inteligencia Artificial han sido empleadas para evaluaciones predictivas de condiciones de vulnerabilidad, mediante tareas de entrenamiento Off-line y el uso de algoritmos de clasificación que separan a la condición operativa futura del sistema en estable o inestable. Además, se ha incluido la estimación de indicadores que cuantifiquen el nivel de vulnerabilidad [4].

- *Evaluación poscontingencia.*- En esta evaluación se ofrece la posibilidad de sugerir acciones de control correctivo en el SEP mientras evoluciona el evento que ha sido identificado como un causante futuro de inestabilidad. Bajo esta perspectiva, esta evaluación constituye una estrategia inteligente y moderna de abordar los problemas actuales de inestabilidad en los SEP. La evaluación se basa en la disponibilidad de mediciones provenientes de PMU, las cuales brindan información valiosa de la dinámica del SEP. Así, es posible identificar el estatus de vulnerabilidad del sistema poscontingencia. Estos datos poscontingencia ofrecen

un novedoso marco de evaluación de la DVA. Esta evaluación requiere incluso una respuesta más rápida que la DSA, en consecuencia, se emplean técnicas de Inteligencia Artificial y de Minería de Datos para estructurar algoritmos con características de rapidez, precisión y flexibilidad [1]. A continuación, se explica con más detalle las particularidades de la DVA.

2.2.1.3. Planteamientos de Evaluación de Vulnerabilidad Dinámica

2.2.1.3.1. Estado del arte

Las investigaciones relacionadas con la DVA muestran planteamientos de evaluación desde eventos individuales hasta eventos múltiples o desde un área local hasta un análisis global. Esto se justifica porque muchos de los problemas de inestabilidad en el SEP ocurren por eventos complejos que involucran una serie de factores de todo el sistema.

Con relación a las investigaciones basadas en técnicas de Inteligencia Artificial, en [24] se presenta un enfoque para la predicción de eventos de inestabilidad transitoria basado en la teoría de Árboles de Decisión, en donde las mediciones provenientes de PMU son utilizadas en las pruebas dicotómicas de los nodos de los árboles. En [25] se presenta un enfoque para predecir el ángulo del rotor de generadores de un SEP utilizando Redes Neuronales Artificiales, en donde se consigue predecir el estatus de vulnerabilidad de cada generador. En [26] se propone un esquema jerárquico para la predicción de estabilidad transitoria basado en el clasificador SVC. En [27] se emplean redes neuronales recurrentes y de memoria a corto plazo (LSTM, por sus siglas en inglés) para la evaluación de Estabilidad Transitoria en tiempo real mediante el uso de mediciones de unidades PMU.

En relación con otras técnicas novedosas para DVA, en [28] se presentan varios métodos, como el E-SIME, el cual ostenta uno de los mejores desempeños para aplicaciones en tiempo real. En este método se construye el equivalente OMIB del sistema para predecir eventos de inestabilidad transitoria considerando mediciones de PMU. En [29] se describe una metodología innovadora basada en mediciones PMU para la predicción del equivalente SIME usando aprendizaje automático, a la cual se la denomina P-SIME. Los resultados demuestran la factibilidad y efectividad que podría lograrse en la estimación del estatus de estabilidad del SEP, relacionado con márgenes de estabilidad transitoria del SIME. En [3], [15] se presentan esquemas basados en la visualización del espacio de fase, los cuales permiten encontrar patrones que podrían alertar sobre un posible colapso. Estos métodos permiten monitorear curvas de variables críticas y proporcionar una alerta temprana; sin embargo, se necesita el trazo de imágenes para encontrar patrones, lo que dificulta una respuesta automática. En [30] se presenta una metodología basada en Minería de Datos

para DVA que permite predecir la evolución de eventos de inestabilidad en un SEP. Se consideran métodos de Montecarlo con la generación de datos de contingencias en un sistema.

En [4] se propone un enfoque basado en el análisis del LLE para la evaluación de la Estabilidad Transitoria utilizando datos de PMU. Mediante el establecimiento de un modelo matemático aproximado que representa el valor del LLE, así como el análisis de la trayectoria del plano de fase (velocidad-ángulo) poscontingencia, se propone un criterio empírico para determinar si se producirá Inestabilidad Transitoria. En [5] se presenta un algoritmo para monitorear la Estabilidad Transitoria de un SEP con un enfoque libre del modelo del sistema y que emplea datos provenientes de PMU para proporcionar información sobre la estabilidad del sistema. El algoritmo propuesto se basa en la teoría de sistemas dinámicos y el cálculo aproximado del LLE del sistema.

Asimismo, en [1] se presenta una investigación que se constituye como la pionera en el desarrollo de algoritmos de evaluación de la vulnerabilidad de SEP en tiempo real en Ecuador y en la región. En este trabajo se presenta una novedosa metodología para DVA, considerando cinco síntomas de alerta en el sistema, tales como: inestabilidad transitoria, inestabilidad oscilatoria, inestabilidad de voltaje de corto plazo, inestabilidad de frecuencia de corto plazo, y sobrecargas. La propuesta permite evaluar dos tareas involucradas en el concepto de vulnerabilidad: a) valoración del estado de seguridad del sistema, y b) análisis de la tendencia del sistema a cambiar sus condiciones a un estado crítico. Sus principales contribuciones son: i) un novedoso método para determinar Regiones de Vulnerabilidad Dinámica poscontingencia (DVR) basado en Minería de Datos, ii) una metodología para clasificar el estado de vulnerabilidad del sistema usando un algoritmo de clasificación basado en Máquinas de Soporte Vectorial (SVM), y iii) una propuesta para evaluar la vulnerabilidad en tiempo real basada en varios índices de desempeño. La metodología demuestra ser práctica para evaluar la vulnerabilidad en tiempo real a través del uso de tecnología moderna disponible actualmente en Centros de Control.

Se debe resaltar que, a pesar de que las investigaciones mencionadas han mostrado planteamientos factibles para la DVA, la complejidad dinámica y comportamiento caótico del SEP, descrito en varias investigaciones [1], [8], pueden afectar la precisión y los tiempos de cálculo de la predicción propuesta con estas metodologías. En este sentido, se requiere de investigación complementaria que oriente la adición de más información relevante en la identificación de patrones o alternativas algorítmicas que permitan mejorar el desempeño de las propuestas actuales.

2.2.1.3.2. *Herramientas matemáticas usuales*

De acuerdo con las investigaciones más recientes y novedosas en torno a DVA, se destaca la constante necesidad de aplicar herramientas matemáticas robustas que brinden resultados oportunos, precisos y cuya aplicación sea lo suficientemente flexible para su uso en tiempo real. Bajo esta perspectiva, se tienen las siguientes herramientas matemáticas usadas para DVA comúnmente: Funciones de Energía y Exponentes de Lyapunov [17], [31], [32], [33], [34], [35]; Redes Neuronales Artificiales [16], [25], [36]; Máquinas de Soporte Vectorial [1], [26]; Árboles de Decisión [24]; Reconocimiento de patrones [1], [3], [6], [15]; Métodos de Minería de Datos [1]; Equivalentes OMIB-SIME [19]; Índices de Severidad de Área Extendida [37], etc.

2.2.1.4. Aplicaciones de la Evaluación de Vulnerabilidad Dinámica

Existen principalmente dos aplicaciones de la DVA propuestas en [1] que permiten completar un esquema de evaluación para el desarrollo de una Red Inteligente autocurable. A continuación, se describen estas dos aplicaciones, las cuales se encuentran involucradas directamente en el concepto de vulnerabilidad.

- Valoración del nivel de seguridad del sistema.- Una tarea de la DVA es estimar el nivel de seguridad del sistema, es decir, cuantificar la vulnerabilidad del SEP en tiempo real, lo cual puede ser factible a través de índices que reflejen el estatus de vulnerabilidad o el impacto de cada fenómeno de inestabilidad apropiadamente.
- Determinación de la tendencia del sistema a cambiar sus condiciones hacia un estado crítico.- Esta tarea de la DVA se enfoca principalmente en la predicción de situaciones de inestabilidad con base en las condiciones actuales del sistema. Esto es posible con el uso de Inteligencia Artificial, lo cual permite calificar el estatus de un sistema poscontingencia a futuro como estable o inestable.

2.2.2. Sistemas de Medición de Área Extendida

Las acciones tradicionales de monitoreo, protección y control de un SEP se basan únicamente en mediciones locales. Sin embargo, esto complica enfrentar diversos fenómenos de inestabilidad y mantener la seguridad del sistema entero. En los últimos años han surgido los Sistemas de Medición/Monitoreo de Área Extendida (WAMS, por sus siglas en inglés), basados en tecnología de medición sincrofasorial. Estos sistemas constituyen la infraestructura básica para implementar un esquema integral de monitoreo de la dinámica del SEP en tiempo real que permita ejecutar acciones de protección y control inteligentes.

2.2.2.1. Tecnología de Medición Sincrofasorial

La tecnología de medición sincrofasorial se basa en las PMU, las cuales proporcionan mediciones fasoriales de voltaje y corriente con períodos de actualización de pocos milisegundos. Estos datos pueden ser obtenidos en tiempo real y aprovechados para permitir el desarrollo de enfoques modernos que brinden *Conciencia Situacional* del estado completo del SEP y de su vulnerabilidad.

2.2.2.1.1. Señales Sinusoidales Sincronizadas

En esta tecnología se considera la representación fasorial de variables del SEP obtenidas a través de mediciones. Sea $x(t)$ una señal con amplitud X_m , frecuencia angular ω y ángulo de fase ϕ , entonces se tiene:

$$x(t) = X_m \cos(\omega t + \phi) = \text{Re}\{X_m e^{j(\omega t + \phi)}\} \quad (2.2)$$

De este modo, la representación fasorial de $x(t)$ está dada por:

$$x(t) \leftrightarrow \bar{X} = \left(\frac{X_m}{\sqrt{2}}\right) e^{j\phi} \quad (2.3)$$

Además, se requiere que las cantidades fasoriales determinadas del sistema se encuentren sincronizadas para que toda esta información considere un mismo marco de referencia con fines de monitoreo integral. Los fasores referenciados y sincronizados se denominan sincrofasores. Es así como se considera en los WAMS una señal de tiempo estándar como referencia para las mediciones. Los fasores del sistema son referenciados con una onda de tipo coseno (señal de sincronización) a frecuencia nominal que está sincronizada con el Tiempo Universal Coordinado (UTC, por sus siglas en inglés-francés).

La señal de sincronización debe ostentar disponibilidad ininterrumpida y continua. Además, la señal debe ser de fácil acceso para cada sitio en donde se ubicarán las unidades de medición. Asimismo, se debe garantizar suficiente precisión para lograr ciertos requisitos de error máximo. La fuente de sincronización más utilizada es el Sistema de Posicionamiento Global (GPS, por sus siglas en inglés), el cual se basa en una señal de sincronización 1-PPS, con un error máximo de 1 μs [1].

2.2.2.1.2. Unidades de Medición Fasorial

Las PMU permiten estimar sincrofasores de ondas de voltaje y corriente alterna. Para calcular un sincrofasor, una PMU necesita disponer de mediciones de la señal eléctrica $x(t)$, así como de la onda coseno de referencia sincronizada con UTC. En el cálculo de un sincrofasor, las PMU utilizan algoritmos de estimación como la Transformada Discreta de

Fourier (DFT, por sus siglas en inglés). Estos algoritmos comúnmente emplean un número fijo de muestras en un periodo de tiempo específico para realizar la estimación fasorial.

La alta precisión y velocidad de respuesta, junto con la capacidad de sincronización de tiempo, hacen que las PMU sean apropiadas para los sistemas WAMS en aplicaciones de monitoreo, control y protección [38]. La Figura 2.3 esquematiza la estructura de una PMU.




Figura 2.3. Estructura básica de una Unidad de Medición Fasorial [1], [38]

2.2.2.2. Aplicaciones del WAMS

La estrategia de medición de las variables esenciales de un SEP mediante el uso de unidades PMU es una característica clave para el desarrollo de aplicaciones de monitoreo, control y protección. Además de la disponibilidad de equipos PMU, el WAMS requiere de algoritmos avanzados de procesamiento de señales, sistemas de comunicación dedicados, que incluyen concentradores de datos, y una infraestructura de análisis en tiempo real.

Considerando las prestaciones del sistema WAMS, en cuanto a rápidos intervalos de actualización de la información medida en un SEP, es posible el monitoreo del comportamiento dinámico del sistema, así como la capacidad de detectar condiciones inseguras de funcionamiento que sugieran la activación de acciones críticas de corto plazo.

Entre las aplicaciones que permiten los Sistemas de Medición de Área Extendida se encuentran:

- Sistemas de Monitoreo de Área Extendida - Wide Area Monitoring Systems (WAMS)
- Sistemas de Control de Área Extendida - Wide Area Control Systems (WACS)
- Sistemas de Protección de Área Extendida - Wide Area Protection Systems (WAPS)

La conjunción de WAMS, WACS y WAPS se denomina WAMPAC. En la Figura 2.4 se exponen varias aplicaciones de Monitoreo, Control y Protección de un SEP, considerando diferentes niveles operacionales relacionados con el alcance y grado de sofisticación. Se debe resaltar cómo la tecnología de medición sincrofásorial da lugar a la existencia del esquema WAMPAC, la cual se constituye en un nivel operacional moderno de los SEP.

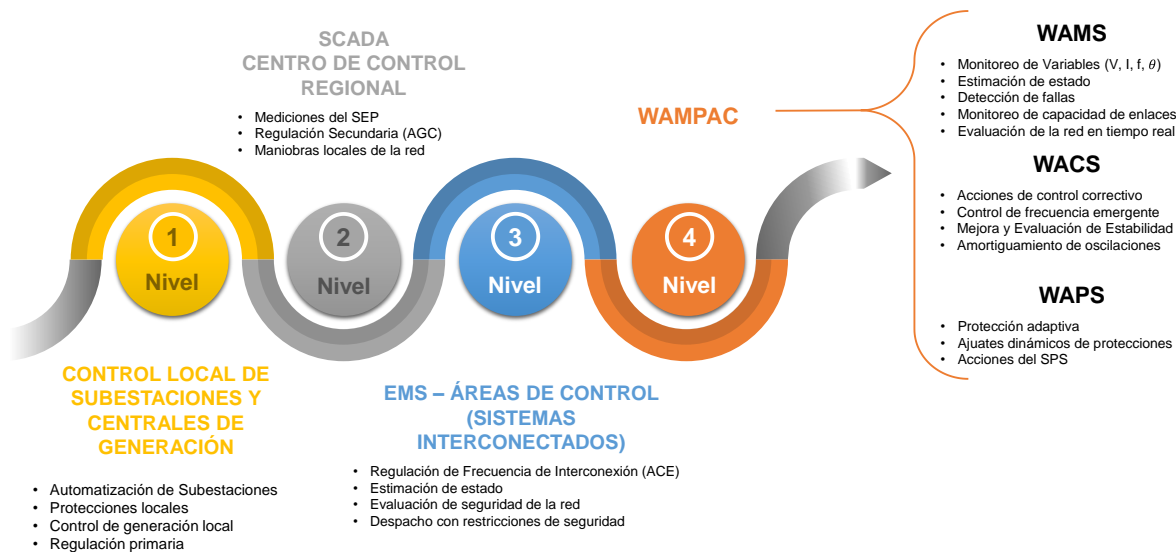


Figura 2.4. Aplicaciones de Monitoreo, Control y Protección de un SEP [1], [39]

Como se observa en la Figura 2.4, el WAMPAC constituye una estrategia sofisticada de Conciencia Situacional del SEP, en donde es posible el desarrollo de acciones críticas preventivas y correctivas de corto plazo.

2.2.3. Esquema funcional del WAMPAC para desarrollar DVA

El esquema WAMPAC involucra diferentes etapas interrelacionadas que permiten en conjunto conseguir el desarrollo de una Red Inteligente que se pueda autocurar (Self-Healing Grid). En la Figura 2.5 se presenta este esquema, en donde destaca la interrelación de las diferentes etapas y el flujo de información que se gestiona en cada una.

En este punto, se resaltan las siguientes prestaciones principales de la funcionalidad del WAMPAC que permiten el desarrollo de aplicaciones de DVA.

- Con la disponibilidad de PMU en el sistema WAMS, es posible el monitoreo integral del SEP, el cual permite adquirir datos de la condición funcional del SEP en tiempo real e información relacionada con su vulnerabilidad. Esto constituye el insumo básico para la DVA.
- El WAMPAC constituye una infraestructura que gestiona datos históricos del desempeño del sistema, los cuales también son un insumo para el reconocimiento de patrones y etapas de entrenamiento Off-line de los algoritmos que ejecutan DVA.
- El WAMPAC proporciona conciencia situacional de la condición en tiempo real del SEP, a partir de lo cual es posible la formulación de algoritmos avanzados de procesamiento de datos que valoren el nivel de seguridad del SEP y la tendencia a

cambiar sus condiciones de operación hacia un estado crítico. En este caso, el WAMPAC gestiona dentro de su infraestructura el procesamiento de estos algoritmos para la ejecución de DVA.

- Finalmente, el resultado de la DVA se materializa en acciones de control correctivas ejecutadas gracias a la infraestructura de control y protección provista en el WAMPAC.

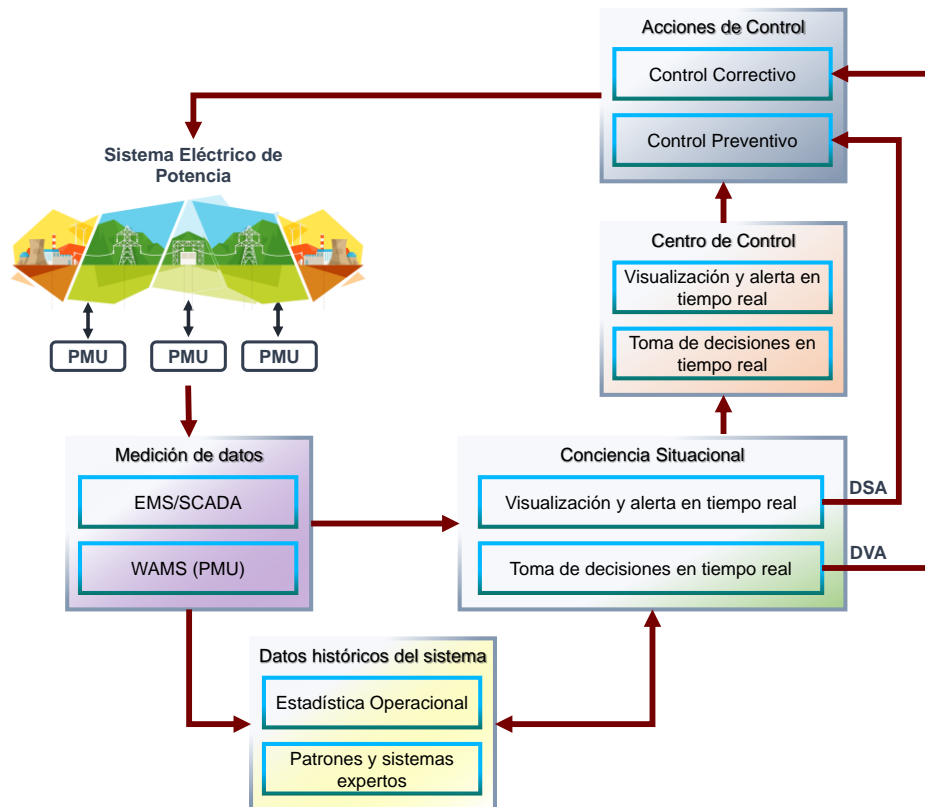


Figura 2.5. Esquema de integración de funcionalidades para Monitoreo, Control y Protección de un SEP en tiempo real [1]

Cabe mencionar que la información procesada en la DSA y DVA se envía también al Centro de Control para monitoreo en tiempo real y toma de decisiones. Este trabajo se enfoca en desarrollar una metodología de DVA, específicamente, un algoritmo para el procesamiento de datos en el WAMPAC.

2.2.3.1. Retardo de tiempo del WAMPAC

Con el fin de que una aplicación de DVA sea práctica, los tiempos involucrados de retardo en las etapas del WAMPAC deben ser mínimos. De este modo, los resultados de DVA pueden ser obtenidos con suficiente anticipación y las acciones de control pueden ser provistas y ejecutadas oportunamente antes de la ocurrencia de eventos en cascada. Es

decir, el esquema WAMPAC debe actuar previo a los sistemas de protección local, es decir antes del inicio de un evento en cascada.

En este sentido, el proceso involucrado en la estructura WAMPAC comprende: el retardo de tiempo para las mediciones obtenidas de las PMU, las comunicaciones de fibra óptica, el rendimiento de concentrador de datos, el disparo transferido y el cierre del interruptor (representación de acción correctiva).

Los retardos asociados en el proceso dependen de la complejidad de cada SEP y deben determinarse antes del desarrollo del esquema WAMPAC. En la Tabla 2.3 se presentan valores referenciales de retardo de tiempo en un WAMPAC típico [1].

Tabla 2.3. Retardos de tiempo de un esquema WAMPAC por proceso [1]

Proceso	Retardo de tiempo (ciclos con $f=60\text{Hz}$)	Retardo de tiempo (ms)
Mediciones de PMU	3	50
Comunicaciones por Fibra Óptica	2	33
Rendimiento del concentrador de datos	2	33
Disparo transferido	1	17
Accionamiento del interruptor	2-5	33-83
Total	10-15	167-217

2.2.3.2. Arquitectura de comunicaciones del WAMPAC

Con la integración de la Tecnología de Medición Sincrofasorial, el desarrollo de sistemas de comunicación de alta velocidad y tecnología de procesamiento de señales digitales, el uso de los esquemas WAMPAC se han extendido a nivel mundial de forma acelerada [40]. En la Figura 2.6 se ilustra la arquitectura básica de un sistema de comunicaciones de un WAMPAC típico, en donde se incluyen los principales componentes que permiten la gestión de la información proveniente de PMU y su procesamiento para aplicaciones como la DVA.

Cabe mencionar que este tipo de arquitectura centralizada ha sido reemplazada en ciertos casos debido a la complejidad de los SEP. En este sentido, se han propuesto novedosas arquitecturas más particulares, por ejemplo, arquitecturas jerárquicas o distribuidas que ofrecen mayor flexibilidad para la integración de diferentes Operadores de Sistemas [40].

2.2.4. Experiencias del WAMPAC

Considerando las prestaciones que proporciona el esquema WAMPAC, se han planteado diferentes propuestas de soluciones rentables para mejorar la planificación, operación, mantenimiento, comercio de energía, protección adaptiva, control y monitoreo global, etc., [41]. En este sentido, en la Figura 2.7 se presenta el porcentaje de uso de aplicaciones en

esquemas WAMPAC estimado en el Sistema de Potencia de la India (uno de los más grandes a nivel mundial).

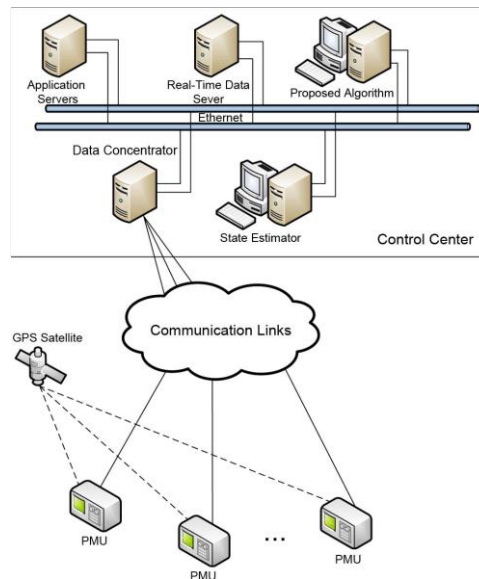


Figura 2.6. Arquitectura básica de comunicaciones del esquema WAMPAC [9]




Figura 2.7. Porcentaje de uso de aplicaciones en esquemas WAMPAC [9]

Se debe destacar que las aplicaciones WAMPAC se encuentran en pleno desarrollo y aún no existen prácticas o definiciones estándar, por lo que en cada país las empresas que operan los SEP cuentan con sus propias aplicaciones, las cuales presentan características particulares. Con respecto a la aplicación del WAMS en Ecuador, se cuenta con las siguientes características [42], [43].

- Con base en estudios especializados desarrollados por el ex Centro Nacional de Control de Energía (actual Operador Nacional de Electricidad CENACE), se definieron puntos de medición estratégicos para la ubicación de PMU, los mismos que se encuentran localizados en varias subestaciones del Sistema Nacional Interconectado (SNI).

- La aplicación WAMS utilizada, denominada WAProtector y desarrollada por la empresa ELPROS, gestiona las PMU del sistema y brinda las diferentes funcionalidades del esquema a través de una interfaz de usuario personalizable.
- Se diseñó una red de datos dedicada e independiente para la adquisición de datos provenientes de PMU, con una interfaz de capacidad E1 (2 Mbps) en topología de anillo. Esta red permite la transmisión a las diferentes aplicaciones WAMS, garantizando así tiempos apropiados para el envío y recepción de información, según el estándar IEEE C37.118.
- CENACE ha desarrollado diferentes algoritmos para el análisis de varios fenómenos de estudio en el SNI en el entorno de WAProtector. Por ejemplo: estabilidad estática de ángulo, estabilidad de voltaje, estabilidad oscilatoria y, en general, el despliegue de información mediante gráficas interactivas, como se ejemplifica en la Figura 2.8.
- CENACE ha orientado una gran cantidad de análisis y desarrollos en la mitigación del fenómeno de estabilidad oscilatoria, incluyendo la sintonización de estabilizadores del sistema de potencia (PSS), obteniendo grandes beneficios técnicos, comerciales y económicos [44].

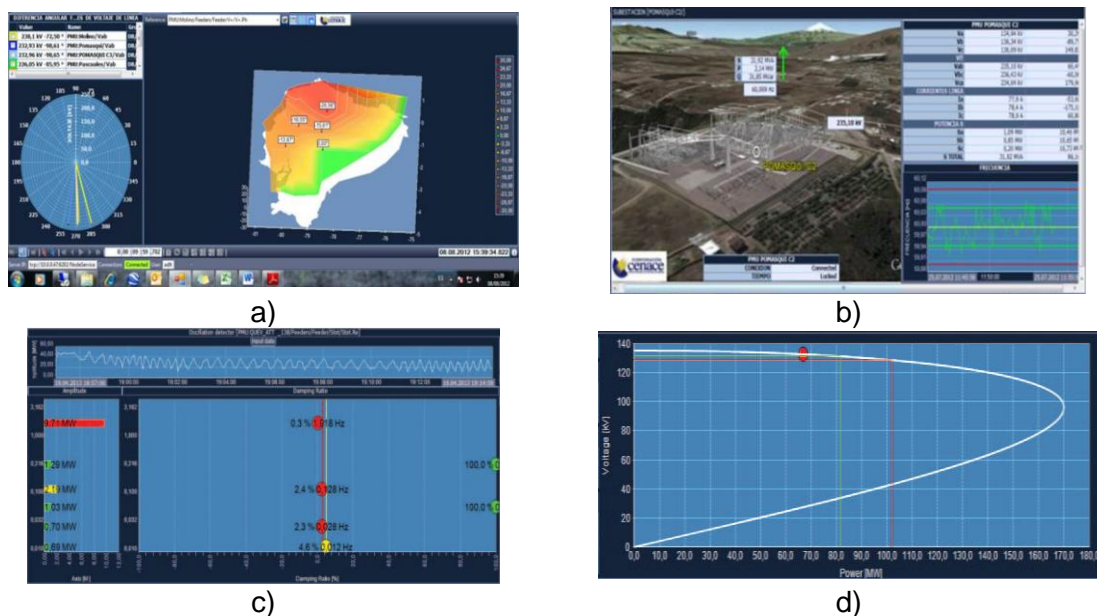


Figura 2.8. Ejemplos de aplicaciones de WAProtector: a) Diferencias angulares, b) Despliegue de Subestación, c) Modos Oscilatorios, d) Curvas PV [43]

2.3. Estabilidad y Exponentes de Lyapunov

Según Lyapunov una trayectoria dada es estable si, para un ε arbitrario, existe siempre un δ , tal que las demás trayectorias que comiencen en una vecindad menor que δ permanecen máximo a una distancia ε . Es decir, si una condición inicial se encuentra lo suficientemente cerca de un punto de equilibrio (dentro de un círculo de radio δ), la trayectoria correspondiente se mantendrá acotada, no más allá de ε (ver Figura 2.9).




Figura 2.9. Ilustración de la definición de estabilidad de Lyapunov [11]

Lyapunov definió un método para evaluar la estabilidad de una solución dada, a través de la introducción de un *número característico* λ_L . Este número, análogo a un LE, se define como la tasa exponencial que equilibra la tasa de crecimiento de una trayectoria dada $\delta(t)$. Es decir, asumiendo que $\delta(t) \approx e^{\lambda t}$, entonces $\delta(t) \cdot e^{-\lambda_L t}$ no converge ni diverge [14].

En este caso, se definen a los LE como medidas de la tasa de divergencia (o convergencia) de trayectorias que en un inicio se encuentran infinitesimalmente separadas. Lyapunov define que dos condiciones iniciales cercanas infinitesimalmente evolucionarán con una diferencia descrita por una función exponencial, a una tasa dada por λ_L . En la Figura 2.10 se ejemplifica esta situación para una trayectoria $x(t)$. Se observa que la evolución dinámica de $x(t)$, frente a dos condiciones iniciales infinitesimalmente cercanas, difiere en una cantidad $\delta(t)$, que es proporcional a una función exponencial con tasa de variación λ .




Figura 2.10. Evolución dinámica de una trayectoria con dos diferentes condiciones iniciales infinitesimalmente cercanas [31]

2.3.1. Definición analítica de los Exponentes de Lyapunov

Una definición matemática de los LE puede desarrollarse en términos de la denominada ecuación variacional de un sistema dinámico no lineal, $\dot{x} = f(x)$ [8], [33]. En primer lugar, se deriva $\dot{x} = f(x)$ con respecto a un punto inicial del espacio de estado, x_0 , entonces:

$$\begin{aligned} D_{x_0} \dot{\phi}_t(x_0) &= D_x f(\phi_t(x_0)) D_{x_0} \phi_t(x_0), \\ D_{x_0} \phi_{t_0}(x_0) &= I, \end{aligned} \quad (2.4)$$

Donde $\phi_t(x_0)$ es la solución de $\dot{x} = f(x)$ para el punto inicial x_0 . Si se define $D_{x_0} \phi_t(x_0) = \Phi_t(x_0)$, entonces las expresiones anteriores se pueden reescribir como:

$$\begin{aligned} \dot{\Phi}_t(x_0) &= D_x f(\phi_t(x_0)) \Phi_t(x_0), \\ \Phi_{t_0}(x_0) &= I, \end{aligned} \quad (2.5)$$

La ecuación 2.5 es una ecuación variacional, constituida como una expresión lineal variante en el tiempo que describe la evolución de $\Phi_t(x_0)$. Además, sean $m_i(t)$, con $i = 1, 2, \dots, n$, los autovalores de $\Phi_t(x_0)$. Una definición precisa de los LE, λ_i , está dada por:

$$\lambda_i = \lim_{t \rightarrow \infty} \frac{\ln(|m_i(t)|)}{t} \quad (2.6)$$

A partir de esta definición, varios autores han expresado cómo los LE representan la tasa promedio de expansión o contracción a lo largo de cada dimensión i , para un volumen que se encuentra en un espacio de dimensión total n [8], [17], [33]. El número de exponentes es el mismo que el de la dimensión del espacio de estado del sistema dinámico analizado. Estos exponentes se derivan con base en la evolución de largo plazo en cada eje de una n -esfera infinitesimal. Durante su evolución, esta n -esfera infinitesimal se convierte en un n -elipsoide debido a la naturaleza deformante de la dinámica que existe en cada eje. La Figura 2.11 ejemplifica la deformación de los ejes principales del círculo a lo largo de una trayectoria de referencia de un flujo bidimensional.




Figura 2.11. Evolución de una n -esfera inicialmente infinitesimal a lo largo de una trayectoria de referencia [31]

Los LE están relacionados con la contracción y expansión de diferentes direcciones en el espacio de estado. Sin embargo, no se puede definir una dirección exacta asociada con un exponente dado, en virtud de que la orientación del elipsoide cambia continuamente a medida que evoluciona [35].

De esta manera, si se tiene un exponente λ_i positivo, entonces la evolución de la diferencia entre dos condiciones iniciales infinitesimalmente cercanas de una trayectoria presentará una dinámica que se expandirá a lo largo de la dimensión i . Si el exponente es negativo, la diferencia se va a contraer en promedio en esa dirección.

Para un comportamiento estable en estado estacionario, la contracción neta debe ser superior que la expansión, es decir:

$$\sum_{i=1}^n \lambda_i < 0 \quad (2.7)$$

Existen varias propiedades de los LE que definen características relevantes de un sistema dinámico. Por ejemplo, si el sistema es caótico² existirá al menos un LE positivo, el cual refleja la sensibilidad a las condiciones iniciales. Para otros comportamientos estables, puntos de equilibrio y periódicos, se tienen exponentes negativos.

Adicionalmente, los LE contienen información relacionada con otro tipo de propiedades más específicas de la evolución dinámica de los sistemas. Por ejemplo, el campo de la teoría ergódica, la aparición de atractores complejos, la entropía del sistema y la sensibilidad frente a las condiciones iniciales. El lector puede revisar [17], [34], [45] para un análisis amplio sobre esta teoría.

2.3.2. Nuevas perspectivas de análisis

El cálculo clásico de los LE, a través del uso de la expresión 2.6, conlleva dificultades en la práctica [8]. En la estimación de los LE se han propuesto diferentes algoritmos, los cuales consideran modelos matemáticos aproximados. Se debe resaltar que es necesario la disponibilidad de un modelo analítico del fenómeno estudiado, lo cual en muchos casos resulta imposible por la complejidad del sistema dinámico. Por esta razón, la aplicación de la teoría clásica de los LE enfrenta serias limitaciones para análisis de estabilidad de SEP en tiempo real y no ha sido ampliamente difundida [6].

² Un sistema caótico es aquel que presenta un comportamiento dinámico aparentemente aleatorio, altamente sensible a las condiciones iniciales, pero que en sí es determinista. Por ejemplo, el movimiento de un péndulo doble.

No obstante, en investigaciones recientes se han propuesto nuevos paradigmas en la aplicación de la teoría de los LE. En este sentido, han surgido contribuciones novedosas que plantean la estimación de Exponentes a partir de series de tiempo de sistemas dinámicos. De esta manera, se prescinde del modelo analítico y así es posible superar los inconvenientes de la estimación clásica de los LE. En [46] se plantea por primera vez la teoría relacionada con la estimación de Exponentes a partir de series de tiempo. A partir de estas concepciones, en [6], [7] se proponen metodologías de estimación aproximada de LE a partir de señales dinámicas de un SEP provenientes de unidades PMU.

Estas nuevas propuestas consideran la estimación del Máximo Exponente de Lyapunov (LLE, por sus siglas en inglés), λ_1 , si se toman en cuenta a los exponentes λ_i ordenados de forma descendente. En este contexto, se asumen varias suposiciones. Una de las más importantes es que para fines prácticos el LLE es el exponente dominante en la expresión 2.7 por las ventanas de tiempo asociadas a la Estabilidad Transitoria. De esta manera, el signo del LLE se constituye en un indicador de estabilidad de SEP. Si el LLE de largo plazo es positivo, el sistema es inestable; y si es negativo, el sistema tiende a ser estable [5].

2.3.3. Formulación matemática del LLE para series de tiempo

Los enfoques de evaluación de estabilidad basados en el LLE obtenido a través de series de tiempo son atractivos porque pueden eliminar los errores del modelo y simplificar los cálculos significativamente. Estos métodos son más adecuados para TSA en tiempo real, principalmente porque evitan esfuerzos computacionales asociados al tratamiento de un modelo analítico. En [5], [6] se desarrollaron fundamentos analíticos para la estimación del LLE a partir de series de tiempo poscontingencia del ángulo del rotor, los cuales se resumen a continuación.

2.3.3.1. Teorema de Oseledec y primera estimación del LLE

De acuerdo con el teorema de Oseledec, para un punto de referencia de una serie de tiempo $\delta(0^-)$ y su punto vecino $\delta'(0^-)$ escogido del espacio de estado de un sistema dinámico, la distancia euclídea d entre las trayectorias que emergen de $\delta(0^-)$ y $\delta'(0^-)$, es decir, la trayectoria original y la trayectoria vecina, presentarán una evolución que se divide en tres fases ilustradas en la Figura 2.12.

En la fase I, la diferencia entre las trayectorias exhibe fluctuaciones. En la fase II, la distancia experimenta un crecimiento exponencial a través de una tasa dada por el LLE, que corresponde a un segmento lineal en la gráfica logarítmica. Finalmente, en la fase III, la distancia de las trayectorias se satura y converge a un valor constante.




Figura 2.12. Evolución de la distancia logarítmica de diferentes trayectorias con condiciones iniciales cercanas

Como se demuestra en [34], el LLE puede ser estimado como la tasa de separación de las trayectorias vecinas en la fase II, es decir:

$$m = \lambda \approx \frac{\log|d(k\Delta t)| - \log|d(0)|}{k\Delta t} = \frac{1}{k\Delta t} \log \left| \frac{d(k\Delta t)}{d(0)} \right| \quad (2.8)$$

$$\lambda = \frac{1}{k\Delta t} \log \left| \frac{\|\delta'(k\Delta t) - \delta(k\Delta t)\|}{\|\delta'(0) - \delta(0)\|} \right| \quad (2.9)$$

Donde k es el número de muestras de la serie temporal en la fase II, Δt es el tiempo de muestreo de la serie, $\delta'(0)$ y $\delta(0)$ los puntos iniciales para la estimación del LLE en la trayectoria vecina y original; y, $\delta'(k\Delta t)$ y $\delta(k\Delta t)$ los puntos de la trayectoria vecina y original k puntos después de los puntos iniciales. $\|\cdot\|$ denota la distancia euclídea.

Con respecto a la selección del tiempo inicial para la estimación del LLE, que garantice que el cálculo se desarrolla durante la fase II ilustrada en la Figura 2.12, se tiene que, para un SEP, la fase I es infinitesimalmente más pequeña que la fase II, por lo que la fase I puede ser despreciada para fines prácticos [7].

2.3.3.2. Ventana de Theiler y trayectorias contiguas

Se debe notar que la trayectoria original y vecina son usualmente segmentos de la misma serie de tiempo, pero con diferentes puntos iniciales, como se ilustra en la Figura 2.13 [6].

Con el fin de garantizar que las trayectorias se encuentren temporalmente separadas y que pueden ser consideradas como trayectorias diferentes, dos puntos contiguos de la trayectoria original y vecina deben estar separados en una cantidad w , denominada Ventana de Theiler. En este caso aproximado se tiene que $\delta'(k\Delta t) \approx \delta(k\Delta t + w)$. Esta ventana debe ser determinada de acuerdo con las características de cada sistema dinámico. Para un SEP, de acuerdo con lo demostrado en [5], [6], esta ventana puede corresponder a la que se obtiene con dos muestras consecutivas obtenidas de una unidad PMU, cuando las frecuencias de muestreo se encuentran entre 30-120 Hz.




Figura 2.13. Trayectoria original y vecina obtenidas de la misma serie de tiempo

2.3.3.3. Teorema de Takens y simplificación del cálculo

Por otro lado, se debe tener presente que en la teoría original de los LE, se analiza la dinámica del espacio de estado completo del sistema dinámico, es decir, la tasa de divergencia (o convergencia) relacionada con todas las variables de estado del sistema. No obstante, incluso un SEP de tamaño moderado puede tener cientos de variables de estado, por lo que no es práctico utilizar todas estas variables del espacio de estado para la estimación del LLE. Con este antecedente, se ha planteado la modelación aproximada de la dinámica del SEP con solo un pequeño número de variables de estado [6].

De acuerdo con el teorema de Takens [47], la dinámica de un sistema dinámico no lineal puede reconstruirse a través de observaciones de una sola variable de estado. Es decir la evolución de un componente en un sistema no lineal se ve afectada por los cambios de otros componentes y, por lo tanto, la información de todos estos componentes relacionados está inherentemente incluida en un componente único. A partir de esta consideración, en

[6], [7] se desarrollan varias simplificaciones en la expresión 2.9. *En resumen, se demuestra que esta expresión es válida tanto para una trayectoria como para una serie de tiempo de una variable de estado en particular del sistema dinámico. Por ejemplo, en la expresión 2.9, el término δ puede hacer referencia al voltaje, ángulo del rotor, etc.*

2.3.3.4. Métodos de estimación de la pendiente expresada como LLE

Como se explicó antes, en la expresión 2.9 se estima la pendiente de la distancia logarítmica definida en la fase II de la evolución de trayectorias vecinas, según se mostró en la Figura 2.12. Sin embargo, en el estado del arte se han planteado diferentes métodos de estimación de esta pendiente.

2.3.3.4.1. Pendiente de una recta

Se trata del enfoque clásico explicado para la expresión 2.9, en donde el LLE es la pendiente entre dos puntos de la distancia logarítmica situados en la fase II de la evolución de trayectorias vecinas (Figura 2.12). Se ha demostrado que este método puede conllevar a errores significativos tomando en cuenta que la distancia logarítmica puede presentar fluctuaciones caóticas que representen desviaciones en el cálculo de la pendiente. Además, solo se están considerando dos puntos (inicial y final) de una dinámica inherentemente compleja enriquecida con mucha más información [34].

2.3.3.4.2. Mínimos cuadrados

La pendiente también puede ser estimada a través de un modelo de regresión lineal. Esto teniendo en cuenta que las influencias de los errores de medición y las fluctuaciones no lineales y caóticas que se pueden presentar en la evolución de un sistema dinámico pueden provocar un comportamiento altamente disperso en las observaciones. En consecuencia, algunas investigaciones presentan el planteamiento del algoritmo de mínimos cuadrados para estimar el LLE [3], [9]. En la Figura 2.14 se esquematiza la dispersión que puede presentar una serie de tiempo en la estimación del LLE y cómo el modelo de regresión lineal es una alternativa para abordar el problema.

2.3.3.4.3. Promedio móvil

En [48] se plantea un método alternativo que permite abordar apropiadamente las influencias de los errores de medición y las fluctuaciones no lineales y caóticas que se pueden presentar en la evolución de un sistema dinámico. En este caso, se formula el cálculo del LLE a través de promedios móviles desarrollados sobre un número específico de muestras de la serie de tiempo, denominadas como *Condiciones Iniciales*.




Figura 2.14. Estimación de la pendiente LLE a través de un modelo de regresión lineal




Figura 2.15. Estimación del LLE a través de un promedio móvil

En esta perspectiva, la idea básica es tomar N condiciones iniciales y estudiar su evolución en el tiempo. De esta manera, el LLE en un instante t se define como la distancia entre trayectorias vecinas en el instante t , normalizada con la distancia entre trayectorias al instante inicial y este resultado promediado sobre un número de condiciones iniciales. Considerando que, en una serie de tiempo, se trabajan con observaciones muestreadas en un tiempo discreto con período Δt , en la Figura 2.15 se esquematiza la metodología de cálculo a través de un promedio móvil.

Sea δ una serie de tiempo que evoluciona dinámicamente en el tiempo, entonces la distancia entre la trayectoria original $\delta(\Delta t)$ y vecina $\delta'(\Delta t)$, considerando los teoremas de Oseledec y Takens y definiendo la ventana de Theiler igual al período de muestreo Δt , se tiene que en un tiempo discreto $k\Delta t$, con $k > N$:

$$\delta'(k\Delta t) \approx \delta((k+1)\Delta t) \quad (2.10)$$

$$d(k\Delta t) = |\delta((k+1)\Delta t) - \delta(k\Delta t)| \quad (2.11)$$

Reemplazando las expresiones anteriores en la ecuación 2.9, se tiene:

$$\lambda = \frac{1}{k\Delta t} \log \left| \frac{\delta((k+1)\Delta t) - \delta(k\Delta t)}{\delta(\Delta t) - \delta(0)} \right| \quad (2.12)$$

Si se realizan N cálculos con la expresión anterior, desplazados en pasos de Δt , a través de una ventana móvil, según se esquematiza en la Figura 2.15, y se realiza un promedio de estos N valores del LLE se tiene la siguiente expresión final [4]:

$$\lambda(k\Delta t) \approx \frac{1}{Nk\Delta t} \times \sum_{m=1}^N \log \frac{|\delta((k+m)\Delta t) - \delta((k+m-1)\Delta t)|}{|\delta(m\Delta t) - \delta((m-1)\Delta t)|} \quad (2.13)$$

En el ANEXO A se expone un ejemplo de aplicación del LLE para el sistema dinámico del péndulo doble, en donde se emplea la expresión 2.13 y se exponen las particularidades de la dinámica de este indicador frente a condiciones estables o inestables.

2.3.4. Perspectivas de aplicación del LLE

- El LLE permite caracterizar el fenómeno de estabilidad de un sistema dinámico. No obstante, se debe preespecificar una ventana de tiempo para la observación LLE. El tamaño de la ventana es crucial para obtener resultados de evaluación confiables y oportunos, es decir, un tamaño de ventana muy pequeño generará resultados de evaluación poco confiables, mientras que un tamaño de ventana demasiado grande generará resultados precisos pero inoportunos [4], [6].

- El LLE es una serie de tiempo que se calcula después de $2N + 2$ muestras de tiempo de la serie de tiempo original poscontingencia. Este retardo tiene implicaciones que deben abordarse apropiadamente en análisis en tiempo real [5].
- El uso del LLE surge en las últimas décadas debido a que existe la posibilidad de describir la dinámica de un SEP a partir de series de tiempo obtenidas de PMU. Esto evita los enfoques tradicionales de cálculo que implicaban la necesidad de un modelo analítico del sistema dinámico. El uso del LLE constituye, por lo tanto, en un método híbrido para TSA [5].
- El LLE es considerado como un indicador de estabilidad de un sistema dinámico que puede brindar o desentrañar más información que las señales originales del sistema analizado. Por ejemplo, en un SEP, el LLE puede contener información más expresa del fenómeno de estabilidad que las mismas series de tiempo del ángulo del rotor. En este sentido, cabe destacar que dado que se ha demostrado que los SEP pueden ser caóticos, entonces existirá incertidumbre en las predicciones basadas únicamente en señales del ángulo del rotor. En su lugar, el LLE es capaz de desentrañar información valiosa de la dinámica del sistema y abordar el comportamiento caótico de mejor forma mostrándolo aparentemente como un comportamiento predictivo [8]. Además, se ha demostrado que el LLE reduce errores de modelo y simplifica los cálculos [5].

2.4. Minería de Datos

El proceso completo de metodologías para descubrir conocimiento a partir de datos se denomina Minería de Datos, una tarea que cada vez se hace más importante [49] en el contexto de las redes eléctricas inteligentes. En este apartado se describen los principales conceptos y herramientas de Minería de Datos empleados en este trabajo.

2.4.1. Generación de datos mediante el Método de Montecarlo

El comportamiento de muchos sistemas dinámicos se ve influenciado por variables de entrada que son esencialmente estocásticas o aleatorias. De esta manera, existe una permanente incertidumbre en el análisis de estos sistemas considerando que no todos los escenarios posibles pueden ser explorados. En este contexto, una de las técnicas probabilísticas aplicadas para abordar la incertidumbre en las variables de entrada y así manejar de una manera más realista este tipo de problemas es el método de Simulaciones de Montecarlo. Este método es atractivo porque permite simular fenómenos complejos de modo simplificado caracterizando el sistema a través de la aleatoriedad de las entadas.

En análisis de SEP, la generación de datos mediante Simulación de Montecarlo es una técnica utilizada comúnmente para la creación de eventos de contingencia considerando variabilidad en estados operativos, condiciones de las contingencias, parámetros de los elementos, etc. Estos datos se convierten en un insumo para la identificación de patrones o el entrenamiento de algoritmos de Aprendizaje Automático, [1].

2.4.2. Técnicas de Minería de Datos

El conocimiento obtenido a partir de grandes volúmenes de datos, a través de Minería de Datos, se consigue mediante la identificación o extracción de patrones inmersos en los datos, como se esquematiza en la Figura 2.16.




Figura 2.16. Proceso de descubrimiento de conocimiento mediante Minería de Datos [1]

A continuación, se describen diferentes técnicas empleadas en este trabajo que están diseñadas para el análisis multivariante de datos (datos constituidos por diferentes variables o características).

2.4.2.1. Análisis Exploratorio de Datos

El Análisis Exploratorio de Datos (EDA, por sus siglas en inglés) es una fase inicial del estudio de datos, que está orientado a la familiarización de los datos. En esta fase preliminar se utilizan técnicas matemáticas sencillas y representaciones gráficas. En esta fase es posible evidenciar las relaciones más evidentes que existen entre las variables y que se pueden caracterizar y cuantificar con un análisis más profundo. Por otro lado, el EDA permite también estudiar las principales características de la distribución de las variables y detectar sus valores atípicos mediante estadística inferencial.

En este contexto, se estudia la estructura de los datos mediante una valoración estadística de las variables involucradas. Típicamente, se estiman diferentes estadísticos como: la media, mediana, la desviación estándar, varianza, coeficiente de variación, asimetría o Skewness, Kurtosis, etc., [50]. Además, se cuantifican y clasifican los datos u observaciones según una característica dependiente o de salida.

Algunos elementos gráficos típicos de análisis son los histogramas, los diagramas de caja, las gráficas y matrices de dispersión, etc.

2.4.2.2. Ingeniería de Características

El análisis de datos implica un manejo adecuado de los mismos para que puedan ser estudiados de la manera más flexible posible. En este sentido, los datos comúnmente se estructuran a través de una matriz de dimensión $n \times p$, en donde n refleja el número de entidades u observaciones y p el número de variables que describen cada observación o características (features) [50]. Con el fin de contar con la mejor versión posible de la matriz de datos para un análisis libre de ruido y eficiente a nivel computacional, se cuenta con la técnica de Ingeniería de Características, la cual tiene principalmente dos enfoques: Selección de Características y Extracción de Características [51].

2.4.2.2.1. Selección de características (Feature selection)

La selección de características consiste en escoger un subconjunto de características de las características originales para reducir la complejidad del modelo analizado (Reducción de Dimensionalidad), mejorar la eficiencia computacional de los algoritmos que tratan con los datos (algoritmos de Aprendizaje Automático) y reducir el error debido al ruido causado por características irrelevantes. Para la selección de características el científico de datos puede emplear técnicas empíricas para esta selección o basarse en la aplicación de técnicas de Feature Importance (Importancia o Significancia de Características), es decir, a partir de una métrica que pondere la influencia de las características en el modelo [51].

2.4.2.2.2. Extracción de características (Feature extraction)

La Extracción de Características consiste en derivar información a partir del conjunto de características original. Esto con el fin de crear un subespacio vectorial de características. Al igual que con las técnicas de selección de características, estas técnicas también se utilizan para reducir la cantidad de características del conjunto original. Es así como es posible reducir la complejidad del modelo, mejorar la eficiencia para los cálculos y reducir errores por ruido. Algunas técnicas de Extracción de Características son el Análisis de Componentes Principales (PCA), Análisis Discriminante Lineal (LDA) y Funciones Empíricas Ortogonales (EOF, por sus siglas en inglés).

Otros enfoques de Extracción suelen ser asociados con el tratamiento de datos a través de escalamiento, normalización o estandarización. También suelen incluirse manipulaciones matemáticas empíricas para resaltar alguna propiedad del conjunto de datos.

Cabe destacar que en el enfoque de extracción de características se procura no distorsionar las relaciones originales o la información significativa de los datos, es decir, preservar la esencia de la información de los datos [51].

2.4.2.3. Reducción de dimensionalidad y simplificación de modelos

Como se mencionó antes, como parte de la Ingeniería de Características, es posible tratar el conjunto de datos con técnicas que permitan simplificar los modelos interpretándolos desde otros espacios vectoriales que permiten extraer mejor la información de los datos.

2.4.2.3.1. Componentes Principales

El Análisis de Componentes Principales es una técnica ampliamente utilizada por su simplicidad y prestaciones. Este análisis permite reducir la dimensionalidad aprovechando estimaciones de variabilidad. En esta técnica se transforma el conjunto de datos en uno nuevo, en donde las variables se denominan Componentes Principales, las cuales no están correlacionadas y se encuentran ordenadas de modo que los primeros componentes contienen la mayor parte de la variación presente en las variables originales [50].

Las componentes se determinan al aplicar Descomposición en Valores Singulares (SVD) a la matriz de covarianza (S) del conjunto de datos original. Sea X la matriz de datos original, las componentes principales se obtienen con:

$$Z = XU \quad (2.14)$$

Donde U es la matriz que contiene los autovectores de S . S y U se relacionan con:

$$S = U\Lambda U' \quad (2.15)$$

Donde Λ es una matriz diagonal que contienen en sus elementos a los autovalores λ_i de S .

Con la finalidad de reducir la dimensionalidad del problema, se seleccionan aquellas componentes que contienen la mayor variabilidad (principales). Esto se realiza asociando cada componente con el correspondiente autovalor λ_i e introduciendo el concepto de *Variabilidad Explicada* (VE), la cual se calcula con la expresión 2.16. De esta forma, el número de componentes elegidas depende de la variabilidad explicada deseada.

$$EV_i = \frac{\lambda_i}{\sum_{j=1}^p \lambda_j} \cdot 100\% \quad (2.16)$$

2.4.2.3.2. Funciones Empíricas Ortogonales

Las Funciones Empíricas Ortogonales (EOF) son un método novedoso de reconocimiento de patrones usado en investigaciones con DVA que han mostrado resultados satisfactorios en cuestión de simplicidad y precisión [1], [52]. Estas funciones se obtienen de la aplicación de la descomposición *SVD* a series de tiempo, lo cual las diferencian de las PCA.

Esta técnica permite descomponer una función discreta de tiempo $f(t)$ (por ejemplo, el ángulo o magnitud de un voltaje) en una suma de un conjunto discreto de funciones patrón llamadas EOF. De esta manera, es posible extraer las componentes individuales más predominantes de una señal, lo cual permite identificar patrones inmersos [52]. Para la aplicación de las EOF, la matriz de datos $n \times p$ se interpreta de una manera especial. Las n observaciones corresponden al número de series o señales. El número p representa las muestras temporales de la serie. Así se estructura la matriz \mathbf{F} , que contiene en cada fila una serie de tiempo $f(t)$; por ejemplo, las mediciones obtenidas de PMU. Entonces:

$$\mathbf{F} = \begin{pmatrix} \mathbf{f}_1(t) \\ \vdots \\ \mathbf{f}_n(t) \end{pmatrix} = \begin{pmatrix} x_{11} & \cdots & x_{1p} \\ \vdots & \ddots & \vdots \\ x_{n1} & \cdots & x_{np} \end{pmatrix} \quad (2.17)$$

Donde f_k es la k -ésima función discreta de tiempo medida a través de p muestras. La descomposición *SVD* de la matriz rectangular \mathbf{F} es una factorización de la forma:

$$\mathbf{F}_{np} = \mathbf{U}_{nn} \mathbf{\Lambda}_{np}^{1/2} \mathbf{V}'_{pp} \quad (2.18)$$

Donde \mathbf{U} es una matriz ortogonal cuyas columnas son los autovectores de $\mathbf{F}\mathbf{F}'$, \mathbf{V}' es la matriz ortogonal transpuesta cuyas columnas son los vectores ortonormales de $\mathbf{F}'\mathbf{F}$, y $\mathbf{\Lambda}^{1/2}$ es una matriz diagonal cuyos elementos son la raíz cuadrada de los autovalores de \mathbf{U} (llamados también valores singulares).

La descomposición de la matriz \mathbf{F} puede ser escrita de la siguiente forma:

$$\mathbf{F} = (\mathbf{u}_1 \quad \cdots \quad \mathbf{u}_n)_{nn} \begin{pmatrix} \lambda_1^{1/2} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \lambda_p^{1/2} \\ 0 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & 0 \end{pmatrix}_{np} \begin{pmatrix} \mathbf{v}'_1 \\ \vdots \\ \mathbf{v}'_p \end{pmatrix}_{pp} \quad (2.19)$$

Esta expresión puede ser escrita de manera compacta como:

$$\mathbf{F} = \sum_{i=1}^p \lambda_i^{1/2} \mathbf{u}_i \mathbf{v}'_i \quad (2.20)$$

De esta manera, cada serie de tiempo puede ser expresada según la siguiente ecuación.

$$\mathbf{f}_k = \lambda_1^{1/2} u_{k1} \mathbf{v}_1 + \lambda_2^{1/2} u_{k2} \mathbf{v}_2 + \cdots + \lambda_p^{1/2} u_{kp} \mathbf{v}_p \quad (2.21)$$

Es así como f_k se puede descomponer en una suma de un conjunto de funciones discretas (\mathbf{v}_j), conocidas como vectores patrón o funciones EOF, que son ortogonales y están

ponderadas por coeficientes reales de la forma $a_{kj} = \lambda_j^{1/2} u_{kj}$, los cuales se denominan EOF scores. Por lo tanto, la matriz F puede expresarse como.

$$F = \sum_{i=1}^p \mathbf{a}_i v_i' \quad (2.22)$$

Donde \mathbf{a}_i es el i -ésimo vector cuyos elementos son los a_{ij} EOF scores. En este caso, todas las a_{ij} EOF scores pueden ser calculadas de forma matricial con la siguiente expresión:

$$A_{np} = U_{nn} \Lambda_{np}^{1/2} \quad (2.23)$$

Donde A es la matriz de EOF scores. A partir de las expresiones anteriores se puede derivar lo siguiente:

$$F_{np} = A_{np} V_{pp}' \quad (2.24)$$

De esta última ecuación, tomando en cuenta la característica ortogonal de V' de ser igual a su matriz inversa, la matriz A puede ser calculada del siguiente modo:

$$A_{np} = F_{np} V_{pp} \quad (2.25)$$

La suma de los valores singulares de $F(\lambda_i^{1/2})$ es una medida de la varianza total de la matriz de datos, por lo que cada valor singular refleja la correspondiente variabilidad VE. Es así como el número de funciones EOF seleccionadas para reducir la dimensionalidad del problema depende de la VE deseada. De manera empírica, es usual que se grafiquen los valores singulares en orden descendente en un diagrama conocido como Diagrama de Codo (Elbow plot), para asociar el punto de inflexión de la curva con el número de EOF que se sugiere que brindan una VE aceptable para el problema analizado [1].

Una característica atractiva de las funciones EOF es que permiten una mejor adaptación al conjunto de series de tiempo en comparación con otras técnicas como las Series de Fourier, las cuales consideran solo funciones trigonométricas predefinidas [1].

2.4.2.4. Visualización de datos

La visualización de datos se constituye como una herramienta básica que permite una representación gráfica de los datos que oriente de forma preliminar características relevantes de los fenómenos analizados. En este sentido, existen gráficas con diferentes grados de complejidad que permiten analizar datos con un enfoque simplificado. Se tienen desde las representaciones gráficas más simples de estadística univariante, como histogramas, diagramas de caja o gráficos de dispersión; hasta gráficos más

especializados como gráficas de contorno, mapas de calor, dendrogramas, diagramas de dashboard y gráficas para datos multivariantes. En este sentido, se mencionan detalles de algunos tipos de gráficos especializados usados en el presente trabajo.

2.4.2.4.1. *Coordenadas Paralelas*

Una de las técnicas de visualización considerada en este trabajo corresponde al gráfico de tipo *Coordenadas Paralelas*. En este gráfico es posible la observación de espacios vectoriales multidimensionales y, por lo tanto, se puede comparar el conjunto de características de varias observaciones individuales [53], [54]. Cada barra vertical de este gráfico representa una coordenada, variable o característica de las observaciones. Luego, los valores se trazan como una serie de líneas conectadas a través de cada eje paralelo. En este gráfico es factible la identificación de tendencias, valores atípicos e inclusive grupos de datos (*clusters*) en el conjunto de datos. En la Figura 2.17 se expone un ejemplo de gráfico de coordenadas paralelas para el conjunto de datos *Iris*, en donde se aprecia una representación de datos multivariantes [55].

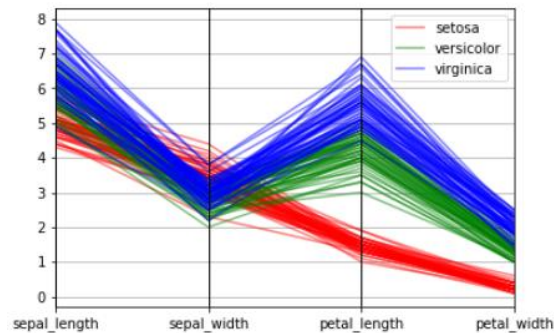


Figura 2.17. Ejemplo de coordenadas paralelas para el conjunto de datos *Iris* [55]

2.4.2.4.2. *Algoritmo de RadViz*

El algoritmo de visualización de coordenadas radiales o de RadViz es una técnica empleada para identificar la existencia de patrones en conjuntos de datos multidimensionales. En este gráfico las dimensiones se asocian con puntos denominados anclajes dimensionales (*dimensional anchors DAs*) localizados en una representación circular o esférica, es decir, a través de un espacio bidimensional o tridimensional respectivamente [48], [56]. En este algoritmo de visualización, las observaciones se localizan dentro de un círculo o una esfera en función de su atracción relativa a cada uno de los anclajes dimensionales.

La atracción hacia cada anclaje se determina a partir de la magnitud de cada característica de la observación que se grafica. La formulación más básica de RadViz es que la función

de atracción sea directamente proporcional a la magnitud de la característica correspondiente. De esta manera, se tiene que para una observación i , las correspondientes coordenadas x_i y y_i de RadViz en una representación bidimensional están dadas por la expresión 2.26 y 2.27.

$$x_i = \frac{\sum_{j=1,\dots,d} a_{ij} \cos(\theta_j)}{\sum_{j=1,\dots,d} a_{ij}} \quad (2.26)$$

$$y_i = \frac{\sum_{j=1,\dots,d} a_{ij} \sin(\theta_j)}{\sum_{j=1,\dots,d} a_{ij}} \quad (2.27)$$

Donde θ_j es la posición angular en el círculo correspondiente de la característica j , a_{ij} es la característica j de la observación i , de un total de d características. En la Figura 2.18 se presenta un ejemplo de representación de RadViz para datos de 4 características.




Figura 2.18. Ejemplo del algoritmo de RadViz con 4 características [48]

La localización de una observación también se puede entender como el punto de equilibrio que resulta al unir la observación con resortes ajustados en cada DA, en donde la fuerza de cada resorte es proporcional a la magnitud de las características de la observación. Cuanto mayor sea el valor de una característica en particular, más cerca estará el punto proyectado hacia el DA correspondiente.

2.4.2.4.3. Curvas de Andrews

Las Curvas de Andrews son una representación gráfica de estructuras de datos de dimensiones elevadas propuesta por David Andrews en [57]. Andrews sugiere la idea de codificar y representar datos multivariantes mediante curvas seno y coseno. En este sentido, una observación con p características $\{x_1, x_2, \dots, x_p\}$ se transforma en una Curva de Andrews mediante una función finita de p términos dada por la expresión 2.28.

$$f_x(t) = \frac{x_1}{\sqrt{2}} + x_2 \sin(t) + x_3 \cos(t) + x_4 \sin(2t) + x_5 \cos(2t) + \dots \quad (2.28)$$

Es decir, las características de una observación constituyen los coeficientes de una serie de Fourier representada en el dominio $t \in [-\pi, \pi]$.

La visualización de datos mediante las Curvas de Andrews puede entenderse también como una proyección del conjunto de observaciones sobre el vector $(\frac{1}{\sqrt{2}}, \sin(t), \cos(t), \sin(2t), \cos(2t), \dots)$. En el caso de que existan patrones o estructuras embebidas en los datos, estas pueden ser visibles en las Curvas de Andrews. Estas curvas han sido utilizadas en múltiples campos, como biología, neurología, sociología, electrónica, etc. Algunos de los análisis que se pueden desarrollar son la detección de períodos y valores atípicos en las series temporales [57].

2.5. Aprendizaje Automático

El Aprendizaje Automático (o Machine Learning, en inglés) es un subcampo de la Inteligencia Artificial, cuyo objetivo es desarrollar algoritmos capaces de permitir que las computadoras realicen tareas análogas al aprendizaje de una persona y así sea posible la automatización de tareas [58]. En esta sección se proporciona una descripción de los conceptos de Aprendizaje Automático más importantes abordados en el presente trabajo.

2.5.1.1. Modelos de Aprendizaje Automático

2.5.1.1.1. Conjunto de Hipótesis de un algoritmo

Este conjunto contiene las funciones de mapeo (hipótesis) que relacionan datos de entrada, que poseen determinadas características, con un conjunto de etiquetas o variable *target* de salida [59]. Estas funciones usualmente no pueden ser determinadas de manera explícita en algoritmos de Aprendizaje Automático y su complejidad o simplicidad tiene incidencias en la eficiencia del algoritmo y en el sobreajuste o subajuste que podría existir con hipótesis poco o demasiado generalizables respectivamente.

Típicamente, la solución de un problema de Aprendizaje Automático consiste en seleccionar una función de un conjunto de hipótesis que permita relacionar con mayor precisión el conjunto de datos de entrada con la etiqueta de salida (técnica denominada comúnmente como aprendizaje supervisado) [59].

2.5.1.1.2. Elementos en un modelo de Aprendizaje

Las metodologías ampliamente difundidas de Aprendizaje Automático emplean conceptos comunes para los elementos que conforman los diferentes algoritmos. Entre ellos se tiene:

- Hiperparámetros.- Se trata de parámetros independientes o libres que no están determinados por el algoritmo de aprendizaje, sino que se especifican como entradas para el algoritmo.
- Conjunto de entrenamiento.- Corresponde a las muestras tomadas para el entrenamiento del algoritmo. Estas muestras deben ser representativas del conjunto de datos y comúnmente comprenden una porción de 70%, 80% o 90% del conjunto de datos original.
- Conjunto de validación.- Se trata de una porción del conjunto de datos utilizado para el ajuste de los parámetros de un algoritmo. Las muestras de validación se usan para seleccionar apropiadamente los valores para los parámetros libres de un algoritmo (hiperparámetros).
- Conjunto de prueba.- Se trata de las muestras utilizadas para evaluar el desempeño de un algoritmo de aprendizaje. Estas muestras se separan del conjunto de entrenamiento y no están presentes en la etapa de aprendizaje para evitar que los algoritmos *memoricen* la información del conjunto de datos y así se pierda capacidad de generalización. En muchos casos, el conjunto de prueba y validación se usan indistintamente como el mismo conjunto.
- Función de costo.- La función de costo mide con algún criterio cuantificable la diferencia entre la etiqueta que se predice y el valor real o esperado de esa etiqueta.

2.5.1.1.3. Clasificación y regresión

Existen dos tareas del Aprendizaje Automático usadas con alta frecuencia en Inteligencia Artificial. Se trata de las tareas de Clasificación y Regresión. Los algoritmos de Clasificación se enfocan en predecir la segmentación del conjunto de datos, los cuales están divididos por una etiqueta de clases. De esta manera, la predicción es *esencialmente* discreta. En la Figura 2.19 se presentan diferentes ejemplos de clasificación obtenida con varios algoritmos para tres conjuntos de prueba de dos clases (observaciones en rojo y en azul). Los algoritmos tratan de buscar la mejor frontera de separación (Boundary) que discrimina las clases de datos para desarrollar la predicción.

Por otro lado, en el caso de modelos de regresión, la etiqueta de salida es un valor no discreto, por ejemplo, un número real. En esta situación, la predicción del algoritmo se enfoca en identificar un valor continuo cercano al valor esperado. En la Figura 2.20 se presentan ejemplos de resultados de regresión que ilustran los conceptos de subajuste y sobreajuste que pueden sufrir los algoritmos.




Figura 2.19. Ejemplos de resultados de clasificación con diferentes algoritmos de Aprendizaje Automático [54]




Figura 2.20. Ejemplos de resultados de regresión obtenidos en diferentes casos de subajuste, buen ajuste y sobreajuste [60]

2.5.1.2. Algoritmos de Aprendizaje Automático

2.5.1.2.1. Máquinas de soporte vectorial

Las Máquinas de Soporte Vectorial (SVM) constituyen un algoritmo de aprendizaje que puede ser utilizado para tareas de clasificación (SVC) y regresión (SVR). Las SVM han demostrado en muchos casos los mejores desempeños con respecto a otros algoritmos [1]. Este algoritmo pertenece al conjunto de los denominados métodos Kernel y es usualmente robusto para evitar problemas de sobreajuste.

Con respecto al algoritmo SVC, se consideran hipótesis que clasifican los datos a través de la definición de un plano de separación multidimensional, denominado hiperplano. Este hiperplano es determinado a través de un proceso de optimización con el fin de obtener la mejor separación posible entre clases de datos.

La Figura 2.21 ilustra la solución del algoritmo para un problema de clasificación entre datos segmentados por dos clases (puntos en rojo y en azul). Se define un hiperplano óptimo con base en observaciones conocidas como vectores soporte de cada clase.




Figura 2.21. Vectores soporte y separación de un Hiperplano del algoritmo SVC [59]

En este sentido, sea el conjunto de entrenamiento de pares de observaciones y etiquetas (x_i, y_i) , $i = 1, \dots, m$. Donde $x_i \in R^n$ y $y \in \{1, -1\}^m$, para un problema de clasificación de dos clases. De esta manera, la solución del problema consiste en la búsqueda de la ecuación del hiperplano óptimo que separa ambas clases. Es decir:

$$\min_{w, b, \xi} \quad \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^m \xi_i \quad (2.29)$$

$$\text{sujeto a} \quad y_i(\mathbf{w}^T \phi(x_i) + b) \geq 1 - \xi_i, \quad (2.30)$$

$$\xi_i \geq 0$$

Donde \mathbf{w} es un vector n -dimensional que contiene los coeficientes del hiperplano o un vector de ponderaciones, b es un término de sesgo o *bias*, ξ_i es una variable de holgura definida para abordar situaciones en donde no se puede conseguir una separación exacta. C es esencialmente un parámetro de regularización, que controla el equilibrio entre lograr un error bajo en los datos de entrenamiento (cuando no existe una separación exacta) y minimizar la norma de las ponderaciones.

Por otro lado, el término $\phi(x_i)$ representa una función de x hacia un nuevo espacio vectorial, comúnmente llamada *función Kernel* $\mathbf{K}(x_i, x_j)$, que se define como:

$$\mathbf{K}(x_i, x_j) \equiv \phi(x_i)^T \phi(x_j) \quad (2.31)$$

Existen diferentes alternativas de funciones Kernel, las más populares son: lineales, polinomiales y las funciones de base radial (RBF, por sus siglas en inglés). En este trabajo se utiliza la función Kernel RBF de la expresión 2.32, debido a que se ha probado que es capaz de manejar posibles relaciones no lineales entre etiquetas y características [1].

$$\mathbf{K}(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \quad \gamma > 0 \quad (2.32)$$

En el entrenamiento del algoritmo se busca el conjunto óptimo de w , b y ξ que minimiza la función objetivo, mientras que los parámetros C y γ deben ser definidos previamente, por lo que constituyen los hiperparámetros del algoritmo SVC.

2.5.1.2.2. Árboles de decisión y Random Forest

Un árbol de decisión es un algoritmo que predice una etiqueta de salida cuando la observación x asociada viaja desde un nodo raíz de una estructura tipo árbol hasta una hoja o terminal. En cada nodo del camino de la raíz a la hoja, se divide el espacio de entrada para determinar el siguiente camino por el que viajará la observación. La división del espacio se realiza a partir de reglas de partición. Estas reglas se basan en características de x . El algoritmo itera hasta llegar a obtener hojas con una etiqueta específica.

En la Figura 2.22 se ilustra un ejemplo didáctico que resume lo mencionado. Se considera un ejemplo con dos características (X_1 , X_2) y 5 regiones o clases. Cada nodo interior del árbol corresponde a una pregunta relacionada con las características. En definitiva, el entrenamiento del algoritmo significa encontrar las reglas de partición que proporcionan la mejor predicción para un conjunto de observaciones dado. Para estimar la calidad de la partición, se consideran diferentes métricas, típicamente se usan las siguientes métricas: Error de clasificación, Impureza de Gini y Entropía [58].

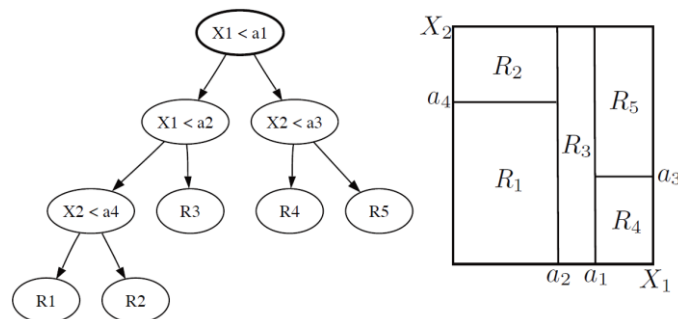


Figura 2.22. Ejemplo de un árbol de decisión con preguntas numéricas basado en dos características X_1 y X_2 y 5 clases o regiones posibles [59]

Los árboles de decisión suelen ser rápidos de entrenar, evaluar y fáciles de interpretar. No obstante, en este algoritmo aparecen diferentes inconvenientes. Por una parte, se pueden tener diferentes reglas de partición para un mismo conjunto de datos y, por otro lado, con diferentes conjuntos de entrenamiento se podrían obtener resultados muy distintos. Es decir, existe una varianza que hace que los modelos no puedan ser generalizables.

Por esta razón, se han planteado mejoras que surgen de la combinación de varios algoritmos (métodos *Ensemble*). Una propuesta es el uso de árboles de forma combinada, como si se tratara de un bosque de árboles (*Forest*). Esto como una estrategia para reducir

la varianza y que el algoritmo conjunto sea menos sensible a los datos de entrenamiento. En el algoritmo de Bosque, para manejar el desempeño conjunto, se utiliza el algoritmo Bootstrap. Este algoritmo realiza un muestreo aleatorio del conjunto de entrenamiento para asignar un subconjunto de datos para cada árbol del bosque. Bootstrap permite que el modelo sea menos sensible a los datos de entrenamiento al evitar que el mismo conjunto de datos sea probado en todos los árboles. Además, en cada árbol se considera por separado únicamente ciertas características para las reglas de partición, las cuales son escogidas de forma aleatoria. Es por esta razón que se conoce al algoritmo como *Random Forest*. La selección de características aleatoria reduce la correlación entre árboles [58].

2.5.1.2.3. *Nearest Shrunken Centroid*

El algoritmo *Nearest Shrunken Centroid* (NSC) se trata de una variación del método del Vecino Cercano (*Nearest Neighbor*). El método *Nearest Neighbor* memoriza el conjunto de entrenamiento y luego predecir la etiqueta de una nueva observación con base en las etiquetas de sus vecinos más cercanos. En este sentido, sea ρ , la distancia entre dos observaciones de la matriz de datos X (definida por ejemplo por la métrica Euclídea). La distancia entre dos elementos es $\rho(x, x') = \sqrt{\sum_{i=1}^p (x_i - x'_i)^2}$, donde x_{ij} es un elemento en la matriz, con $i = 1 \dots n$ como la i -ésima observación y $j = 1 \dots p$ como la j -ésima característica. Con t muestras de entrenamiento, para cada $x \in X$, sea $\pi_1(x), \dots, \pi_t(x)$ un conjunto de distancias ordenadas según su distancia a x , $\rho(x, x_i)$ [61]. Es decir:

$$\rho(x, x_{\pi_i(x)}) \leq \rho(x, x_{\pi_{i+1}(x)}) \quad (2.33)$$

Entonces la regla de clasificación, conocida como regla k-NN implica que para una observación nueva x , la etiqueta predicha corresponde a aquella que existe en la mayor parte de observaciones que cumplen con $i \leq k$.

En el caso particular del algoritmo NSC, sea C el número de clases, K_m el conjunto de las n_m muestras pertenecientes a la clase m . Es así como el j -ésimo componente del centroide de la clase m (promedio de la característica j en la clase m) es:

$$\bar{x}_{mj} = \sum_{i \in K_m} x_{ij} / n_m \quad (2.34)$$

A su vez, el j -ésimo término del centroide general es:

$$\bar{x}_j = \sum_{i=1}^n x_{ij} / n \quad (2.35)$$

En el algoritmo NSC, los centroides de clase se contraen hacia los centroides generales, una vez que se estandariza cada variable por la desviación estándar dentro de la clase. De esta forma, se pondera con un peso mayor a las características cuya expresión es estable dentro de las muestras de una misma clase. Si se considera la diferencia:

$$d_{mj} = \frac{\bar{x}_{mj} - \bar{x}_j}{q_m(s_j + s_0)} \quad (2.36)$$

Donde s_j es la desviación dentro de la clase m en la característica j y $q_m = \sqrt{1/n_m + 1/n}$ permite que $q_m \cdot s_j$ sea equivalente al error estándar del numerador d_{mj} . El término s_0 es una constante incluida para limitar valores de d_{mj} . De esta manera, la expresión 2.36 puede reescribirse de la siguiente manera:

$$\bar{x}_{mj} = \bar{x}_j + q_m(s_j + s_0) \cdot d'_{mj} \quad (2.37)$$

En esta expresión se introduce una contracción (*shrink*) en cada d_{mj} (para producir centroides contraídos) en una cantidad Δ . Es decir:

$$d'_{mj} = \text{sign}(d_{mj}) \cdot (|d_{mj}| - \Delta) \quad (2.38)$$

En este algoritmo es posible que algunas características se eliminen de la predicción si los centroides de todas las clases en esas características se acercan lo suficiente al centroide general. Este efecto puede ser entendido como un tipo de *Feature Selection* [62].

2.5.1.2.4. Redes Neuronales Artificiales

Una Red Neuronal Artificial (ANN) o modelo Perceptrón Multicapa (MPL) es un algoritmo computacional inspirado en la estructura de las redes neuronales en el cerebro. Esta red se puede describir como un gráfico dirigido cuyos nodos corresponden a neuronas y los terminales corresponden a enlaces entre ellas. Cada neurona recibe como entrada una suma ponderada de las salidas de las neuronas conectadas a sus terminales de entrada. La idea detrás de las redes neuronales es que muchas neuronas pueden unirse mediante enlaces de comunicación para realizar cálculos complejos [59], [63].

El tipo de red típicamente usado es el modelo retroalimentado que se muestra en la Figura 2.23. Esta red está organizada por capas (*layers*): la inicial o de entrada V_0 , las capas V_1, \dots, V_{T-1} denominadas capas ocultas y la última capa denominada capa de salida. En donde T es el número de capas o la profundidad de la red. La capa de entrada tiene $p + 1$ neuronas, siendo p el número de características de los datos en entrada y una neurona adicional, cuya entrada es constante, la cual consisten en un término de sesgo o bias b .




Figura 2.23. Esquema de una red neuronal retroalimentada [59]

Sea $v_{t,i}$ la i -ésima neurona en la t -ésima capa y $o_{t,i}(\mathbf{x})$ la salida de $v_{t,i}$ cuando la red está alimentada con el vector de entrada \mathbf{x} . Por lo tanto, para un $i \in [p]$ se tiene $o_{0,i}(\mathbf{x}) = x_i$ y para $i = p + 1$ se tiene $o_{0,i}(\mathbf{x}) = 1$. De manera recursiva, si se supone que ya se han calculado las salidas de las neuronas en la capa t , entonces las salidas de las neuronas en la capa $t + 1$ se calculan de la siguiente forma. Al considerar el término $v_{t+1,j} \in V_{t+1}$ y $a_{t+1,j}(\mathbf{x})$ como la entrada a $v_{t+1,j}$. Entonces:

$$a_{t+1,j}(\mathbf{x}) = \sum_{r:(v_{t,r}, v_{t+1,j})} w((v_{t,r}, v_{t+1,j})) \cdot o_{t,r}(\mathbf{x}), \quad (2.39)$$

$$o_{t+1,j}(\mathbf{x}) = \sigma(a_{t+1,j}(\mathbf{x}))$$

Donde la entrada a $v_{t+1,j}$ es la suma ponderada de las salidas de las neuronas en V_t que están conectadas a $v_{t+1,j}$ y r representa el índice de las neuronas contenidas en la capa correspondiente. El término w define los pesos de ponderación. La salida de $v_{t+1,j}$ es simplemente el resultado de la aplicación de una función σ en su entrada. Cada neurona está modelada como una función escalar σ , conocida como función de activación. Las funciones de activación más comunes son la función signo, relu, sigmoide $\sigma(a) = 1/(1 + e^{-a})$ y tangente hiperbólica.

En el entrenamiento de una Red Neuronal se resuelve un problema de optimización que permite la determinación de los pesos asociados a las entradas de cada neurona y el término bias. Para la solución del problema se emplea típicamente el algoritmo conocido como Retropropagación, el cual se basa en el método del Gradiente Descendente para la optimización. Se debe notar que en el algoritmo del Gradiente existe un hiperparámetro conocido como la Tasa de Aprendizaje (Learning rate) que hace referencia al tamaño del paso con el que el algoritmo avanza en cada iteración o actualización del gradiente.

Adicionalmente, cabe resaltar que, de forma similar al algoritmo SVC, existe un hiperparámetro de regularización α en ANN, el cual está orientado a reducir los problemas de sobreajuste del algoritmo. Con la regularización se controla el equilibrio entre lograr un bajo error en la función de costo y minimizar la norma de las ponderaciones.

2.5.1.3. K-fold cross-validation

En la práctica, la cantidad de datos disponibles suele ser demasiado pequeña como para reservar un conjunto de prueba amplio, ya que se dejaría una cantidad insuficiente de datos de entrenamiento. Esto genera varios inconvenientes para los algoritmos de aprendizaje, principalmente problemas de sobreajuste. En este sentido, para el uso de Aprendizaje Automático, se utiliza un método ampliamente adoptado, conocido como validación cruzada k-fold (*k-fold cross validation*) para explotar de mejor manera los datos tanto para la selección del modelo como para el entrenamiento [61].

En este tipo de método, el conjunto original de entrenamiento de m observaciones se particiona en k subconjuntos (*folds*), cada uno de tamaño $\text{int}(m/k)$. Para cada subconjunto, el algoritmo se entrena con los demás subconjuntos, dejando que el error se estime con el subconjunto inicial. El entrenamiento se desarrolla k veces y el promedio de estos errores es asumido como el error final del modelo.

El método de k-fold cross validation es usualmente considerado para la selección del modelo, es decir, para la optimización de hiperparámetros, lo cual proporciona un resultado óptimo más robusto y menos sensible al conjunto de entrenamiento. Comúnmente, se utiliza un $k = 10$ debido a su tendencia a obtener la mejor estimación del error [1].

2.5.1.4. Métricas de calidad

Existen diferentes formas para evaluar el desempeño del resultado final del aprendizaje de un algoritmo de clasificación. Entre ellas se tiene:

2.5.1.4.1. Matriz de confusión

La matriz de confusión es una herramienta gráfica que permite relacionar la cuantificación entre la predicción conseguida para un conjunto de observaciones versus la etiqueta real de las mismas [64].

2.5.1.4.2. Accuracy

Esta métrica permite analizar el número de observaciones cuya etiqueta predicha coincide con la etiqueta real. Sea un conjunto de n observaciones; si \hat{y}_i es el valor predicho de la i -ésima observación y y_i el correspondiente valor real, entonces el accuracy se calcula como:

$$\text{accuracy}(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} 1(\hat{y}_i = y_i) \quad (2.40)$$

2.5.1.4.3. Precision

$$\text{precision} = \frac{tp}{tp + fp} \quad (2.41)$$

2.5.1.4.4. Recall

$$\text{recall} = \frac{tp}{tp + fn} \quad (2.42)$$

Donde tp son los verdaderos positivos, fp los falsos positivos y fn los falsos negativos.

2.5.1.4.5. f1-score

La métrica f1-score puede ser interpretada como la media armónica de las métricas precision y recall.

$$\text{f1-score} = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (2.43)$$

Para las métricas indicadas, una clasificación alcanza su mejor ponderación en 1 y su peor evaluación en 0.

2.5.1.5. Optimización bayesiana de hiperparámetros

La búsqueda de hiperparámetros en modelos de aprendizaje, que proporcione como resultado el mejor rendimiento, es necesaria en casi todos los casos prácticos para obtener un modelo con la mejor estimación de generalización [63]. El enfoque de optimización empleado en los últimos años, a través de programación en Python, es el uso del módulo *GridSearchCV*, el cual toma un conjunto de valores dentro de un dominio especificado para probar cada parámetro y así todas las combinaciones de valores de parámetros posibles. La complejidad de dicha búsqueda crece exponencialmente con la adición de nuevos parámetros. Un enfoque más práctico es el uso del módulo *RandomizedSearchCV*, en donde no se prueban todos los valores de los parámetros, sino que se muestrea un número fijo de configuraciones de parámetros con base en distribuciones probabilísticas especificadas. En esta perspectiva no se garantiza encontrar un mejor resultado con respecto a *GridSearchCV*, pero se mejoran los tiempos computacionales.

La librería *scikit-optimize* proporciona una mejora directa para *GridSearchCV* y *RandomizedSearchCV* con el módulo *BayesSearchCV*. En esta mejora se utiliza el concepto de Optimización Bayesiana, en donde solo se prueba un número fijo de

configuraciones de parámetros con base en una búsqueda orientada. El propósito de la Optimización Bayesiana es reducir la cantidad de veces que se debe calcular la Función Objetivo asociada, eligiendo solo el conjunto de hiperparámetros más prometedor para evaluar en función de los resultados anteriores de la función de evaluación. En este sentido, el siguiente conjunto de hiperparámetros se selecciona de una manera *inteligente* de acuerdo con un modelo de la Función Objetivo llamado *Función Sustituta*.

En la Optimización Bayesiana las evaluaciones pasadas de la Función Objetivo son utilizadas para crear un modelo probabilístico que relaciona o mapea un conjunto de hiperparámetros con la probabilidad de una métrica optimizada en la Función Objetivo. Esto se describe con teoría de probabilidad mediante el Teorema de Bayes con la expresión $P(\text{métrica} \mid \text{hiperparámetros})$. El modelo probabilístico se denomina Función Sustituta y su optimización resulta ser más sencilla que considerar directamente a la Función Objetivo. De esta manera, la Optimización Bayesiana, para cada iteración, encuentra el siguiente conjunto de hiperparámetros para evaluar la Función Objetivo seleccionando los hiperparámetros que funcionan mejor en la Función Sustituta. El algoritmo se resume así:

Optimización Bayesiana	
1.	Se construye un modelo de probabilidad sustituto (Función Sustituta) de la Función Objetivo.
2.	Se encuentran los hiperparámetros que funcionan mejor en la Función Sustituta.
3.	Se aplican los hiperparámetros encontrados en la Función Objetivo.
4.	Se actualiza la Función Sustituta incorporando los nuevos resultados (evaluación de la Función Objetivo y los hiperparámetros asociados)
5.	Se repiten los pasos 2 a 4 hasta alcanzar un máximo de iteraciones o tiempo definido.

El algoritmo intenta que la Función Sustituta se asemeje cada vez más a la Función Objetivo con el paso de las iteraciones. Si bien es cierto, en este algoritmo se consume un poco más de tiempo seleccionando los siguientes hiperparámetros. No obstante, se cuenta con la ventaja de que se hacen menos llamadas a la Función Objetivo. En la práctica, el tiempo destinado a seleccionar los siguientes hiperparámetros es insignificante en comparación con el tiempo dedicado a la evaluación de la Función Objetivo. Al evaluar los hiperparámetros que parecen más prometedores a partir de resultados anteriores, se ha demostrado que la Optimización Bayesiana puede obtener mejores resultados y en menos iteraciones en comparación con *GridSearchCV* y *RandomizedSearchCV* [65].

En la Figura 2.24 se expone un ejemplo de aproximación de la Función Sustituta a la Función Objetivo. Mientras existan más evaluaciones de la Función Objetivo, la aproximación de la Función Sustituta mejora. Por lo tanto, si el algoritmo selecciona los

hiperparámetros que maximizan a la Función sustituta, es probable que también produzcan buenos resultados en la Función Objetivo.




Figura 2.24. Ejemplo de aproximación de la Función Sustituta a la Función Objetivo

La Función Sustituta, también llamada superficie de respuesta, puede considerarse como una pseudo-representación probabilística de la Función Objetivo. La denominación de superficie de respuesta se debe a que se trata de un mapeo de hiperparámetros con la probabilidad de una métrica optimizada en la Función Objetivo. Existen varias formas de construir la Función Sustituta, incluyendo: Procesos Gaussianos, Regresión con el algoritmo de Random Forest y el estimador de Parzen con estructura de árbol. Las definiciones de estos algoritmos pueden ser exploradas en [63], [65], [66].

3. METODOLOGÍA DE EVALUACIÓN PREDICTIVA DE ESTABILIDAD TRANSITORIA

*Simpler solutions are
more likely to be correct
than complex ones.
- Occam's Razor*

La metodología propuesta tiene como fin permitir la evaluación predictiva de Estabilidad Transitoria con base en la identificación de patrones del LLE. El análisis predictivo se desarrolla con herramientas de Aprendizaje Automático, mientras que la identificación de patrones se consigue con técnicas novedosas de Minería de Datos.

En el presente capítulo se conduce al lector a través de los conceptos esenciales y la estructura de la metodología propuesta.

3.1. Descripción general de la metodología propuesta

En la Figura 3.1 se esquematizan las seis etapas en las que se ha dividido la propuesta metodológica. Se incluyen las principales actividades realizadas en cada etapa, junto con los resultados proporcionados por cada una.

En las secciones siguientes se describe en detalle cada una de las seis etapas indicadas. Para la explicación de los diferentes análisis, se considera como base el sistema de prueba IEEE 9-Bus System, cuyos datos se presentan en el ANEXO B.



Figura 3.1. Esquema descriptivo de la Metodología propuesta

3.2. Generación o Adquisición de datos

El presente trabajo de titulación utiliza como datos de entrada las series de tiempo de los ángulos del rotor de las máquinas sincrónicas que componen un SEP de análisis. Estas series de tiempo son obtenidas mediante simulación en el dominio del tiempo. En este sentido, se considera el uso de simulaciones de Montecarlo en un SEP para la generación de un volumen de datos significativo. Esto con la finalidad de incluir un número representativo de posibles eventos en el análisis. De este modo, los resultados de la aplicación de Minería de Datos y Aprendizaje Automático pueden reflejar y caracterizar el fenómeno de Estabilidad Transitoria con un nivel de generalización suficiente [1].

En esta propuesta, cada iteración de Montecarlo ejecutada simula la adquisición en tiempo real de las series de tiempo de los ángulos del rotor, a través de unidades PMU instaladas en el sistema. Sobre estas series de tiempo se desarrollan los análisis de Minería de Datos y Aprendizaje Automático correspondientes. Adicionalmente, para cada escenario

simulado, se obtiene un índice de pérdida de sincronismo (indicador de out-of-step OOS), el cual permite definir el target o variable dependiente o de salida.

Para la adquisición de datos se considera la modelación de un SEP en el software PowerFactory; y el lenguaje de programación Python para la generación de eventos mediante un proceso de simulaciones de Montecarlo. En esta tarea se consideran diferentes funcionalidades de PowerFactory y del módulo *powerfactory* de Python. A continuación, se explican los detalles de la adquisición de datos considerada.

3.2.1. Simulación en el dominio del tiempo

La tecnología actual de las PMU permite la toma de muestras del sistema con frecuencias de 30 a 120 muestras por segundo [4], [6]. En este trabajo se considera una frecuencia de muestreo de 120 Hz. A través de la funcionalidad de sincronización del módulo de Simulación *RMS* disponible en PowerFactory es posible el muestreo de datos con la frecuencia especificada. Esto hace factible que las simulaciones se desarrollen considerando un paso de simulación que permita obtener datos con una frecuencia de 120 Hz (como si se tratara de la adquisición en tiempo real de datos desde una PMU).

Adicionalmente, las simulaciones se basan en la disponibilidad de datos del ángulo del rotor para cada generador de un sistema. Se debe notar que esto demandaría la instalación de unidades PMU en cada unidad de generación. En la actualidad esto es posible con algoritmos de estimación que permiten obtener datos del ángulo del rotor de las máquinas de un sistema a partir de un número reducido de PMU instaladas apropiadamente [1], [6].

Con respecto a los tiempos de simulación requeridos, se considera en este trabajo una ventana de simulación panorámica de 5 segundos.

Finalmente, se debe precisar que los ángulos del rotor de los generadores son estimados con referencia al Centro de Inercia (COI, por sus siglas en inglés) del sistema. De acuerdo con lo puntualizado en [1], [67], el COI proporciona una referencia física más consistente para la descripción de los ángulos del rotor y el análisis de Estabilidad Transitoria. Además, se ha demostrado que los ángulos COI pueden ser utilizados como indicadores precisos de pérdida de sincronismo [1], [67], [68]. De esta forma, se prescinde de convenciones clásicas a fin de caracterizar adecuadamente el fenómeno de Estabilidad Transitoria [68]. El COI de cada generador es utilizado para obtener la condición de estabilidad de cada máquina. En este sentido, se considera que si el COI de una máquina excede un valor de 180° , entonces el generador pierde estabilidad. De este modo, el target de salida

correspondiente a esa simulación se define como un 1 lógico, caso contrario, como un 0 lógico.

3.2.2. Estimación del Máximo Exponente de Lyapunov

De acuerdo con el planteamiento descrito en la sección 2.3.4, es posible la estimación del LLE a partir de las series de tiempo del ángulo del rotor de los generadores del SEP. De este modo, se obtienen nuevas series de tiempo del LLE que serán utilizadas para el análisis de Estabilidad Transitoria. Se debe considerar que para la estimación del LLE se requiere la definición del número de condiciones iniciales que se usarán en la expresión 2.13. Este número influye en el retardo con el que se obtendrá el cálculo del LLE.

Adicionalmente, considerando lo investigado en [5], [6], el número de condiciones iniciales también influye en el tiempo de estabilización del LLE. De este modo, un número reducido de condiciones iniciales provocaría tiempos de convergencia del LLE elevados. No obstante, como el enfoque del presente trabajo es el análisis de patrones del LLE y la definición de ventanas de observación reducidas (análisis de las primeras muestras del LLE), es aceptable la elección de un número mínimo de condiciones iniciales. En este contexto, el planteamiento para el cálculo del LLE consiste en la elección de dos condiciones iniciales en la expresión 2.13.

Por otro lado, se debe notar que, en la propuesta de estimación del LLE, se tiene una definición arbitraria para el cálculo de la pendiente que representa el LLE (ver Figura 2.15). En el presente trabajo se adoptan las consideraciones de cálculo del LLE propuestas en [7], mediante un promedio móvil, y se añade una modificación. La modificación consiste en reducir el número de términos necesarios para el cómputo de cada iteración del sumatorio interno de la expresión 2.13. En este caso, se introduce una variable de compresión *shrink* (s), que indica el número de términos que se reducen a la variable k del denominador de la ecuación 2.13. El nombre adoptado proviene del hecho que la introducción de esta variable, contribución de este trabajo, se asemeja a una compresión o escalamiento en tiempo en la evolución de la trayectoria con la que se calcula el LLE. Esto con la finalidad de reducir el número de muestras necesarias para la estimación del LLE. Una importante ventaja de la introducción del parámetro *shrink* es que posibilita conseguir *menores ventanas de evaluación*, mejorando así los tiempos de predicción.

En la Figura 3.2 se esquematiza la funcionalidad del parámetro *shrink* en el cómputo de las series de tiempo del LLE. Se aprecia que con la introducción de este parámetro es posible obtener la estimación del LLE de forma más temprana.

Como en este trabajo se plantea el uso de un número de condiciones iniciales igual a 2, el valor máximo que puede tomar el parámetro *shrink* en esta situación es igual a 1. Debido a que la frecuencia de muestreo en el presente análisis es de 120 Hz, entonces un valor de $shrink = 1$ significa que el LLE se obtiene con una anticipación de $1/120 = 8.33 \text{ ms}$ a lo que se obtendría sin considerar la modificación.




Figura 3.2. Efecto de la introducción del parámetro *shrink* en la estimación del LLE

De acuerdo con el esquema de la Figura 3.2, se tiene que la ventana de tiempo de análisis del LLE está dada por un número de muestras definido con la expresión 3.1. Donde N representa el número de condiciones iniciales y n_{LLE} el número de muestras del LLE.

$$TW_{samples} = 2N + 1 - shrink + n_{LLE} \quad (3.1)$$

3.2.3. Preparación y estructura de datos de Montecarlo

La simulación de Montecarlo en el presente trabajo está basada en la generación de eventos de cortocircuito en líneas de transmisión de un SEP. Luego de lo cual se considera el despeje de la línea fallada por acción de las protecciones asociadas y se obtiene la evolución dinámica poscontingencia del sistema. En este contexto, las series de tiempo del ángulo del rotor de los generadores constituyen simulaciones en el dominio del tiempo que representan los datos de análisis que se monitorean en tiempo real.

Las simulaciones deben tomar en cuenta el comportamiento estocástico de un SEP y las diferentes posibilidades de ocurrencia de contingencias para obtener resultados representativos [69]. Con este propósito, se consideran en las simulaciones diferentes variables y distribuciones probabilísticas asociadas. En la Tabla 3.1 se expone un detalle de las variables tomadas en cuenta para cada una de las simulaciones de Montecarlo, su distribución o criterio de variabilidad y los parámetros asociados.

Tabla 3.1. Descripción de estocasticidad en variables de la simulación de Montecarlo

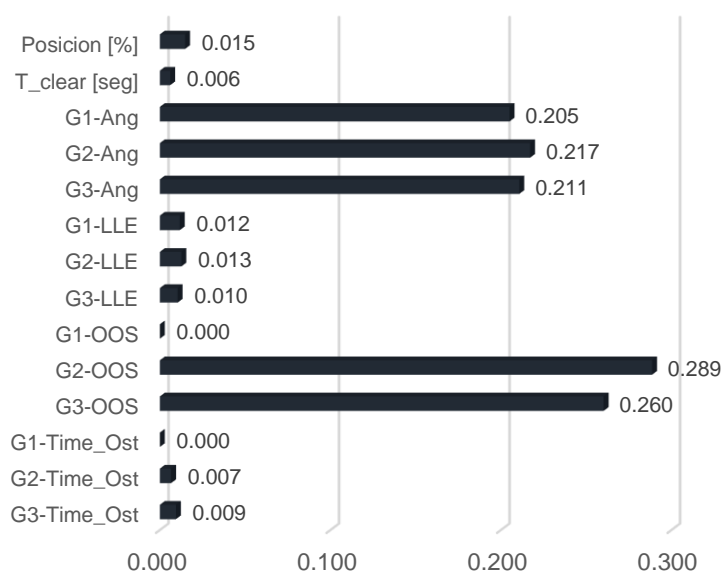
Nro.	Variable	Distribución	Parámetros
1	% Posición de falla (sobre líneas de transmisión) [70]	Distr. de probabilidad uniforme continua	$U \sim [0\% - 100\%]$
2	Elemento en falla (líneas de transmisión) [71]	Distr. de probabilidad uniforme discreta	$U \sim [L/T_1 - L/T_n]$
3	Tiempo de despeje (seg.) [72]	Distr. de probabilidad normal	$N \sim \{\mu = 0.1; \sigma = 0.03\}, t_{min} = 64ms$
4	Estado operativo (Potencia Activa de cargas) [1]	Distr. de probabilidad normal	$N \sim \{\mu = P_{nominal}; \sigma = 10\% \cdot P_{nominal}\}$
5	Estado operativo (Factor de potencia de cargas) [69]	Distr. de probabilidad uniforme continua	$U \sim [fp_{min} - fp_{max}]$
6	Hora del día	Distr. de probabilidad uniforme discreta	$U \sim [1 - 24]$
7	Curva de Demanda Diaria [1]	Distr. de valores horarios (ver ANEXO C)	Curva típica Residencial, Comercial e Industrial
8	Factor de contribución: consumo residencial, comercial e industrial	Distr. de probabilidad uniforme continua	$U \sim [0\% - 100\%]$

En lo que concierne al número de simulaciones de Montecarlo necesarias, en [73] se presenta un criterio para la definición de parada, a fin de cumplir con un número suficiente con el que el problema se encuentra bien representado. El criterio se define mediante una expresión de error relativo ε_r estimado sobre la variabilidad de una característica. Este error está dado por la ecuación 3.2. En donde Φ^{-1} es la función inversa de la distribución normal estándar, μ_k es el valor medio de la variable k , N es el número de simulaciones y δ es el error aleatorio o nivel de significancia (definido en 1% en este trabajo).

$$\varepsilon_r^k = \frac{\Phi^{-1} \left(1 - \frac{\delta}{2} \right) \cdot \sigma_k}{\mu_k \cdot \sqrt{N}} \quad (3.2)$$

El enfoque del uso de la simulación de Montecarlo en este trabajo es la generación de datos para obtener la mayor información posible. En consecuencia, el criterio considerado no es encontrar la condición para detener la ejecución de simulaciones, sino definir un número de simulaciones elevado que permita obtener errores relativos bajos. Por ejemplo, menores a 0.05, como se presenta referencialmente en [74].

En este sentido, se prueba el resultado del error relativo que se obtiene con 10000 simulaciones para el sistema IEEE 9-Bus System. Se tienen los valores expuestos en la Figura 3.3. Con relación a las variables dinámicas temporales (ángulo del rotor y LLE) se utiliza como datos los valores finales de las series de tiempo (datos obtenidos a $t = 5$ s).



	Posicion [%]	T_clear [seg]	G1-Ang	G2-Ang	G3-Ang	G1-LLE	G2-LLE	G3-LLE	G1-OOS	G2-OOS	G3-OOS	G1-Time_Ost	G2-Time_Ost	G3-Time_Ost
ε_r^k	0.015	0.006	0.205	0.217	0.211	0.012	0.013	0.010	0.00	0.289	0.260	---	0.007	0.009

- ✓ Posicion [%]: Posición porcentual en la que se simula un cortocircuito en una línea.
- ✓ T_clear [seg]: Tiempo de despeje de una falla.
- ✓ Gen i-Ang: Angulo del rotor del generador "Gen i".
- ✓ Gen i-LLE: Valor del LLE para el generador "Gen i".
- ✓ Gen i-OOS: Índice de pérdida de sincronismo del generador "Gen i".
- ✓ Gen i-Time_Ost: Tiempo de operación de la protección OSR del generador "Gen i".

Figura 3.3. Error relativo obtenido en la ejecución de 10000 simulaciones de Montecarlo

Se aprecia que los errores en el caso de la información del ángulo del rotor (G1-Ang, G2-Ang, G3-Ang) y el índice de pérdida de sincronismo o target definido a partir de la evolución del COI de cada generador (G2-OOS, G3-OOS) alcanzan valores no mayores a 0.3. En estos casos, la información de eventos estables e inestables se diferencia significativamente o existe extrema variabilidad. Esto por las incursiones angulares elevadas en casos inestables. Es así como aparecen errores relativos elevados. Por tal motivo, para estas variables no es práctica la definición de un límite de error.

Por otro lado, se aprecia que para el resto de las variables los errores son mucho menores, en donde las cantidades no exceden el valor de 0.02. Por ejemplo, en el caso del LLE. Esto ocurre como producto de que la información de eventos estables e inestables se encuentra regularizada en un rango o espacio vectorial más definido. Por esta razón, el LLE y el tiempo de disparo de las unidades de generación serán las variables consideradas para identificar que se obtienen errores reducidos. En este trabajo, se plantea definir como límite un valor de error relativo de hasta 0.05 para aceptar el número de simulaciones de Montecarlo ejecutadas. En consecuencia, una cantidad de 10000 simulaciones de Montecarlo es suficiente en el caso del sistema de prueba IEEE 9 Bus-System.

Por otro lado, se debe mencionar que para todos los casos se simulan fallas trifásicas por ser las más severas en el SEP y, por lo tanto, aquellas que comúnmente son analizadas en estudios de estabilidad transitoria [70].

Con relación a la variabilidad en el estado operativo, se considera la ejecución de Flujos Óptimos de Potencia mediante el módulo *pypower* de Python para la estimación del punto de operación y la representación variable del mismo. Los costos de operación asociados a los generadores, requeridos en el flujo, se detallan en el ANEXO B [1], [69].

En la Figura 3.4 se presenta, a modo de ejemplo, la distribución de datos de las tres primeras variables de entrada indicadas en la Tabla 3.1. Esta distribución de datos se obtiene a partir de la ejecución de 10000 simulaciones de Montecarlo.




Figura 3.4. Histogramas de variabilidad en el diseño de las simulaciones de Montecarlo

3.3. Análisis Exploratorio de Datos

En este apartado se plantea el Análisis Exploratorio de los Datos de las simulaciones de Montecarlo. Esto con el fin de identificar, de una manera preliminar, características en la estructura de los datos obtenidos. En la Tabla 3.2 se presenta un resumen de estadística univariante obtenida para el conjunto de 10000 simulaciones. Para las variables dinámicas temporales se utiliza como dato el último valor de las series de tiempo.

Tabla 3.2. Estadística univariante de resultados generales de simulaciones de Montecarlo

	Posicion [%]	T_clear [seg]	G1-Ang	G2-Ang	G3-Ang	G1- LLE	G2- LLE	G3- LLE	G1- OOS	G2- OOS	G3- OOS	G1- Time_Ost	G2- Time_Ost	G3- Time_Ost
Mean	49.93	0.11	-62.91	148.57	178.17	-0.61	-0.53	-0.69	0.0	0.01	0.01	--	1.01	0.95
Median	49.72	0.10	-13.72	31.82	37.34	-0.54	-0.48	-0.62	0.0	0.00	0.00	--	0.95	0.88
Std. Dev.	28.72	0.02	500.82	1252.49	1458.19	0.27	0.26	0.28	0.0	0.09	0.10	--	0.26	0.35
Variance	824.71	0.00	250823.1	1568733.5	2126329.6	0.08	0.07	0.08	0.0	0.01	0.01	--	0.07	0.12
Coef. Var.	0.58	0.23	7.96	8.43	8.18	0.45	0.49	0.40	--	11.21	10.10	--	0.26	0.37
Skewness	0.01	0.53	-10.41	10.60	11.38	0.19	0.07	0.12	0.0	11.12	10.01	--	1.06	2.35
Kurtosis	1.82	2.87	111.14	115.18	145.36	7.43	8.48	9.29	0.0	124.59	101.10	--	4.60	14.19

Se tienen los siguientes hallazgos de este resultado estadístico:

- El generador G1 no pierde estabilidad en ninguna de las simulaciones. De esta manera, esta unidad se constituye en un generador no crítico en el sistema.
- De manera general, se observa que para las unidades G2 y G3 existen estadísticos muy similares. Esto como consecuencia de que el comportamiento de estabilidad transitoria es un fenómeno que afecta globalmente al sistema y en particular, a ambos generadores.
- Con relación al valor medio y la mediana, se tiene que en ciertos casos, por ejemplo: en el valor del ángulo del rotor, ambos estadísticos difieren considerablemente, lo que sugiere la posible presencia de datos atípicos o más de una distribución de datos inmersa. Esto como resultado de que se están incluyendo casos estables e inestables en el conjunto analizado.
- Una media de valores negativos en el LLE sugiere que gran parte de los eventos simulados corresponden a eventos estables (el LLE en estado estacionario tiende a valores negativos para un evento estable).
- Se observan altas asimetrías en los datos, en especial en las variables de ángulo y LLE, producto de una tendencia establecida por las condiciones de inestabilidad y estabilidad del sistema.
- En los resultado de la Kurtosis se aprecian valores elevados en el LLE, lo que sugiere baja homogeneidad que puede relacionarse con dos distribuciones que componen el conjunto total de datos.

Con relación a la valoración de eventos estables e inestables, en la Figura 3.5 se observa la cantidad de eventos de cada clase obtenida de las simulaciones. Se aprecia que el número de eventos inestables constituye un porcentaje reducido, menor al 1% del total de simulaciones. Además, el generador G1 no pierde estabilidad en ningún caso.




Figura 3.5. Valoración de eventos para el sistema IEEE 9-Bus System

En relación con el resultado de las variables de ángulo del rotor, LLE y el índice de pérdida de sincronismo, alcanzados a $t = 5 s$, en la Figura 3.6 se visualizan histogramas de los datos generados para el caso de eventos estables. En este caso se aprecia que el signo del LLE ostenta un valor negativo en estos eventos. Además, se aprecia que los valores que toma el ángulo del rotor no se incrementan indefinidamente, como consecuencia de una dinámica estable del sistema.




Figura 3.6. Histogramas para eventos estables en el sistema IEEE 9-Bus System

Por otro lado, en la Figura 3.7 se visualizan los histogramas para eventos inestables. En relación con el índice de pérdida de sincronismo se aprecia que la pérdida de estabilidad no es simultánea en todos los casos para los generadores G2 y G3, es decir, que existen eventos en los que solo una de estas máquinas pierde estabilidad. Además, en todas las simulaciones de eventos inestables el LLE presenta un valor positivo y los valores del ángulo del rotor ostentan magnitudes excesivas, producto de una condición inestable.




Figura 3.7. Histogramas para eventos inestables en el sistema IEEE 9-Bus System

Finalmente, se plantea la visualización de la dispersión de valores del LLE. Esto con la finalidad de identificar posibles relaciones gráficas del indicador entre generadores. Para este caso, en la Figura 3.8 se presenta la matriz de dispersión correspondiente. Se evidencia que los eventos inestables se ubican en una región diferente que los eventos estables, específicamente, en donde todos los valores del LLE son positivos. Además, el solapamiento es nulo entre observaciones estables e inestables.

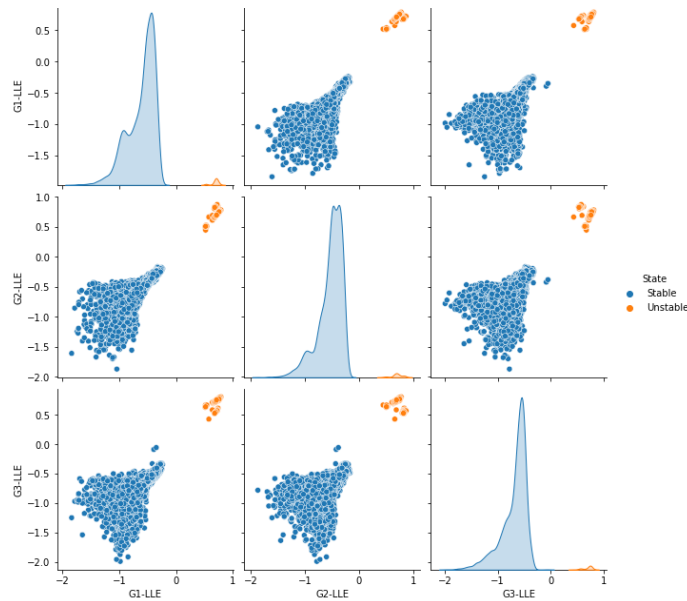


Figura 3.8. Matriz de dispersión del LLE en el sistema IEEE 9-Bus System

3.4. Aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria

La metodología propuesta considera el análisis del LLE, calculado a partir de mediciones de un SEP, para la evaluación predictiva de Estabilidad Transitoria. Bajo esta perspectiva, se debe notar que el LLE se constituye como un indicador confiable de estabilidad [34], [45], el cual ha sido investigado en varias propuestas relacionadas con análisis de sistemas dinámicos [5], [8], [32]. No obstante, en varias de las investigaciones que incluyen el análisis del LLE para el estudio de Estabilidad Transitoria se ha identificado que las propuestas presentadas adolecen de varias restricciones y desventajas que dificultan e inclusive imposibilitan su aplicabilidad. Entre ellas, se encuentran principalmente:

- El planteamiento de metodologías de evaluación que han mostrado no ser lo suficientemente precisas, considerando que se basan en hipótesis formuladas en sistemas simplificados, y que no pueden ser extendidas con generalidad hacia sistemas complejos [3], [4], [5]. Por ejemplo, para el monitoreo del LLE, se

considera el análisis de ciertas fluctuaciones del exponente, las cuales no necesariamente responden a patrones claramente definidos [4], [6]. De esta manera, su generalización en los sistemas actuales se ve limitada.

- En ciertas metodologías, la evaluación predictiva de Estabilidad Transitoria no se consigue oportunamente, por lo que las propuestas no se encuentran lo suficientemente acondicionadas para la evaluación en tiempo real. Las propuestas de [5], [6], [7] logran identificar condiciones de estabilidad en tiempos mayores a 1 segundo, lo cual es inaceptable en la filosofía en la que se concibe la protección y control de los SEP actuales. Esta situación ocurre porque el análisis convencional del LLE se limita a la simple observación de ventanas de tiempo excesivamente extensas.
- Se presentan planteamientos basados en el cómputo analítico de los Exponentes de Lyapunov y el modelo explícito del sistema, los cuales son altamente complejos de ser aplicados al considerar la magnitud de los SEP actuales [8], [9].

A continuación, se presenta un breve análisis de la Aplicación del análisis del LLE en los resultados del proceso de simulación de Montecarlo en el sistema IEEE 9-Bus System.

3.4.1. Evolución dinámica del LLE

En primer lugar, se expone la evolución dinámica del LLE a través de la Figura 3.9 y Figura 3.10. Estas series se estiman para el período poscontingencia de las series de tiempo del ángulo del rotor. En los primeros instantes el LLE presenta fluctuaciones que impiden determinar de manera pronta su signo final. Asimismo, desde una perspectiva visual, se observa la casi nula discriminación entre casos estables e inestables por el solapamiento existente en los primeros instantes. Es así como se evidencia que la simple observación del LLE no constituye una vía válida para la evaluación de Estabilidad Transitoria en tiempo real porque el signo final del LLE solo puede ser determinado en estado estacionario, es decir, después de varios segundos.




Figura 3.9. Evolución dinámica del LLE (1000 series) para el generador G2




Figura 3.10. Evolución dinámica del LLE (1000 series) para el generador G3

Por otro lado, en la Figura 3.11 se exponen histogramas formados a partir de los valores finales del LLE (alcanzado a $t = 5 s$), para los generadores G2 y G3. Se observa la precisión del LLE para describir la estabilidad del sistema en estado estacionario. Es decir, se tienen valores negativos del LLE para eventos estables y valores positivos para eventos inestables. Aun así, esta precisión solo se consigue con el valor del LLE de largo plazo (tiempos superiores a 1 s).




Figura 3.11. Histogramas del LLE alcanzado a $t = 5$ s, para los generadores G2 y G3.

De acuerdo con lo identificado en este apartado, no es factible el análisis del LLE de largo plazo para Estabilidad Transitoria, cuando se considera la futura implementación en tiempo real. Por esta razón, surge la necesidad de definir una ventana de observación del LLE reducida, en donde se puedan identificar patrones que simplifiquen el análisis del LLE. Es decir, se trata de prescindir de la observación del signo del LLE, para considerar, en su lugar, las características embebidas en la evolución dinámica del LLE en los primeros instantes poscontingencia. Esto constituye una contribución innovadora del presente trabajo, debido a que se trata de caracterizar la dinámica inicial del LLE para predecir el estatus de estabilidad futuro.

3.4.2. Análisis de la magnitud del LLE

El LLE mide la tasa de convergencia (o divergencia) exponencial de dos trayectorias infinitesimalmente cercanas; y, equivalentemente, la estabilidad de un sistema dinámico [6]. En otros términos, permite cuantificar la expansión o contracción que presenta la evolución dinámica de alguna variable de estado de un sistema. Con un fin ilustrativo, en la Figura 3.12 se muestra la evolución de diferentes funciones polinómicas y el correspondiente cálculo del LLE en cada una. Se observa que mientras mayor es el grado polinómico, la tasa de divergencia es mayor, lo cual se refleja en mayores valores del LLE.




Figura 3.12. Evolución dinámica del LLE de diferentes funciones polinómicas

Es posible identificar que una señal que presenta una mayor divergencia o crece más rápidamente que otra tendrá valores mayores del LLE. Mientras que una señal que presenta incursiones más estables tendrá menores valores del LLE (con evoluciones dinámicas de menor magnitud, el LLE es menor).

Por otro lado, cuando una señal tiende a estabilizarse hacia un valor determinado, el argumento interno de la expresión para calcular el LLE tiende a cero y, por lo tanto, el LLE se acercará a valores negativos (característica de la función logarítmica frente a valores menores a 1). Como se observa en el análisis del LLE para señales exponenciales³ de la Figura 3.13, a medida que existe una mayor tendencia a la estabilización en un valor constante, el LLE tomará valores negativos de mayor magnitud.

³ Por simplicidad, se consideran en este breve análisis funciones polinómicas de un solo término y funciones exponenciales para obtener como resultado una dinámica básica en las señales del LLE.




Figura 3.13. Evolución dinámica del LLE de diferentes señales exponenciales

Las características expuestas sobre el comportamiento del LLE, en la caracterización de la divergencia o convergencia de una señal, serán consideradas a continuación para el estudio de Estabilidad Transitoria al tomar en cuenta esta vez la dinámica de los ángulos del rotor de las máquinas sincrónicas.

3.4.3. Relación entre el LLE y la Estabilidad Transitoria

A partir de la ecuación de oscilación de una máquina sincrónica conectada a una barra infinita (modelo OMIB), es posible obtener una relación entre la energía cinética y potencial adquirida durante la ocurrencia de una falla y la conversión de energía que ocurre después del despeje de la falla. Es decir, un período de aceleración y otro de desaceleración en la máquina sincrónica. Esta situación puede analizarse mediante una curva Potencia vs. Ángulo ($P - \delta$), en donde la diferencia entre la potencia mecánica y eléctrica (torque o potencia de aceleración) delimita dos áreas que son directamente proporcionales a los intercambios de energía que ocurren en la máquina durante la falla y después de la falla. Además, estas áreas son delimitadas por el ángulo del rotor de prefalla δ_0 , aquel que se presenta al momento del despeje de la falla δ_c , y el ángulo máximo de incursión del ángulo del rotor δ_m . En la Figura 3.14a se ilustran los conceptos mencionados.

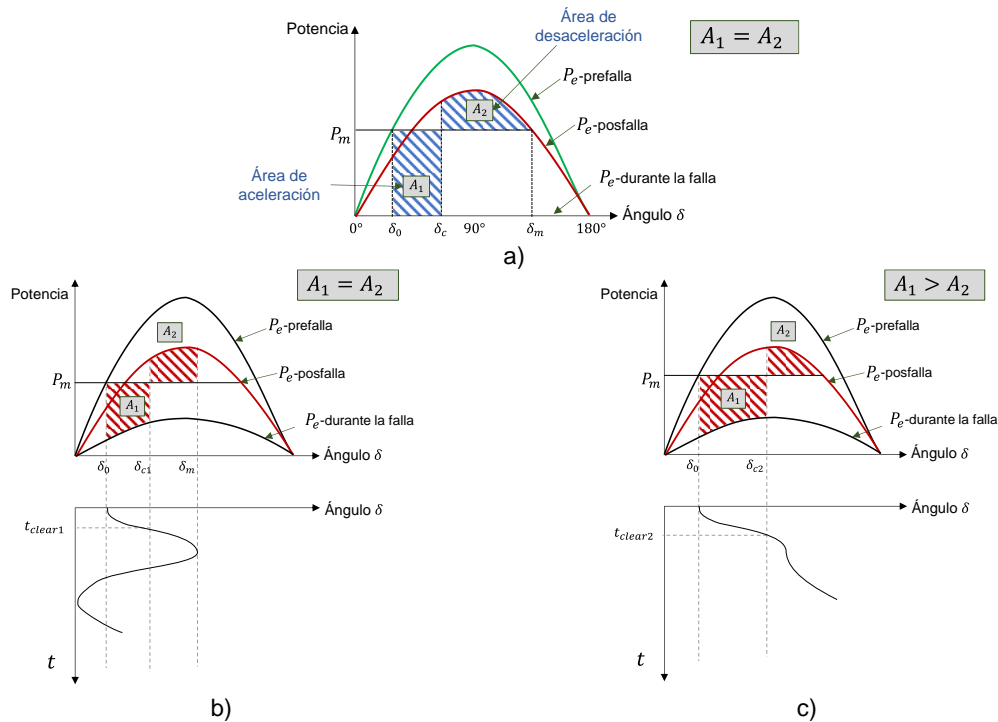


Figura 3.14. Criterio de áreas iguales para el análisis de Estabilidad Transitoria: a) Elementos curva $P - \delta$, b) Evento estable, c) Evento inestable [12]

En esta perspectiva, luego de algún evento de cortocircuito, el sistema alcanzará una condición estable si el área de desaceleración (A_2) que puede formarse es al menos igual al área de aceleración (A_1). Durante la evolución dinámica del evento, el ángulo del rotor se incrementará hasta alcanzar un valor máximo y luego cambiará de dirección, describiendo un régimen oscilatorio en el que se espera que el sistema tienda a estabilizarse o alcanzar algún punto de equilibrio (ver Figura 3.14b).

Es así como existe un valor máximo que el ángulo del rotor puede alcanzar al momento del despeje de una falla, de tal manera que el área A_2 pueda ser al menos igual al área A_1 . Este ángulo se conoce como ángulo crítico de despeje $\delta_{critico}$. El tiempo correspondiente en el que se alcanza este ángulo se denomina tiempo crítico de despeje de una falla t_c . De este modo, el tiempo crítico de despeje es el tiempo máximo que ocurre desde el inicio de una falla hasta su despeje, y que permite que el sistema sea transitoriamente estable.

En el caso de que el ángulo del rotor en el momento del despeje de una falla sea superior que el ángulo $\delta_{critico}$, el área A_2 que se forma será menor que el área A_1 y el sistema no será capaz de mantener sincronismo. Esto ocurre porque la energía de desaceleración no es suficiente para compensar la aceleración adquirida en la máquina durante la ocurrencia de la falla [11], por lo que el ángulo del rotor se incrementa de manera indefinida, como se esquematiza en la Figura 3.14c.

En resumen, para que exista estabilidad, la energía cinética añadida al rotor durante una falla debe poder disiparse en el período posfalla. Esto es esencialmente lo que establece el criterio de Áreas Iguales.

Adicionalmente, se debe notar que el área ocupada por A_1 y A_2 depende en gran medida del torque de aceleración y desaceleración respectivamente. Cuanto mayor sea el torque de desaceleración, el ángulo del rotor posfalla evolucionará con una tasa de decaimiento mayor, debido a que enfrenta una mayor energía de desaceleración.

Con fines ilustrativos, en la Figura 3.15 se ejemplifican dos casos en los que existen diferentes áreas de desaceleración A_{d1} para un Caso 1 y A_{d2} para un Caso 2. Se observa que al existir mayor torque de desaceleración en el Caso 2, el ángulo del rotor enfrenta una evolución dinámica de mayor convergencia con respecto al Caso 1.




Figura 3.15. Comparación de la dinámica del ángulo del rotor con respecto a una mayor energía de desaceleración en la primera oscilación

En este sentido, el ángulo del rotor tendrá una característica más estable cuanto mayor energía o torque de desaceleración se presente. A partir de esto se puede inferir que, para un evento estable, la tasa de variación del ángulo será más pronunciada que para un evento inestable [75].

Como consecuencia, la dinámica posfalla del ángulo del rotor tenderá a evolucionar con una tasa de variación mayor para un evento estable que para uno inestable, lo cual se corrobora con lo ilustrado en la Figura 3.15. Al tomar en cuenta que el LLE puede medir esta tasa de variación, entonces es posible relacionar este índice con la evolución del

ángulo del rotor y el torque de aceleración. Es decir, la dinámica de un evento estable e inestable puede ser diferenciada aproximadamente con la magnitud del LLE.

En definitiva, dado que un evento inestable presenta un menor torque de desaceleración y, por lo tanto, una menor tasa de convergencia que un evento estable, entonces un evento inestable presentaría un LLE menor que un evento estable, durante la primera oscilación. Esto significaría que $LLE_{caso1} \ll LLE_{caso2}$, lo cual se esquematiza en la Figura 3.15.

Cabe destacar que lo mencionado solo es aplicable para los *primeros instantes* de la dinámica posfalla del ángulo del rotor y del LLE en un OMIB. Pero de manera general, por la complejidad de los sistemas multimáquina, no es posible la generalización de que el LLE de un evento inestable siempre será menor en magnitud que el LLE de un evento estable. Además, las oscilaciones caóticas del ángulo del rotor se manifiestan también en fluctuaciones en el LLE que distorsionan al indicador [5]. Por tal motivo, la simple observación del LLE no puede garantizar un resultado totalmente confiable.

En esta sección se han proporcionado los primeros indicios o patrones del comportamiento esperado del LLE para un sistema OMIB. No obstante, con el fin de extender el análisis para sistemas complejos, en este trabajo se plantea el uso de técnicas de Minería de Datos para una identificación más formal de patrones, generalizable y que brinde mayores precisiones en las conclusiones a formular. Principalmente, con respecto a cómo diferenciar el LLE obtenido para eventos inestables y para eventos estables.

3.4.4. Número de muestras de análisis del LLE

En virtud de que uno de los propósitos del análisis de este trabajo es la identificación de patrones en el LLE para una evaluación de Estabilidad Transitoria oportuna, la evolución completa del LLE en una ventana de simulación extendida de 5s deja de ser necesaria. En consecuencia, se propone el análisis de una ventana de tiempo reducida, es decir, el análisis únicamente de las primeras muestras del LLE.

En este sentido, se debe tomar en cuenta que, para que esta propuesta de evaluación predictiva sea práctica, los tiempos involucrados de retardo en la estimación del LLE, junto con la ventana de tiempo de análisis, deben permitir que el WAMPAC de un SEP cuente con los resultados de esta evaluación con suficiente anticipación. Es decir, en un tiempo de evaluación de estabilidad t_{TSA} apropiado, con el fin de que las acciones de control puedan ser ejecutadas oportunamente antes de la ocurrencia de eventos en cascada.

De esta manera, para la determinación del número de muestras del LLE que se considerarán en el análisis, se toman en cuenta también los retardos asociados al sistema

de comunicaciones y demás procesos del WAMPAC (ver Tabla 2.3). En la Figura 3.16 se presenta un esquema de las ventanas de tiempo involucradas en este tipo de análisis.




Figura 3.16. Esquema de ventanas de tiempo para el análisis del LLE

En esta ilustración se incluyen etapas críticas del desarrollo de los eventos de contingencia en un sistema. Se tiene el tiempo inicial t_0 en el que ocurre una falla. Posteriormente, en un tiempo t_{clear} ocurre el despeje de esta falla. Después de una ventana de tiempo de análisis TW , se obtiene un resultado de evaluación de Estabilidad Transitoria (TSA), es decir, la predicción de si el evento conlleva a una condición estable o inestable del sistema.

Luego, este resultado predictivo de estabilidad se envía al WAMPAC para el desarrollo de las acciones de control correspondientes que eviten la inestabilidad en el sistema (cuando esta sea predicha). No obstante, se presentará inevitablemente un tiempo de retardo en las acciones de control del sistema WAMPAC. Frente a estas situaciones, se requiere que las acciones de control ocurran antes del disparo de alguna unidad de generación en un tiempo $t_{Out St}$, evitando así eventos en cascada. En este contexto, se define un tiempo t_{max} , el cual representa el tiempo máximo admisible para obtener un resultado predictivo de estabilidad antes de que este sea enviado al WAMPAC.

En la Figura 3.16 se observa que existe un tiempo de disponibilidad t_{disp} , que representa la holgura existente para que se efectivice una acción de control del WAMPAC antes del disparo de un generador. El tiempo de disponibilidad debe ser, por lo tanto, mayor que el tiempo de retardo del WAMPAC ($t_{disp} > t_{delay}$).

Con base en lo mencionado, se tiene que la ventana de tiempo de análisis del LLE, que permitirá establecer las muestras necesarias de observación del LLE, debe cumplir con las siguientes condiciones en un sistema de G generadores y un conjunto con M simulaciones o casos de análisis:

$$TW \leq t_{max} - \text{mean}_{i=1...M}\{t_{clear}\} \quad (3.3)$$

Donde:

$$t_{max} \leq \text{mean}_{i=1...G}\{t_{\min Out St}\} - t_{delay} \quad (3.4)$$

Y, para cada unidad de generación:

$$t_{\min Out St} = \min_{i=1...M}\{t_{Out St}\} \quad (3.5)$$

A partir de los datos obtenidos de las simulaciones de Montecarlo para el sistema de prueba IEEE 9-Bus System, y considerando que los tiempos en análisis tienen un carácter estocástico, se tiene la distribución de frecuencias de tiempos mostrada en la Figura 3.17.




Figura 3.17. Histogramas de tiempos de eventos en el sistema IEEE 9-Bus System

Tabla 3.3. Resumen estadístico de tiempo de eventos en el sistema IEEE 9-Bus System

Variable temporal	Tiempo (ms)
$t_{clear} - \text{mean}$	106.3
$t_{clear} - \text{min}$	64.0
$t_{clear} - \text{max}$	213.7
$t_{\min Out St}$	G2: 541.7 G3: 400.0
$t_{\min Out St} - \text{mean}$	471
$t_{max} \leq$	254
$TW \leq$	148

A partir de la información provista, se tiene la estadística de tiempos de los eventos que se expone en la Tabla 3.3; tomando en cuenta un retardo máximo del WAMPAC de 217 ms.

De acuerdo con los resultados mostrados en la Tabla 3.3, y considerando las ventanas de tiempo admisibles para una frecuencia de muestreo de 120 Hz, se selecciona por *aproximación* una ventana de tiempo de análisis de $TW = 150\text{ ms}$, equivalente a un número de muestras $TW_{samples} = \left(1 + \frac{0.150\text{ s}}{\frac{1}{120\text{ s}}}\right) = 19$. Considerando la expresión 3.1, el número de muestras del LLE requerido para el análisis es:

$$n_{LLE} = TW_{samples} - (2N + 1 - shrink) = 19 - (2 \cdot 2 + 1 - 1) = 15$$

Considerando la estadística de tiempos mostrada, se justifica que el uso de 15 muestras del LLE proporciona tiempos medios de predicción que permiten el desarrollo de acciones de control oportunas en el WAMPAC. A partir de los tiempos de disparo de las unidades de generación, es posible analizar estadísticamente los tiempos disponibles de las acciones de control, lo cual se expone en la Figura 3.18.




Figura 3.18. Estadística de tiempo de disponibilidad en el sistema IEEE 9-Bus System

En general, los tiempos de disponibilidad resultantes confirman la posibilidad de llevar a cabo acciones de control correctivas previas a la actuación de una protección local. Esto considerando que estos tiempos son considerablemente superiores que los retardos asociados al sistema WAMPAC (217 ms). Por lo tanto, se justifica cómo la evaluación de

Estabilidad Transitoria en tiempo real propuesta es capaz de alertar sobre la necesidad de acciones de control globales antes del comienzo de un evento en cascada.

3.4.5. Análisis del LLE en un sistema multimáquina

Para ejemplificar el resultado de la aplicación del LLE en sistemas multimáquina, se considerarán las simulaciones obtenidas en el sistema de prueba IEEE 9-Bus System y el LLE calculado a partir de los ángulos del rotor de las máquinas G2 y G3 del sistema. Debido a que se propone la observación de una ventana de tiempo de análisis reducida, se estudian los resultados obtenidos con las 15 primeras muestras del LLE para las 10000 simulaciones de Montecarlo desarrolladas en este sistema. En la Figura 3.19 y la Figura 3.20 se presenta la evolución del LLE para esta ventana de tiempo de análisis y la cuantificación de las medidas de dispersión: rango y varianza, para la magnitud del LLE.




Figura 3.19. Evolución del LLE en G2 para una ventana de observación reducida




Figura 3.20. Evolución del LLE en G3 para una ventana de observación reducida

En este resultado se observa que la magnitud del LLE obtenida para eventos inestables es significativamente menor en comparación con las magnitudes que puede alcanzar el LLE para eventos estables (valores más cercanos a 0). De manera preliminar, es posible afirmar que el LLE correspondiente a eventos inestables ocupa un espacio vectorial más reducido o concentrado que el LLE relacionado con eventos estables, el cual se muestra como más disperso. Esto se corrobora en los reducidos valores de las medidas de dispersión (rango y varianza) obtenidas durante la evolución de las 15 primeras muestras del LLE. La dispersión del LLE de eventos inestables es muy baja en comparación con la dispersión del LLE de eventos estables. El rango de magnitudes del LLE en eventos inestables alcanza valores menores a 8.1 p.u., mientras que el rango de eventos estables alcanza valores que inclusive superan 250 p.u. Por otro lado, se aprecia que la varianza del LLE de

eventos inestables es, en la mayoría de los casos, menor que el 3% de la varianza del LLE de eventos estables.

Se debe notar también que existe un alto grado de solapamiento entre los eventos estables e inestables, el cual impide una mejor discriminación entre el LLE obtenido para estos dos tipos de eventos. *No obstante, se identifica una evidente característica de que la magnitud del LLE para eventos inestables se encuentra concentrada en un espacio vectorial reducido del espacio formado por las EOF scores (como se apreciará más adelante).* Esta característica puede ser aprovechada para incluir más información en los análisis de Estabilidad Transitoria que han sido planteados en el estado del arte relacionado [1].

Es preciso resaltar que en el análisis del ángulo del rotor no se identifica esta característica encontrada en la magnitud del indicador LLE, según se presenta en la Figura 3.21. En este caso, se han graficado los ángulos del rotor desde el instante del despeje de las correspondientes fallas y durante 250ms. Se observa que las magnitudes del ángulo del rotor para eventos inestables ocupan un espacio vectorial amplio, tan similar al que ocupan las magnitudes correspondientes a eventos estables. Además, se observa que también existe solapamiento de los eventos inestables y estables.




Figura 3.21. Evolución del ángulo del rotor en G3 para una ventana reducida

Cabe mencionar que el comportamiento del LLE mostrado en la Figura 3.19 y la Figura 3.20 puede ser sintetizado de una manera más formal a través de una identificación matemática de patrones. En este sentido, en el presente trabajo se plantea como una nueva propuesta de análisis del LLE, la aplicación de novedosas técnicas de Minería de Datos sobre el LLE para una identificación de patrones que expliquen el comportamiento del LLE con interpretaciones matemáticamente simplificadas. Esta estrategia se desarrolla

para superar los problemas de imprecisión y retardo que surgen en el análisis directo o la simple observación del LLE en tiempo real identificados en propuestas relacionadas y que se ha expuesto en las secciones anteriores.

En resumen, se tienen las siguientes observaciones acerca de la aplicación del LLE para el estudio de Estabilidad Transitoria en un SEP:

- El LLE permite el análisis de la dinámica del ángulo del rotor, al ser una medida de la tasa de convergencia (o divergencia) de la trayectoria que puede tomar esta dinámica, lo cual se describió de forma simplificada a través del modelo OMIB.
- El LLE presenta características particulares de discriminación.- Se identifica que la magnitud del LLE para eventos inestables se encuentra concentrada en un espacio vectorial reducido del espacio formado por las EOF scores. Esta característica puede ser aprovechada para incluir más información en los análisis de Estabilidad Transitoria que han sido planteados en el estado del arte relacionado.
- El cómputo del LLE es relativamente sencillo, por lo que puede ser potencialmente utilizado en aplicaciones en tiempo real. Esto tomando en cuenta inclusive los retardos asociados al sistema WAMPAC.

3.5. Minería de datos del Máximo Exponente de Lyapunov

La teoría relacionada ha demostrado que el índice LLE garantiza un resultado acondicionado y lo suficientemente preciso de la estabilidad de un sistema no lineal. Sin embargo, el tiempo necesario de convergencia del LLE, que juega un papel importante en el análisis de Estabilidad Transitoria, puede ser muy extenso, por lo que la exploración completa de la evolución dinámica del indicador enfrenta una importante limitación.

Por este motivo, se propone la aplicación de técnicas de Minería de Datos en el LLE para explorar con mejor detalle patrones, tendencias y reglas que expliquen regularidades del indicador. Además de las identificadas empíricamente en las secciones previas. De este modo, se requiere una identificación con interpretaciones matemáticas simplificadas y, aún más importante, que permita desarrollar este tipo de análisis en ventanas de tiempo reducidas.

La propuesta tiene como un propósito implícito identificar reglas que puedan ser más generalizables y demostrar que existen patrones embebidos en el LLE. De este modo, el desarrollo de la metodología de este trabajo contará con un sustento para su potencial aplicación en otros sistemas.

En este sentido, se plantean las siguientes técnicas descritas a continuación:

- Funciones Empíricas Ortogonales.
- Ingeniería de Características.
- Visualización de Datos.
- Equilibrio de Clases.
- Correlación de Información.

Se debe notar que las técnicas de Minería de Datos indicadas también fueron aplicadas para las señales del ángulo del rotor de los generadores. Esto con la finalidad de resaltar las propiedades o regularidades de la identificación de patrones que aparecen en el LLE y no directamente en el ángulo del rotor. En el ANEXO D se presentan los resultados de la aplicación de Minería de Datos en el ángulo del rotor.

Además, como se detallará más adelante en la sección 3.7, las EOF scores del ángulo del rotor también serán utilizadas en el proceso de Aprendizaje Automático como un suplemento o refuerzo a las EOF scores del LLE para mejorar la precisión de los resultados.

3.5.1. Funciones Empíricas Ortogonales

La aplicación de EOF es un método novedoso de reconocimiento de patrones que en investigaciones relacionadas ha mostrado resultados satisfactorios en cuestión de simplicidad y precisión [1], [52], y cuyo uso es considerado en el presente trabajo para la identificación matemática de patrones en el LLE.

Se presenta el desarrollo de un análisis de funciones EOF sobre el conjunto de las series de tiempo del LLE calculadas de las 10000 simulaciones de Montecarlo del sistema IEEE 9-Bus System (se consideran las 15 primeras muestras de tiempo de las señales del LLE).

En la Figura 3.22 se observan las EOF obtenidas. El análisis proporciona 15 funciones (vectores patrón EOF) que son capaces de reconstruir cualquier señal del LLE del conjunto simulado. Un aspecto que se debe destacar es que las primeras EOF poseen una dinámica más simple que las EOF de orden superior. En las primeras EOF es en donde se concentra la forma básica o esencial de las series de tiempo del LLE y la mayor variabilidad explicada.




Figura 3.22. Funciones EOF obtenidas para las series del LLE del generador G2




Figura 3.23. Funciones EOF obtenidas para las series del LLE del generador G3

De acuerdo con [1], es posible que las EOF scores asociadas a los vectores EOF puedan ser representadas mediante un espacio vectorial en el que se puedan distinguir Regiones Dinámicas de Vulnerabilidad (DVR), es decir, las regiones en donde se localizan las observaciones de eventos estables e inestables. A través de estas regiones DVR, una adecuada identificación de patrones permitiría diferenciar desde una perspectiva geométrica la ubicación espacial de estos eventos.

A partir del presente análisis, se desprenden 15 EOF scores. En la Figura 3.24 se exponen las DVR obtenidas con el espacio vectorial de las EOF scores: {EOF2, EOF3, EOF4} para los generadores G2 y G3. En este resultado se aprecia que los eventos inestables ocupan una región altamente concentrada del espacio vectorial indicado. Además, se identifica que los eventos inestables se encuentran localizados en una región cercana al origen.

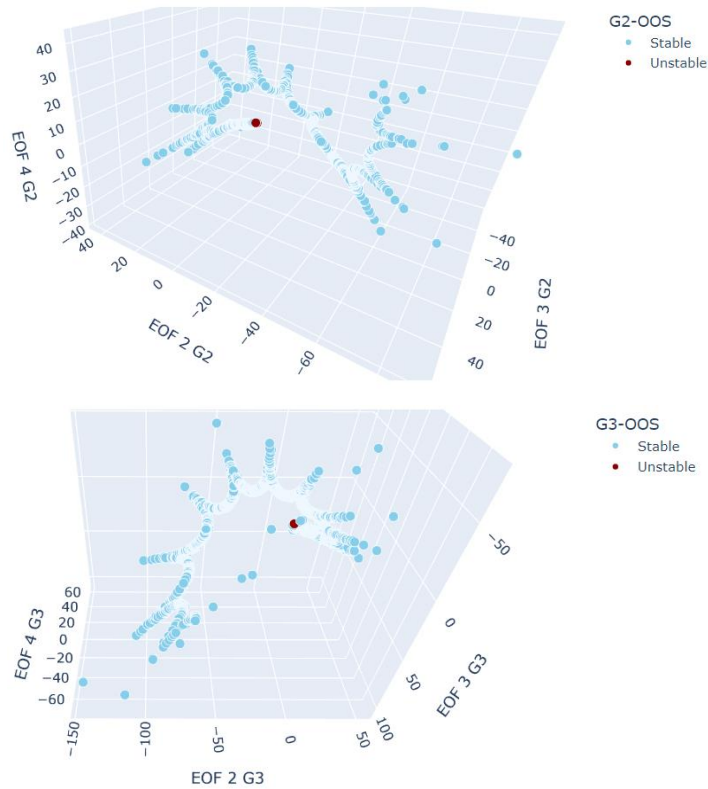


Figura 3.24. Representación tridimensional de las DVR formadas con el espacio vectorial $\{EOF2, EOF3, EOF4\}$ para los generadores G2 y G3

Se debe notar que las 15 EOF scores, que representan las nuevas características proporcionadas por esta técnica de Minería de Datos, conforman un nuevo espacio vectorial de regiones DVR de 15 dimensiones. Lógicamente, no es posible visualizar de una manera directa un espacio vectorial de 15 dimensiones en una representación bidimensional o tridimensional. Considerando esta limitación, en este trabajo se plantea el uso de varias técnicas de visualización multidimensional para sintetizar de una manera gráfica la identificación de patrones conseguida con la técnica de EOF.

Además, considerando que las primeras EOF scores concentran la mayor parte de la información del conjunto de datos [52], es posible considerar un número reducido de EOF en el análisis sin perder una cantidad significativa de información (extracción y selección de características), lo cual es analizado a continuación.

3.5.2. Ingeniería de Características

Con la finalidad de simplificar los modelos de representación de grandes volúmenes de datos y reducir el esfuerzo computacional asociado con el manejo de estos, sin perder información relevante, se considera en esta parte la aplicación de técnicas de extracción y selección de características. De este modo, es posible obtener una menor cantidad de

características y un análisis con aproximación aceptable [76]. La obtención de EOF scores representa en sí un proceso de extracción de características, mientras que la elección de las EOF más representativas se asocia con una tarea de selección de características.

En la Figura 3.25 y la Figura 3.26 se ilustra la variabilidad VE de las 15 EOF obtenidas. En el diagrama de codo mostrado se identifica que el punto de inflexión del codo de la curva de valores singulares se forma alrededor de 3 a 5 EOF. En este sentido, el análisis gráfico sugiere el uso representativo de al menos 5 EOF. Se considerará, con la finalidad de mantener una mayor precisión en los resultados, el uso de las 6 primeras EOF (EOF principales). Se observa que las 6 primeras EOF permiten alcanzar una variabilidad explicada superior al 84%.




Figura 3.25. Variabilidad Explicada de las EOF para el generador G2




Figura 3.26. Variabilidad Explicada de las EOF para el generador G3

En la Figura 3.27 se muestra un ejemplo de reconstrucción de una señal original aleatoria del LLE considerando solamente las 6 primeras EOF en el generador G3. Se evidencia que existe aproximación a la señal original con una ligera pérdida de información.




Figura 3.27. Ejemplo de reconstrucción de una serie de tiempo del LLE del generador G3 considerando las 6 primeras EOF

3.5.3. Visualización de Datos

3.5.3.1. Visualización de Coordenadas Paralelas

La versatilidad de este gráfico puede brindar la potencialidad de visualización del espacio vectorial formado por todas las EOF scores del presente análisis. En este caso, en la Figura 3.28 se presenta el gráfico correspondiente al estudio desarrollado, en donde se trazan las coordenadas paralelas de las EOF scores obtenidas para los generadores G2 y G3.

En este resultado es posible visualizar el espacio vectorial de las 15 EOF scores de una manera consolidada. Nuevamente, se observa que las EOF scores de eventos inestables se concentran en una región reducida del espacio vectorial, lo cual es un resultado análogo relacionado directamente con las conclusiones identificadas en la sección 3.4.5, en donde se encontró que la magnitud del LLE de eventos inestables tiene un rango reducido. Además, se observa que esta concentración se encuentra cercana al origen del espacio vectorial, lo cual constituye una regularidad adicional en la magnitud del LLE de eventos inestables. *En este sentido, se encuentra que las EOF scores de eventos inestables ocupan un espacio vectorial reducido y que se encuentra cerca del origen.*

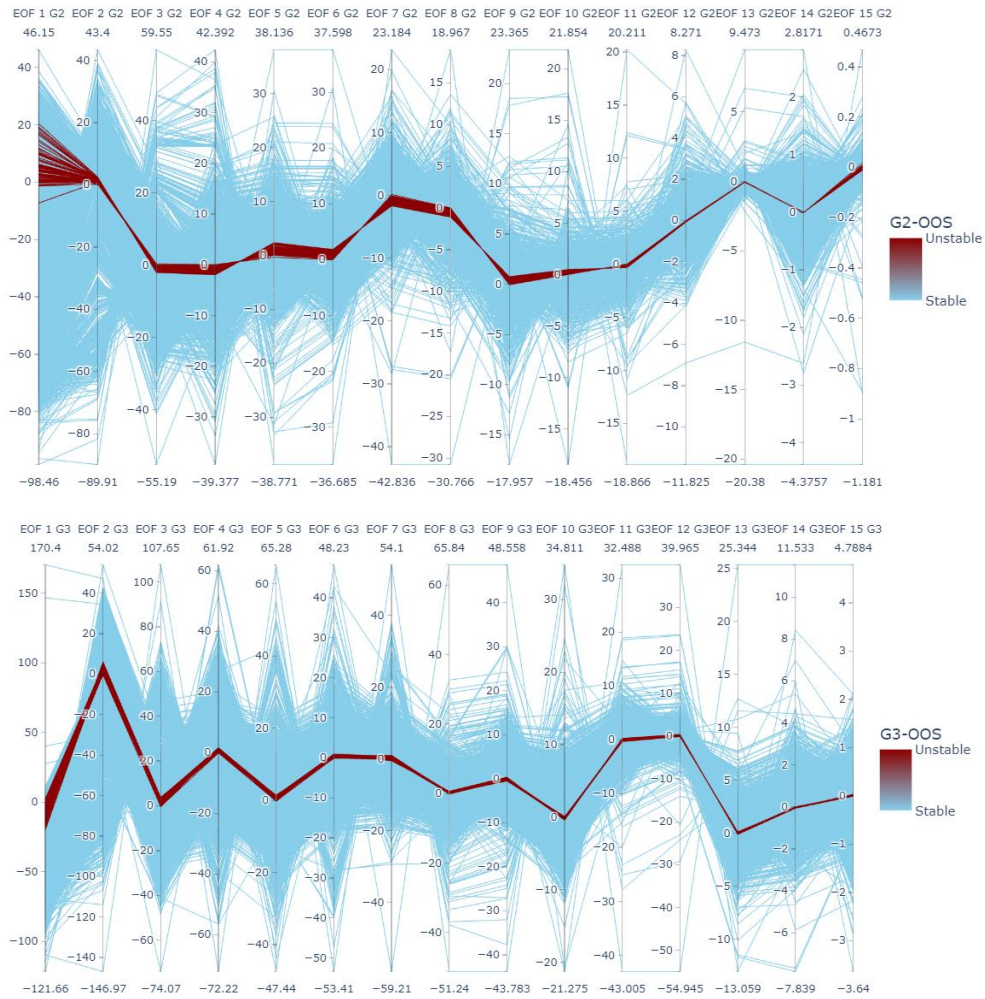


Figura 3.28. Ilustración de Coordenadas Paralelas de las 15 EOF scores obtenidas para los generadores G2 y G3

3.5.3.2. Visualización de las Curvas de Andrews

En el contexto del problema analizado, se considera el conjunto de EOF scores de las observaciones como las características que constituirán los coeficientes de las correspondientes Curvas de Andrews. En la Figura 3.29 y la Figura 3.30 se observan las Curvas de Andrews construidas a partir de 6 y 15 EOF scores, es decir, las curvas desarrolladas a partir de 6 y 15 términos respectivamente.

En estas curvas puede identificarse la concentración de los eventos inestables en una región espacial pequeña, de manera muy similar a lo que se ha analizado hasta este momento con otros gráficos. En consecuencia, se aprecia con un nuevo algoritmo, la concentración de eventos inestables en una región reducida del espacio vectorial.




Figura 3.29. Curvas de Andrews formadas a partir de las 6 primeras EOF scores obtenidas para los generadores G2 y G3 (EOF scores normalizadas entre 0 y 1)




Figura 3.30. Curvas de Andrews formadas a partir de las 15 EOF scores obtenidas para los generadores G2 y G3 (EOF scores normalizadas entre 0 y 1)

Se debe notar que la adición de un mayor número de EOF scores tiene como contribución la inclusión de componentes de alta frecuencia. Además, es evidente que el orden de las

características de una observación juega un papel importante en el análisis de estas curvas. Como sugiere Andrews en [57], el orden sugerido de las variables que construyen una observación debe ser dado por aquel determinado en un análisis de Componentes Principales. En el presente caso, será el determinado por la variabilidad VE de las EOF scores, es decir: {EOF1, EOF2, EOF3, ...}.

3.5.3.3. Visualización Multidimensional del Algoritmo de RadViz

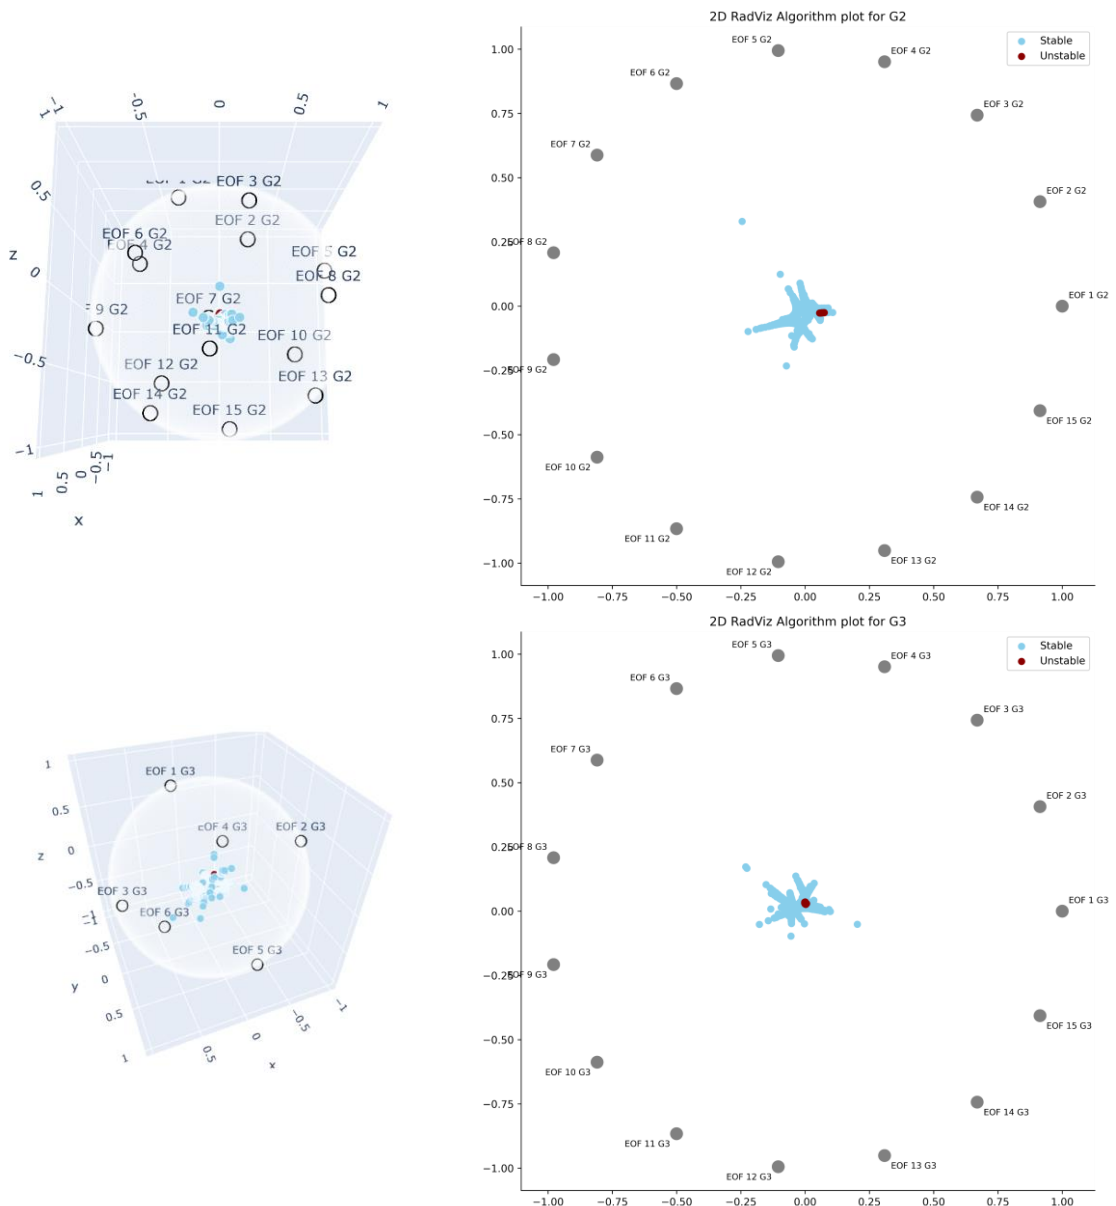


Figura 3.31. Representación tridimensional y bidimensional del espacio vectorial compuesto por las 15 EOF scores obtenidas para los generadores G2 y G3

En el presente análisis de las 15 EOF scores del LLE, se obtiene el resultado mostrado en la Figura 3.31, en donde cada EOF constituye un DA en la representación de RadViz. En

esta visualización se identifica con más claridad que los eventos inestables se localizan en una región concentrada definida por el espacio vectorial de las 15 EOF scores. Esta localización se encuentra cercana al origen. Además, se observa que existe solapamiento entre eventos estables e inestables.

3.5.4. Equilibrio de Clases

En un SEP lo suficientemente acondicionado, se espera que la mayoría de las contingencias más probables no conduzcan al sistema hacia condiciones inestables [11]. Desde una perspectiva de simulaciones de Montecarlo, es razonable que la mayor parte de simulaciones de contingencias obtenidas correspondan a eventos estables y que un número reducido se relacionen con eventos inestables, es decir, un número dispar de eventos inestables y estables.

El desbalance entre la clase estable e inestable puede ser un problema para el adecuado funcionamiento de los algoritmos de Aprendizaje Automático que serán considerados en la etapa de Evaluación predictiva de Estabilidad Transitoria. Esto debido a que se puede subestimar o solapar la información de la clase con menor número de observaciones, en este caso, la clase inestable.

Por tal motivo, de acuerdo con lo sugerido por varios autores en [1], [36], [77], es necesario el manejo del desbalance de clases para evitar la subrepresentación de clases minoritarias. Este problema persiste en muchos campos científicos, por ejemplo: la identificación de células cancerosas, la detección de derrames de petróleo, la detección de fraudes, la extracción de palabras clave, la clasificación de textos o la inestabilidad de sistemas dinámicos. En estos casos la identificación de observaciones de la clase minoritaria es crítica, e inclusive muchas veces más importante que lograr una precisión general óptima para la clase mayoritaria.

Para conseguir un balance entre clases, existe la posibilidad de sobremuestrear las observaciones minoritarias o submuestrear las observaciones mayoritarias. Para el presente trabajo, no se considera el sobremuestreo de la clase minoritaria. Esto debido a que el sobremuestreo replica más de una vez algunas observaciones minoritarias. De este modo, una misma observación puede encontrarse en el conjunto de prueba y en el de entrenamiento a la vez, lo cual provocará sobreajuste en los algoritmos y un resultado aparente de alta precisión equívoco [78].

En consecuencia, este trabajo plantea el uso de una técnica de submuestreo de la clase mayoritaria (eventos estables). Por ejemplo, para el SEP de prueba, se obtuvo en la

frecuencia relativa de observaciones que menos del 1% de simulaciones corresponden a eventos inestables (ver Figura 3.5). Con la aplicación de submuestreo, se tendrá como resultado un nuevo conjunto de datos, en el que el número de observaciones de eventos estables es igual al número de observaciones de eventos inestables.

La técnica de submuestreo usada se basa en el algoritmo *NearMiss version 3* [79]. Este algoritmo se enfoca en las observaciones de la clase mayoritaria más cercanas a la clase minoritaria. En este algoritmo, es posible definir la cantidad de observaciones vecinas que se seleccionarán para cada observación minoritaria. Esto sujeto a la restricción de que se mantenga una relación de equilibrio deseada entre las observaciones de cada clase. En este sentido, es posible definir cuál será la relación entre el número de observaciones de cada clase (en el presente caso el mismo número de observaciones en todas las clases).

En la Figura 3.32 se presenta un ejemplo de la aplicación de este algoritmo sobre un conjunto de datos desbalanceado de 10000 observaciones. Se configura el parámetro de número de observaciones vecinas en un valor igual a tres. Con la aplicación del algoritmo, se obtiene un submuestreo que permite mantener el equilibrio entre clases deseado.

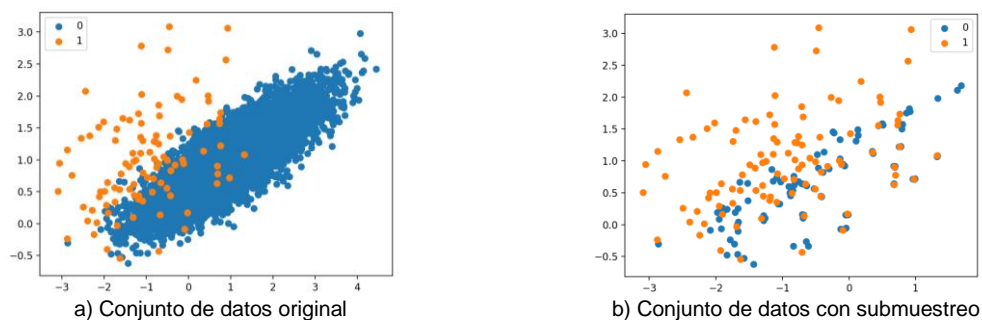


Figura 3.32. Ejemplo de la aplicación del algoritmo NearMiss version 3. Nro. observaciones iniciales: {0: 9900, 1: 100}

Se debe notar que existe pérdida de información en la aplicación del submuestreo, porque se eliminan observaciones del conjunto de datos. No obstante, es preciso puntualizar las siguientes consideraciones que muestran que esta pérdida puede no ser crucial para los propósitos de este trabajo.

El algoritmo NearMiss version 3 preserva o no elimina aquellas observaciones de eventos estables que se encuentran cerca de los eventos inestables, lo cual permite que se mantenga la información necesaria para que los algoritmos de Aprendizaje Automático definan una frontera adecuada en las regiones DVR. Esto es posible porque las observaciones estables más cercanas a las inestables son también las más cercanas a la

frontera, y son éstas las que definen en gran medida el desempeño de un algoritmo de clasificación, como ocurre con el algoritmo de SVM y los vectores soporte asociados [61].

Por otro lado, se ha evidenciado que el conjunto de observaciones estables es mucho más disperso que las observaciones inestables, por lo que el algoritmo NearMiss eliminará gran parte de las observaciones estables que se mantienen considerablemente alejadas de las observaciones inestables y que no se encuentran en las regiones de solapamiento, las cuales son críticas de abordar por parte de los algoritmos de Aprendizaje Automático.

En la Figura 3.33 y la Figura 3.34 se observa el resultado obtenido con la aplicación del algoritmo de submuestreo en las EOF scores de cada generador. Un aspecto destacado es que han sido omitidas o eliminadas aquellas observaciones estables alejadas de la región de concentración de eventos inestables. Aquellas observaciones estables cercanas a las inestables se mantienen y pueden permitir a un algoritmo de Aprendizaje Automático definir apropiadamente una frontera entre casos estables e inestables.




Figura 3.33. Aplicación del algoritmo NearMiss version 3 en EOF scores del generador G2. Nro. observaciones iniciales: {Estables: 9921, Inestables: 79}




Figura 3.34. Aplicación del algoritmo NearMiss version 3 en EOF scores del generador G2. Nro. observaciones iniciales: {Estables: 9903, Inestables: 97}

Cabe mencionar que luego de aplicar la técnica de submuestreo se observa con mayor claridad el solapamiento entre las observaciones estables e inestables. Esto representa un problema para la definición de una frontera que brinde una precisión total para la distinción de eventos estables e inestables. Se debe notar que se trata de un problema común en tareas de clasificación, sobre todo cuando se tienen conjuntos de datos con clases desbalanceadas, como en el presente trabajo [77]. La manera en la que se abordará una solución a este problema se describirá más adelante, en la sección 3.7.

3.5.5. Correlación de Información

El análisis de correlación lineal en un conjunto de datos permite la identificación de características que mantengan una dependencia lineal significativa entre sí, de manera que sea factible omitir algunas de estas características redundantes, conservando aquellas que brindan información suficiente [78].

En la Figura 3.35 se expone la matriz de correlación obtenida considerando como características las EOF scores obtenidas en el presente análisis. En esta matriz, cada elemento representa el valor de correlación entre las correspondientes EOF scores. Se aprecia que las correlaciones más elevadas se presentan entre la EOF1 del generador G1 con las EOF1 del generador G2 y G3 respectivamente. Como se observa, en general las correlaciones son relativamente bajas, por lo que no es posible considerar que existe una alta dependencia lineal entre las EOF scores. De este modo, no se tiene evidencia suficiente para omitir a alguna EOF del análisis.




Figura 3.35. Matriz de correlación obtenida para el sistema de prueba IEEE 9-Bus System

3.5.6. Comparación entre las EOF del LLE y las EOF del ángulo del rotor

La técnica de EOF en las series de tiempo del ángulo del rotor proporciona varios resultados (expuestos en el ANEXO D) que resaltan las regularidades de la identificación de patrones que se presentan en el LLE y no en el ángulo del rotor. Por ejemplo:

- En las EOF scores del ángulo la mayor variabilidad del conjunto de datos ($EV > 99.9\%$) se presentan con 3 EOF. No obstante, en las EOF scores del LLE existe variabilidad extendida en un número mayor de EOF. Para este caso se tiene que con más de 5 EOF apenas se supera el $EV > 80\%$. Esto denota que el LLE está describiendo la dinámica del ángulo del rotor a través de una interpretación matemática de mayor número de variables.
- Las EOF scores del LLE correspondientes a eventos inestables se concentran en una región reducida del espacio vectorial dentro de las regiones DVR. Esta propiedad no se observa en las EOF del ángulo del rotor, en donde los eventos inestables presentan una dispersión similar a la de los eventos estables. Esta situación se resalta aún más en la visualización de coordenadas paralelas y en las herramientas de visualización multidimensional planteadas en este trabajo.
- La mayor dispersión de las EOF del ángulo del rotor de eventos inestables provoca la aparente formación de grupos de datos que se solapan aún más entre las observaciones de eventos estables. Esta condición no ocurre en las EOF del LLE, en donde los eventos estables se encuentran más concentrados y con menor tendencia al solapamiento con eventos estables.

3.6. Conclusiones de la aplicación del LLE y del uso de Minería de Datos

A partir del análisis de estas secciones se han identificado comportamientos regulares en el LLE que pueden ser considerados para la evaluación predictiva de Estabilidad Transitoria. Para esto, se deberán tomar en cuenta las siguientes conclusiones del presente análisis que se constituyen en una contribución para el campo de investigación relacionado:

- 1) *En la mayoría de los eventos relacionados con cortocircuitos en un SEP, se espera que, en los primeros instantes posfalla, la magnitud del LLE de casos inestables ocupe un rango de valores o un espacio vectorial mucho menor que el ocupado por el LLE de casos estables. Esta característica también se evidencia con la*

transformación de las series de tiempo del LLE en Funciones Empíricas Ortogonales.

- 2) *En la evaluación en tiempo real de Estabilidad Transitoria no es factible el análisis del signo final del LLE, como se ha propuesto en múltiples investigaciones [4], [5], debido a los retardos de convergencia del LLE involucrados. Alternativamente, es posible considerar el análisis de patrones de las primeras muestras del LLE, en las cuales se encuentran inmersas regularidades en la magnitud del LLE. Este nuevo enfoque permite obtener ventanas de observación reducidas y acondicionadas para el análisis en tiempo real.*
- 3) *Considerando que el LLE refleja una tasa de variación en el ángulo δ , entonces el LLE en el estado posfalla se encuentra también relacionado matemáticamente con el torque de desaceleración de la máquina sincrónica.⁴*
- 4) *Con la finalidad de identificar información embebida en las primeras muestras del LLE de posfalla, se plantea la aplicación de técnicas de Minería de Datos para superar los problemas de imprecisión, retardo y solapamiento identificados en este indicador.*
- 5) *La aplicación de EOF en las series de tiempo del LLE permite identificar de una manera formal, desde una perspectiva matemática, patrones inmersos en estas señales, los cuales pueden ser considerados como nuevas características para un proceso de Aprendizaje Automático.*

3.7. Evaluación Predictiva de Estabilidad Transitoria

En esta sección se describe una parte esencial de la metodología propuesta, en donde se incluyen herramientas matemáticas que automatizan la predicción de una condición estable o inestable del SEP considerando los patrones identificados por las EOF scores. Se considera el uso de algoritmos de Aprendizaje Automático, específicamente, algoritmos de clasificación para la evaluación predictiva de Estabilidad Transitoria.

La propuesta considera las EOF scores del LLE como una matriz o conjunto de datos que es utilizado para el entrenamiento de los algoritmos. Se define como etiqueta o *target value* de salida de esta matriz de datos la clase de evento (índice de estabilidad), que refleja el estatus de estabilidad futuro del sistema: estable o inestable. De este modo, esta

⁴ Se debe notar que de la misma manera en la que no es posible obtener una expresión analítica para el ángulo del rotor en función del tiempo, tampoco puede ser determinada una expresión explícita del LLE en función del tiempo en el estado posfalla.

evaluación predictiva se convierte en un ejercicio de clasificación binaria, cuyo propósito es determinar, en tiempo real y de manera temprana, si una señal poscontingencia del ángulo del rotor (de la que se obtiene el LLE y las EOF scores asociadas) presentará en el futuro una condición estable o inestable.

Se consideran los siguientes algoritmos de clasificación de gran aplicación y flexibilidad en el campo del Aprendizaje Automático en diversos ámbitos científicos:

- Nearest Shrunken Centroids (NSC) - Módulo: *NearestCentroid*
- Support Vector Classifier (SVC) - Módulo: *SVC*
- Random Forest Classifier (RFC) - Módulo: *RandomForestClassifier*
- Multi-Layer Perceptron Classifier (MLPC) - Módulo: *MLPClassifier*

3.7.1. Datos de entrada

3.7.1.1. Enfoques de evaluación

Con relación a la matriz de datos para el proceso de entrenamiento, se tomarán en cuenta dos enfoques.

- Enfoque individual de evaluación.- El primer enfoque considera de manera individual las p EOF scores de cada generador que constituyen una variabilidad explicada mayor al 80% (EOF principales). Se considera como la etiqueta de salida al índice de estabilidad correspondiente al generador considerado. Es decir, aquel correspondiente a los eventos en los que el generador estudiado pierde o no estabilidad, independientemente de lo que ocurre con los otros generadores de un sistema. En la Figura 3.36 se esquematiza la estructura de la matriz de datos utilizada para el enfoque individual de evaluación predictiva. De este modo, se tendrá un clasificador para cada unidad de generación que forme parte del análisis.

Observación	EOF 1 Gen i	EOF 2 Gen i	...	EOF p Gen i	y = Índice de estabilidad individual
1	#	#	#	#	(estable o inestable)
2	#	#	#	#	(estable o inestable)
...	#	#	#	#	(estable o inestable)
Nro. simulaciones	#	#	#	#	(estable o inestable)

Figura 3.36. Estructura de la matriz de datos de entrada para los algoritmos de clasificación en un enfoque individual de evaluación

- Enfoque global de evaluación.- En este segundo enfoque se considera conjuntamente las p_i EOF scores de cada i -ésimo generador del sistema (que constituyen una variabilidad explicada mayor al 80%) en una sola matriz de datos. Se consideran solo aquellos generadores críticos que pierden estabilidad en el

sistema. La etiqueta de salida es el índice de estabilidad global del sistema. En la Figura 3.37 se esquematiza la matriz de datos utilizada en este caso.

Observación	EOF 1 Gen 1	...	EOF p_1 Gen 1	...	EOF 1 Gen i	...	EOF p_i Gen i	...	EOF 1 Gen n	...	EOF p_n Gen n
1	#	#	#		#	#	#		#	#	#
2	#	#	#		#	#	#		#	#	#
...	#	#	#		#	#	#		#	#	#
Nro. simulaciones	#	#	#		#	#	#		#	#	#

$y =$ Índice de estabilidad global
(estable o inestable)
(estable o inestable)
(estable o inestable)
(estable o inestable)

Figura 3.37. Estructura de la matriz de datos de entrada para los algoritmos de clasificación en un enfoque global de evaluación

3.7.1.2. Información suplementaria

Como se ha observado en los resultados de la sección 3.5, con relación a las regiones DVR de las EOF scores del LLE, existe solapamiento entre las observaciones de eventos estables e inestables. Esta situación tiene como efecto que los algoritmos de clasificación enfrenten dificultades para alcanzar altas precisiones. Este problema es común en fenómenos en los que existe un alto grado de desbalance de clases [77], como ocurre en el presente análisis de Estabilidad Transitoria.

Más aún, en el ANEXO D se presentan los resultados de las DVR obtenidas para el ángulo del rotor, en donde el lector puede comprobar que el solapamiento también está presente en estas EOF scores. No obstante, se determina que las EOF scores del LLE y del ángulo del rotor son distintas, de modo que éstas podrían aportar individualmente información para reducir el efecto del solapamiento y permitir la mejora de la precisión de los algoritmos de clasificación.

Bajo esta premisa, en esta metodología se propone utilizar las EOF scores del ángulo del rotor de manera suplementaria a las EOF scores del LLE. Es decir, adicionar a las matrices de datos del LLE (Matriz LLE) esquematizadas en las Figura 3.36 y Figura 3.37 matrices análogas pero con las EOF scores del ángulo del rotor (Matriz Ang). El propósito final es conseguir mejorar las métricas de precisión en los algoritmos de clasificación. En la Figura 3.38 se esquematiza la estructura de esta matriz, que puede considerarse como una matriz de datos mixta (Matriz LLEAng), que cuenta con las EOF scores del LLE y del ángulo del rotor como información suplementaria.

Observación	EOF LLE 1	...	EOF LLE $n \times p$...	EOF δ 1	...	EOF δ $n \times q$
1	#	#	#		#	#	#
2	#	#	#		#	#	#
...	#	#	#		#	#	#
Nro. simulaciones	#	#	#		#	#	#

$y =$ Índice de estabilidad global
(estable o inestable)
(estable o inestable)
(estable o inestable)
(estable o inestable)

* n: Número de generadores críticos, p: Número de EOF scores principales del LLE, q: Número de EOF scores principales del Ángulo del rotor δ .

Figura 3.38. Estructura de una matriz de datos mixta para los algoritmos de clasificación

La matriz de datos mixta se considerará de manera comparativa con los resultados obtenidos de manera individual con las EOF scores del LLE y del ángulo del rotor.

3.7.1.3. Tratamiento de datos

Se consideran diferentes transformaciones o tratamientos de datos previos, efectuados sobre las matrices de datos descritas antes. Esto debido a que la disparidad de magnitud, estructura y demás propiedades del conjunto de datos de las EOF puede interferir en el desempeño de los algoritmos de clasificación. En el presente trabajo se consideran las siguientes variaciones para el tratamiento de las matrices de datos [54]:

- Datos Originales (Ori) – Ningún tratamiento.
- Estandarización Univariante (Sta).
- Estandarización Univariante y Ponderación de Clases (StWe).
- Normalización unitaria (Nor).
- Equilibrio de clases (Res) – De acuerdo con la sección 3.5.4.

La ponderación de clases hace referencia a un artificio matemático disponible en Python para considerar el desbalance de clases. Este tratamiento de clases solo es posible en los algoritmos SVC y RFC. En este caso, se proporciona una ponderación en la formulación matemática de los clasificadores para ajustar automáticamente pesos de forma inversamente proporcional a las frecuencias de clase en los datos de entrada.

3.7.1.4. División del conjunto de datos en entrenamiento y prueba.

En este trabajo se considera la partición de la matriz de datos de entrada en un conjunto de entrenamiento y otro de prueba. La partición de los datos se desarrolla de manera aleatoria. En la Figura 3.39 se ilustra la partición de la matriz de datos. Se considera, de acuerdo con diversas recomendaciones de varios autores [59], que el 80% de los datos constituyan el conjunto de entrenamiento y la porción restante el conjunto de prueba.

Observación	EOF 1 Gen i	EOF 2 Gen i	...	EOF p Gen i
1	#	#	#	#
2	#	#	#	#
3	#	#	#	#
4	#	#	#	#
...	#	#	#	#
...	#	#	#	#
...	#	#	#	#
Nro. simulaciones	#	#	#	#

$y =$ Índice de estabilidad	
(estable o inestable)	Conjunto de entrenamiento 80% de los datos
(estable o inestable)	
(estable o inestable)	
(estable o inestable)	
(estable o inestable)	Conjunto de prueba 20% de los datos
(estable o inestable)	
(estable o inestable)	

Figura 3.39. Partición de la matriz de datos para los algoritmos de clasificación

3.7.2. Resultados de Evaluación Predictiva

En la Figura 3.40 se ilustra el resultado de clasificación, a través de una matriz de confusión, obtenido con diferentes algoritmos y varios criterios de tratamiento de datos en la matriz de EOF scores del LLE. En este ejemplo se evidencian las particularidades del desempeño de los clasificadores considerados. Para la obtención de estos resultados iniciales, se consideran los hiperparámetros por defecto de los clasificadores disponibles en la librería *sklearn* de Python. El resultado ejemplificado en la Figura 3.40 sugiere que con una misma matriz de datos de entrada es posible obtener diversidad en las métricas de desempeño y, por lo tanto, existe la necesidad de encontrar los mejores algoritmos de clasificación.

En este contexto, se observa en la matriz de confusión que el *accuracy* en cada clase (elementos diagonales) tiene variaciones significativas entre algoritmos e inclusive entre clases. Evidentemente, el desbalance de clases presenta una influencia en esta métrica. Además, se observa cómo hay algoritmos que abordan de mejor forma la predicción de eventos estables o inestables. A través de Python, se consigue el entrenamiento de los clasificadores indicados, con las variaciones de tratamiento de datos descritas para las matrices de datos de las EOF scores del LLE, del ángulo y una matriz de datos mixta con ambos tipos de EOF scores.






Figura 3.40. Matriz de Confusión para algoritmos de clasificación considerando las EOF scores del LLE del generador G2



a) recall en la clase estable



b) recall en la clase inestable

Figura 3.41. Resultado de la métrica *recall* para el generador G3

Con relación a las métricas de desempeño descritas en la sección 2.5.1.4, existen diferentes valoraciones que se pueden adoptar para el desempeño de un clasificador y estas métricas pueden ser exclusivas para la clase estable o inestable. Por ejemplo, en la Figura 3.41 se observa el resultado de la métrica *recall* para el generador G3. Esta métrica puede ser evaluada por separado para la clase estable e inestable. Se observa que para

diferentes algoritmos y tratamiento de datos es posible obtener una elevada métrica al considerar las EOF scores del LLE y la matriz mixta de EOF scores.

Por otro lado, en la Figura 3.42 se presenta el resultado de la métrica *balanced accuracy* para el generador G3. Esta métrica es útil cuando se tratan datos con desbalance de clases, es decir, cuando una clase aparece con mayor frecuencia que la otra, como en el presente caso. Además, en este análisis, la métrica tiene la particularidad de ser la media aritmética del recall de eventos estables e inestables. De esta manera, se considera el efecto de la clasificación en ambas clases y así se reduce el grado de sobreestimación de la métrica debido al mayor número de observaciones estables que son predichas correctamente. En el *balanced accuracy* se evidencian las mejoras en el desempeño de los clasificadores que causa la introducción de las EOF scores del LLE y la matriz mixta.




Figura 3.42. Resultado de la métrica *balanced accuracy* para el generador G3

En este punto, se debe notar que la concentración de patrones en una región reducida de un espacio vectorial evidenciada en las EOF scores del LLE puede ser vista también como la adición de una característica adicional a los algoritmos de Aprendizaje Automático, la cual puede ser interpretada matemáticamente por estos durante el proceso interno de entrenamiento. Según lo demuestra la Ingeniería de Características, la inclusión de nueva información extraída de la original puede brindar mejores precisiones en el entorno del Aprendizaje Automático [76], [80], [81].

Desde otra perspectiva, la alta concentración de EOF scores del LLE de eventos inestables permitiría incrementar la dependabilidad y seguridad conseguida con los algoritmos de clasificación. Esto considerando que la característica de localización introduce en los algoritmos de aprendizaje un criterio adicional sobre la ubicación espacial de estas DVR en el espacio vectorial correspondiente.

Finalmente, cabe mencionar que se han medido los tiempos computacionales relacionados con la predicción de un evento en la clase estable o inestable. En este sentido, se ha determinado que la predicción de Estabilidad Transitoria con los diferentes algoritmos de clasificación se desarrolla en tiempos menores a 1 ms. En consecuencia, se demuestra que los tiempos de predicción son considerablemente reducidos y que no afectan prácticamente a las ventanas de tiempo que se analizaron en el apartado 3.4.4. Por lo tanto, los tiempos computacionales de cálculo pueden ser despreciados.

3.8. Análisis de desempeño de algoritmos de Aprendizaje Automático

En esta sección se introducen los criterios considerados para la comparación entre algoritmos de clasificación y los conceptos relacionados con el proceso de optimización de hiperparámetros a través de una herramienta de solución robusta de Python. El propósito final es encontrar aquellos algoritmos más adecuados para el problema analizado [59].

3.8.1. Comparación entre algoritmos de clasificación

De acuerdo con lo expresado en las secciones previas, el desempeño de un clasificador puede evaluarse con base en el multicriterio de diferentes métricas. Además, las métricas pueden concentrarse en la cuantificación del desempeño de clasificación en una sola clase en particular. En este sentido, en el presente trabajo se propone como métrica de comparación el *balanced accuracy*. Esto debido a que se trata de una métrica que considera conjuntamente el resultado de clasificación de las clases estables e inestables (media aritmética de las métricas *recall* en cada clase). Asimismo, el *balanced accuracy* aborda el problema del desbalance de datos de una manera apropiada; evitando la sobreestimación del *accuracy* obtenido para la clase estable (clase mayoritaria) [82].

En la comparación se consideran los algoritmos de clasificación y las alternativas de tratamiento de datos descritas previamente. En este sentido, se identifican las opciones que proporcionan la mejor métrica del *balanced accuracy*. Las mejores opciones serán consideradas más adelante en la sección 3.8.2, en donde se propone la optimización de hiperparámetros con la finalidad de mejorar aún más la métrica de desempeño.

Para el sistema de prueba, se tienen los resultados de la Tabla 3.4. En este detalle se exponen los clasificadores que proveen los valores más elevados del *balanced accuracy*, considerando las EOF scores del LLE, del ángulo y ambas. Además, se añaden los resultados para el enfoque individual de evaluación por generador y para el enfoque global. En este resultado se observa que el clasificador SVC, con el tratamiento StWe, tiende a presentar mejores resultados.

Tabla 3.4. Compendio de resultados del mejor *balanced accuracy* por tipo de EOF score para el sistema IEEE 9-Bus System

Clasificador-Tratamiento	Best Balanced Accuracy		
	G2	G3	Global
SVC-StWe	1) LLE+Ang (0.9945) 3) LLE (0.9401)	1) Ang (0.9826) 2) LLE (0.9615) 3) LLE+Ang (0.9434)	2) LLE+Ang (0.9603) 3) LLE (0.9303)
NearestCentroid-Nor	2) Ang (0.9590)		1) Ang (0.9690)

Por otro lado, en la Tabla 3.5 se muestran los mejores resultados obtenidos en cada clasificador y tratamiento. Se resaltan las mejores opciones para cada caso.

Tabla 3.5. Compendio de resultados del mejor *balanced accuracy* por clasificador para el sistema IEEE 9-Bus System

Clasificador-Tratamiento	Best Balanced Accuracy		
	G2	G3	Global
NearestCentroid-Ori	Ang (0.9540)	LLE (0.8405)	LLE+Ang (0.9484)
SVC-Ori	LLE (0.5000)	LLE (0.5000)	Ang (0.5357)
RandomForestClassifier-Ori	Ang (0.7692)	LLE+Ang (0.7303)	LLE+Ang (0.7140)
MLPClassifier-Ori	Ang (0.6528)	LLE+Ang (0.5385)	Ang (0.7794)
NearestCentroid-Sta	Ang (0.9587)	LLE+Ang (0.8938)	Ang (0.9668)
SVC-Sta	Ang (0.7308)	LLE (0.5000)	Ang (0.6424)
RandomForestClassifier-Sta	Ang (0.7692)	LLE+Ang (0.7303)	Ang (0.7135)
MLPClassifier-Sta	LLE+Ang (0.7690)	LLE+Ang (0.5762)	LLE+Ang (0.7140)
SVC-StWe	LLE+Ang (0.9945)	Ang (0.9826)	Ang (0.9615)
RandomForestClassifier-StWe	Ang (0.6923)	LLE+Ang (0.6913)	LLE+Ang (0.7133)
NearestCentroid-Nor	Ang (0.9590)	Ang (0.9057)	Ang (0.9690)
SVC-Nor	Ang (0.6923)	LLE (0.5000)	Ang (0.5714)
RandomForestClassifier-Nor	Ang (0.7692)	LLE+Ang (0.7303)	LLE (0.6781)
MLPClassifier-Nor	Ang (0.7305)	LLE (0.5000)	LLE+Ang (0.7133)
NearestCentroid-Res	LLE+Ang (0.6771)	Ang (0.6310)	Ang (0.8099)
SVC-Res	LLE+Ang (0.7438)	LLE+Ang (0.6429)	LLE (0.7576)
RandomForestClassifier-Res	LLE+Ang (0.8042)	LLE+Ang (0.8214)	LLE (0.8535)
MLPClassifier-Res	LLE+Ang (0.6083)	LLE+Ang (0.7857)	LLE+Ang (0.8750)

Con el fin de que el proceso de optimización cuente con una mayor diversidad de algoritmos, se utiliza como insumo el resultado de la Tabla 3.5. Una vez que se han identificado las alternativas de clasificación que presentan la mejor métrica de desempeño, se procede con un proceso de optimización de hiperparámetros que considera como base estas alternativas.

3.8.2. Optimización Bayesiana de hiperparámetros

El proceso de optimización considera las características y particularidades de diferentes algoritmos de Aprendizaje Automático, dentro de un análisis para identificar aquellos algoritmos más adecuados para el problema en cuestión. Para el presente trabajo, en la

Tabla 3.6 se detalla el dominio considerado para los hiperparámetros a ser optimizados en los correspondientes algoritmos de clasificación.

Tabla 3.6. Dominio del conjunto de Hiperparámetros considerados en la optimización de algoritmos de clasificación

Clasificador (módulo)	Hiperparámetros	Dominio
NearestCentroid	shrink_threshold	[0 - 1.01], steps = 0.001
	metric	['euclidean', 'manhattan']
SVC	C	(1e-6, 1e+6, 'log-uniform')
	Gamma	(1e-6, 1e+1, 'log-uniform')
	n_estimators : El número de árboles en el bosque.	[100 - 1000], No. elements = 20
	max_depth : La profundidad máxima del árbol (número de nodos).	[10 - 110], No. elements = 11
RandomForestClassifier	min_samples_split : Número mínimo de observaciones requeridas para dividir un nodo interno.	[2 - 10]
	Criterion : Función para medir la calidad de una división.	['gini', 'entropy']
	min_samples_leaf : El número mínimo de muestras requeridas para dividir un nodo interno.	[2, 3, 4]
	Bootstrap	[True, False]
	layer1	[2 - 100]
	layer2	[2 - 100]
	layer3	[2 - 100]
	layer4	[2 - 100]
MLPClassifier	activation	['logistic', 'tanh', 'relu']
	alpha	(1e-7, 1e2, 'log-uniform')
	learning_rate_init	Real(0.0001, 1)

Se debe notar que, durante el proceso de optimización, la metodología propuesta proporciona tres alternativas de estimación del *balanced_accuracy*:

- **Training CV**: Estimación obtenida durante el proceso de optimización (considerando validación cruzada), es decir, el valor máximo de la Función Sustituta.
- **Testing**: Estimación en un conjunto de prueba independiente del conjunto utilizado en el entrenamiento y considerando el modelo que proporcionó la mejor métrica en la optimización.
- **CV**: Estimación con validación cruzada para el modelo final entrenado con hiperparámetros óptimos.

En primer lugar, se exponen varios ejemplos de los resultados obtenidos del proceso de optimización de hiperparámetros. En este caso, en las Figuras 3.43-3.46 se ilustran los resultados correspondientes del generador G2. En el ANEXO E pueden consultarse los resultados completos de optimización de todos los Algoritmos de Clasificación.

- Optimización Bayesiana MLPC-Sta**
- Best balanced_accuracy (Training CV) = 0.8812
 - balanced_accuracy (Testing) = 0.96
 - balanced_accuracy (CV) = 0.902
 - Best Parameters:
 - ('activation', 'relu')
 - ('alpha', 1.5108e-06)
 - ('layer1', 44)
 - ('layer2', 2)
 - ('layer3', 56)
 - ('layer4', 53)
 - ('learning_rate_init', 0.01337)




Figura 3.43. Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

- Optimización Bayesiana SVC-StWe**
- Best balanced_accuracy (Training CV) = 0.9923
 - balanced_accuracy (Testing) = 0.9935
 - balanced_accuracy (CV) = 0.9930
 - Best Parameters:
 - ('C', 13.7835)
 - ('gamma', 0.008914)




Figura 3.44. Optimización Bayesiana en el algoritmo SVC-StWe generador G2




Figura 3.45. Optimización Bayesiana en el algoritmo NSC-Nor generador G2




Figura 3.46. Optimización Bayesiana en el algoritmo RFC-Res generador G2

De acuerdo con los resultados de las Figuras 3.43-3.46, se identifica que la Optimización Bayesiana permite mejorar la métrica del *balanced_accuracy* descrita en la Tabla 3.5. De este modo, se optimiza el desempeño de los clasificadores considerados en este análisis.

El módulo *BayesSearchCV* de Python brinda la posibilidad de observar resultados adicionales del proceso de optimización a través de diferentes gráficas específicas. En este contexto, es posible observar los valores de los hiperparámetros que han sido probados en el análisis de optimización. De manera ilustrativa, la Figura 3.47 presenta la gráfica correspondiente para el caso de la Optimización Bayesiana en el algoritmo MLPC-Sta generador G2. En este caso se identifican las diferentes alternativas de hiperparámetros

que fueron consideradas y los correspondientes valores óptimos. De esta manera, es posible observar la localización más probable de los valores óptimos.

Por otro lado, existe la posibilidad de caracterizar la influencia de los diferentes hiperparámetros en la Función Sustituta de manera cuantitativa. Esto a través de una métrica denominada *dependencia parcial* (análoga al valor de una derivación parcial) [83]. En la Figura 3.48 se presenta el resultado correspondiente en el caso del clasificador MLPC-Sta.




Figura 3.47. Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

La diagonal de esta gráfica muestra la dependencia de un solo hiperparámetro sobre la función sustituta, mientras que las gráficas debajo de la diagonal muestran el efecto al variar dos hiperparámetros.

La dependencia parcial se calcula promediando el valor de la Función Sustituta de un número de muestras aleatorias en el espacio de búsqueda, mientras se mantienen fijos uno o dos hiperparámetros a intervalos regulares [63]. También, se muestran puntos en color negro para los valores específicos que se muestrearon durante la optimización y una estrella roja para el conjunto de hiperparámetros óptimos encontrados.

Cabe destacar que el mapa colorimétrico asociado proporciona indicios aproximados de la ubicación en donde existe mayor influencia de los hiperparámetros correspondientes. De esta manera, el análisis puede sugerir la omisión del proceso de optimización para ciertos hiperparámetros, cuya variación mantiene la misma dependencia en el modelo.

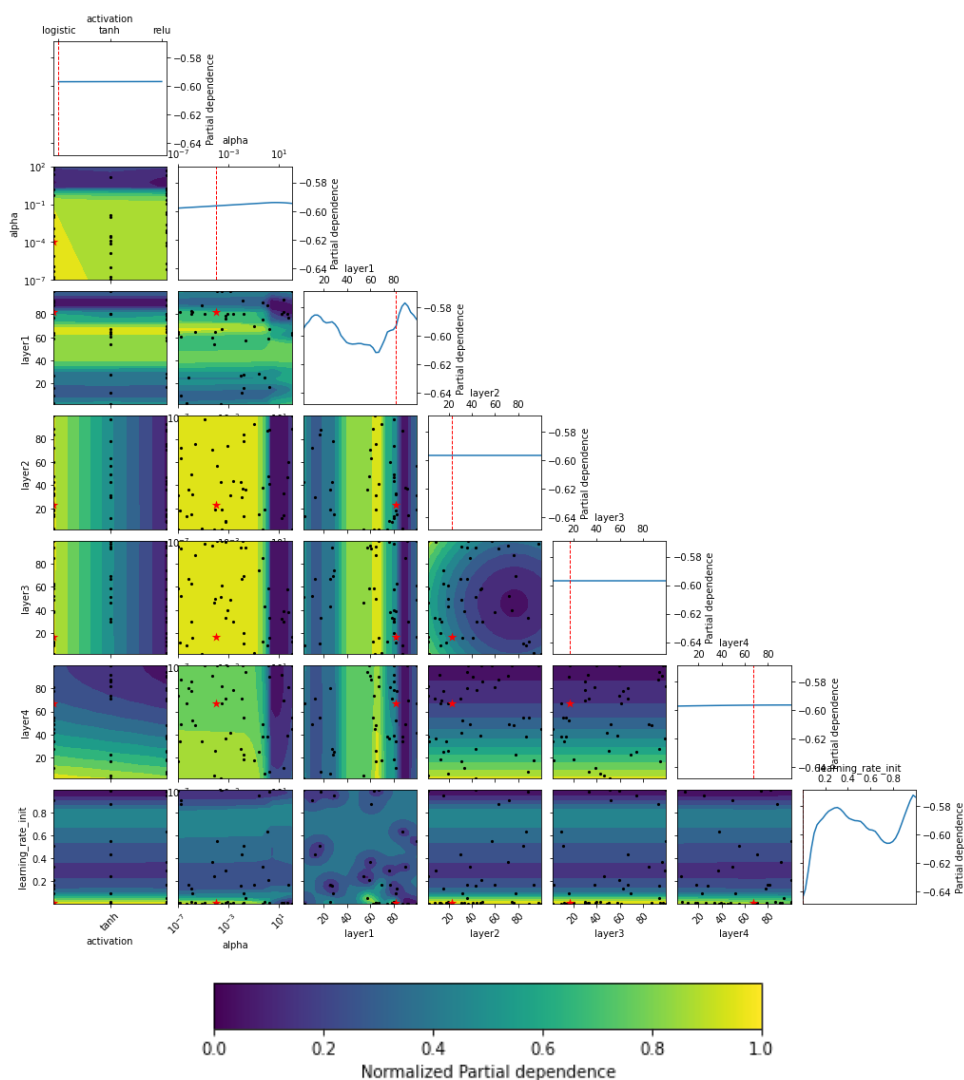


Figura 3.48. Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

Por otra parte, a través del módulo *permutation_importance* de Python es posible cuantificar la importancia o significancia de las diferentes características usadas en el entrenamiento. La significancia se define como el efecto de reducción de una métrica de desempeño (*balanced_accuracy*) frente a la variación aleatoria de una característica. De este modo, se estima cuál es la dependencia del modelo con respecto a esta característica.

En la Figura 3.49 se ilustra la significancia obtenida en el caso del clasificador MLPC-Sta. Se observa la predominancia de ciertas características en el modelo de aprendizaje. Este tipo de resultado puede orientar hacia la simplificación del proceso de entrenamiento seleccionando solo aquellas características predominantes. Esto de manera análoga a una etapa de selección de características.




Figura 3.49. Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

A continuación, en la Tabla 3.7 se presenta un compendio de los resultados obtenidos. Se considerarán, para la selección del algoritmo más adecuado, los resultados del Balanced Accuracy del modelo final entrenado con hiperparámetros óptimos, es decir, las estimaciones CV.

Como se observa en los valores presentados, la mejor opción es el algoritmo SVC-StWe en todos los casos, debido a que proporciona la métrica más elevada. Además, con relación al tipo de EOF utilizada, se tiene que, para el generador G2, la mejor opción es el uso combinado de EOF scores del LLE y del ángulo del rotor; mientras que para los otros casos se tiene que la mejor opción es el uso de las EOF scores del ángulo del rotor.

Tabla 3.7. Compendio de Resultados de Optimización Bayesiana de hiperparámetros

Enfoque	Algoritmo optimizado	Tipo de EOF usada	Balanced accuracy		
			Training CV	Testing	CV
G2	MLPC-Sta	LLE+Ang	0.8812	0.9600	0.9020
	SVC-StWe	LLE+Ang	0.9923	0.9935	0.9930
	NSC-Nor	Ang	0.9520	0.9527	0.9520
	RFC-Res	LLE+Ang	0.7155	0.8375	0.8086
G3	MLPC-Res	LLE+Ang	0.8071	0.8135	0.8280
	SVC-StWe	Ang	0.9680	0.9029	0.9625
	NSC-Nor	Ang	0.9337	0.9057	0.9304
	RFC-Res	LLE+Ang	0.8955	0.7976	0.8806
Global	MLPC-Res	LLE+Ang	0.9625	0.9620	0.9230
	SVC-StWe	Ang	0.9977	0.9613	0.9923
	NSC-Nor	Ang	0.9657	0.9690	0.9697
	RFC-Res	LLE	0.8920	0.8763	0.8247

3.9. Resumen de la metodología

El resumen de la metodología propuesta en este trabajo, segmentada en las seis etapas antes descritas, se esquematiza a partir de la Figura 3.50.

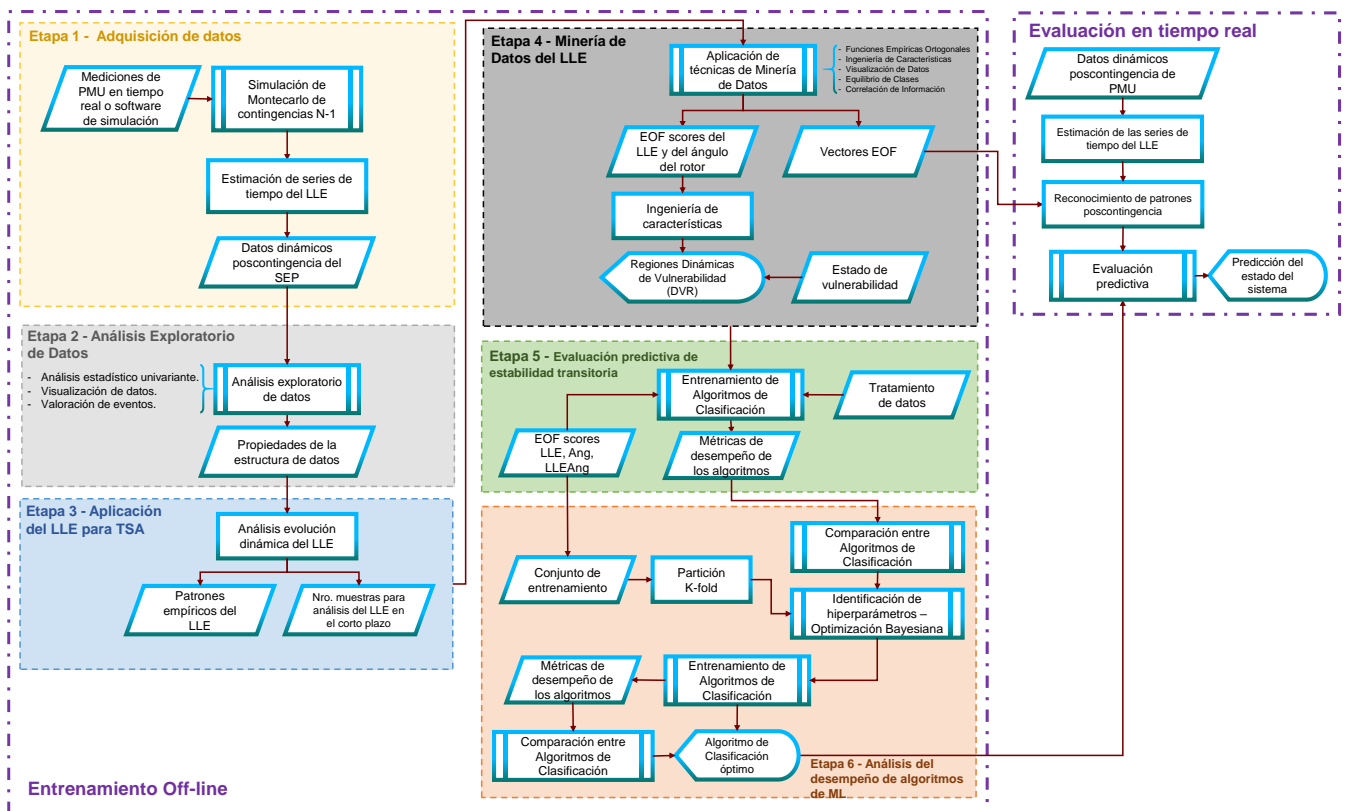


Figura 3.50. Flujograma de la Metodología de Evaluación Predictiva de Estabilidad Transitoria

Finalmente, se debe mencionar que el procedimiento de evaluación en tiempo real es relativamente sencillo. Básicamente, se consideran los datos dinámicos poscontingencia del ángulo del rotor provenientes de las PMU y luego se estiman las series de tiempo del LLE correspondientes. Una serie del LLE, de dimensión $1 \times p$ se multiplica por la matriz de

vectores EOF de dimensión $p \times p$ (identificada en la etapa 4). Es así como se obtiene una matriz de EOF scores de $1 \times p$, con la cual se sigue el mismo procedimiento de la etapa 5 para predecir el estatus de vulnerabilidad utilizando el algoritmo de clasificación que haya sido seleccionado como el más adecuado.

4. RESULTADOS Y DISCUSIÓN

El sistema de prueba utilizado para la aplicación de la metodología propuesta en este trabajo es el IEEE 39-Bus System, cuyos datos se encuentran en el ANEXO B. En este sistema se considera una modificación que consiste en la adición de un circuito paralelo a la línea de transmisión “Line 16-19”. Esto con el fin de satisfacer el criterio N-1 en el conjunto de simulaciones. En la Figura 4.1 se presenta el diagrama del sistema de prueba.

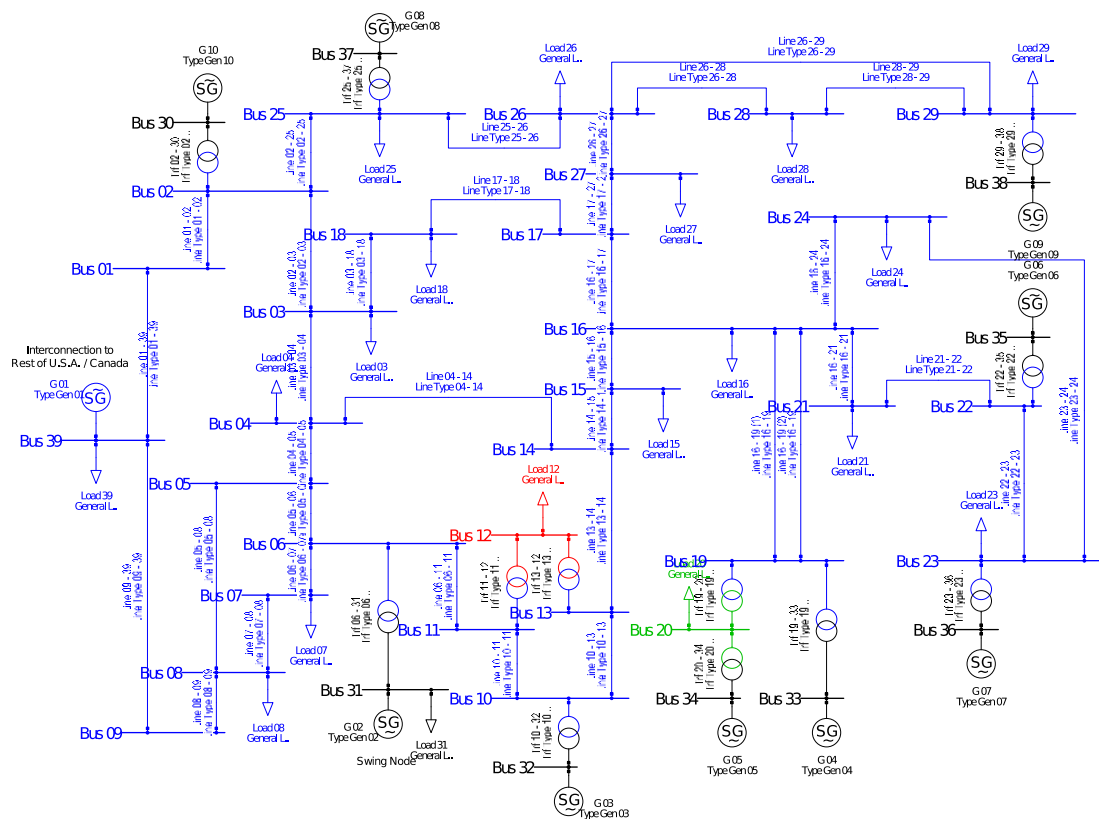



Figura 4.1. Sistema de Prueba IEEE 39-Bus System modificado

Con relación a la etapa de generación y adquisición de datos, se toman en cuenta consideraciones similares a las asumidas para el sistema IEEE 9-Bus System. Por ejemplo, se asume una frecuencia de muestreo de las unidades PMU de 120 Hz. Además, se considera un número de 20000 simulaciones de Montecarlo con las mismas condiciones experimentales de variabilidad detalladas en la Tabla 3.1.

En este caso, se calculó el error relativo de Montecarlo en cada variable de salida que se obtiene con 20000 simulaciones. El resultado correspondiente se presenta en la Figura 4.2, en donde se identifican errores menores a 0.05 para las variables LLE y Time_Ost. Por lo

tanto, la cantidad de 20000 simulaciones en el sistema IEEE 9-Bus System es suficiente para el desarrollo del presente análisis.



- ✓ Gen i-Ang: Angulo del rotor del generador "Gen i".
- ✓ Gen i-LLE: Valor del LLE para el generador "Gen i".
- ✓ Gen i-OOS: Índice de pérdida de sincronismo del generador "Gen i".
- ✓ Gen i-Time_Ost: Tiempo de operación de la protección OSR del generador "Gen i".

Figura 4.2. Error relativo obtenido en la ejecución de 20000 simulaciones de Montecarlo en el sistema de prueba IEEE 39-Bus System

4.1. Análisis Exploratorio de Datos

En esta subsección se expone el Análisis Exploratorio de los datos de las simulaciones de Montecarlo en el sistema IEEE 39-Bus System. En primer lugar, en la Tabla 4.1 y Tabla 4.2 se presenta un resumen de estadística univariante del conjunto de 20000 simulaciones.

Tabla 4.1. Estadística univariante de variables Ang y LLE de simulaciones de Montecarlo en el sistema de prueba IEEE 39-Bus System

	G 01- Ang	G 02- Ang	G 03- Ang	G 04- Ang	G 05- Ang	G 06- Ang	G 07- Ang	G 08- Ang	G 09- Ang	G 10- Ang	G 01- LLE	G 02- LLE	G 03- LLE	G 04- LLE	G 05- LLE	G 06- LLE	G 07- LLE	G 08- LLE	G 09- LLE	G 10- LLE
Mean	-55.00	-39.72	-33.26	63.08	59.79	457.57	448.64	-24.18	5.33	-19.63	-0.33	-0.21	-0.23	-0.22	-0.24	-0.30	-0.28	-0.15	-0.25	-0.30
Median	-14.14	2.00	8.06	31.78	27.82	42.11	34.41	14.76	31.13	10.34	-0.33	-0.22	-0.24	-0.26	-0.27	-0.31	-0.32	-0.16	-0.27	-0.37
Std. Dev.	190.83	194.66	194.78	608.70	609.44	1949.3	1945.2	222.82	266.34	260.11	0.31	0.35	0.38	0.33	0.33	0.36	0.33	0.34	0.34	0.41
Variance	36418	37891	37940	370510	371413	3799654	3783639	49647	70934	67660	0.10	0.13	0.15	0.11	0.11	0.11	0.13	0.11	0.12	0.16
Coef. Var.	3.47	4.90	5.86	9.65	10.19	4.26	4.34	9.22	49.98	13.25	0.97	1.66	1.70	1.47	1.35	1.10	1.28	2.19	1.40	1.37
Skewness	-4.70	-4.43	-4.42	8.98	8.98	4.66	4.70	3.85	-1.97	11.99	0.32	0.24	0.36	0.38	0.48	0.53	0.71	0.10	0.26	0.99
Kurtosis	25.02	25.56	25.55	92.91	92.86	23.44	23.83	191.04	31.99	452.06	4.36	3.77	3.59	4.01	4.43	4.63	4.32	3.95	3.71	4.78

Tabla 4.2. Estadística univariante de variables OOS y Time_Ost de simulaciones de Montecarlo en el sistema de prueba IEEE 39-Bus System

	G 01- OOS	G 02- OOS	G 03- OOS	G 04- OOS	G 05- OOS	G 06- OOS	G 07- OOS	G 08- OOS	G 09- OOS	G 10- OOS	G 01- Time_ Ost	G 02- Time_ Ost	G 03- Time_ Ost	G 04- Time_ Ost	G 05- Time_ Ost	G 06- Time_ Ost	G 07- Time_ Ost	G 08- Time_ Ost	G 09- Time_ Ost	G 10- Time_ Ost
Mean	0	0	0	0.01	0.01	0.04	0.04	0	0.02	0	--	--	--	0.96	0.90	0.84	0.86	--	0.78	--
Median	0	0	0	0.00	0.00	0.00	0.00	0	0.00	0	--	--	--	0.88	0.85	0.78	0.80	--	0.74	--
Std. Dev.	0	0	0	0.08	0.07	0.21	0.20	0	0.14	0	--	--	--	0.33	0.30	0.24	0.28	--	0.20	--
Variance	0	0	0	0.01	0.01	0.04	0.04	0	0.02	0	--	--	--	0.11	0.09	0.06	0.08	--	0.04	--
Coef. Var.	--	--	--	11.78	13.97	4.62	4.91	--	6.84	--	--	--	--	0.35	0.33	0.29	0.33	--	0.26	--
Skewness	0	0	0	11.70	13.90	4.41	4.70	0	6.69	0	--	--	--	2.45	3.65	2.39	5.02	--	1.09	--
Kurtosis	0	0	0	137.87	194.08	20.42	23.14	0	45.75	0	--	--	--	10.93	19.27	12.79	58.45	--	4.55	--

Se tienen los siguientes hallazgos de este resultado estadístico:

- El conjunto de generadores {G 01, G 02, G 03, G 08, G 10} no pierde estabilidad en ninguna de las simulaciones. De esta manera, estas unidades constituyen un conjunto de generadores no críticos en el sistema. Por otro lado, el conjunto de generadores {G 04, G 05, G 06, G 07, G 09} se encuentra involucrado en los eventos de inestabilidad del sistema; por tal motivo, estos generadores serán considerados en los análisis correspondientes del LLE.
- A partir del análisis entre el valor medio y la mediana, se tiene que, en ciertos casos, por ejemplo: en el valor del ángulo del rotor, ambos estadísticos difieren considerablemente, lo que sugiere la posible presencia de datos atípicos o más de una distribución de datos inmersa. Esto como resultado de que se están incluyendo casos estables e inestables en el conjunto analizado.
- Una media de valores negativos en el LLE sugiere que gran parte de los eventos simulados corresponden a eventos estables (el LLE en estado estacionario tiende a valores negativos para un evento estable).
- Con respecto a los coeficientes de variación, se tiene que unos cuantos presentan valores elevados, siendo los mayores aquellos correspondientes a las variables angulares Ang y la variable OOS.
- A partir de los valores de asimetría, es posible evidenciar que se tienen altas asimetrías en los datos (distribuciones claramente asimétricas), en especial en las variables de ángulo y LLE, producto de una tendencia establecida por las condiciones de inestabilidad y estabilidad del sistema. En las variables LLE y OOS se observan coeficientes de asimetría positivos, lo que refleja la presencia de distribuciones con una cola hacia la derecha. Esto es una muestra de que la mayoría de los eventos en el conjunto de datos son estables, porque la mayor concentración de datos se ubica hacia la izquierda de la distribución.

- En los resultados de Kurtosis se aprecian valores elevados en el LLE, lo que sugiere baja homogeneidad (disimilitud con respecto a una distribución normal) que puede relacionarse con dos distribuciones que componen el conjunto total de datos (eventos estables e inestables).

Con relación a la valoración de eventos estables e inestables, en la Figura 4.3 se observa la cantidad de eventos de cada clase obtenida de las simulaciones de Montecarlo. Se aprecia que el número de eventos inestables constituye un porcentaje reducido, menor al 5% del total de simulaciones. Además, se observan los generadores que constituyen conjuntos críticos y no críticos en el sistema desde la perspectiva de Estabilidad Transitoria.




Figura 4.3. Valoración de eventos de simulación en el sistema IEEE 39-Bus System

En relación con el resultado de las variables de ángulo del rotor, LLE y el índice de pérdida de sincronismo, alcanzados a $t = 5 s$, en la Figura 4.4 se visualizan histogramas de los datos generados para el caso de eventos estables. En este caso se aprecia que el signo del LLE no ostenta un valor negativo para todos estos eventos. Esto como consecuencia de que el LLE no se estabiliza o converge en los valores finales correspondientes. Por otro lado, se aprecia que los valores que toma el ángulo del rotor no se incrementan indefinidamente, como consecuencia de una dinámica estable del sistema.

Adicionalmente, en la Figura 4.5 se visualizan los histogramas concernientes a eventos inestables. En relación con el índice de pérdida de sincronismo (variable Out of Step) se aprecia que la pérdida de estabilidad no es simultánea en todos los casos para los generadores, es decir, que existen eventos en los que solo ciertas máquinas pierden estabilidad. Además, como ocurre para eventos estables, se observa que en las simulaciones de eventos inestables el LLE varía entre valores negativos y positivos. Esto denota el hecho de que el LLE no converge hacia valores consistentes con la condición de estabilidad o inestabilidad correspondiente. Asimismo, se observa que los ángulos del rotor ostentan magnitudes excesivas, producto de condiciones inestables del SEP.

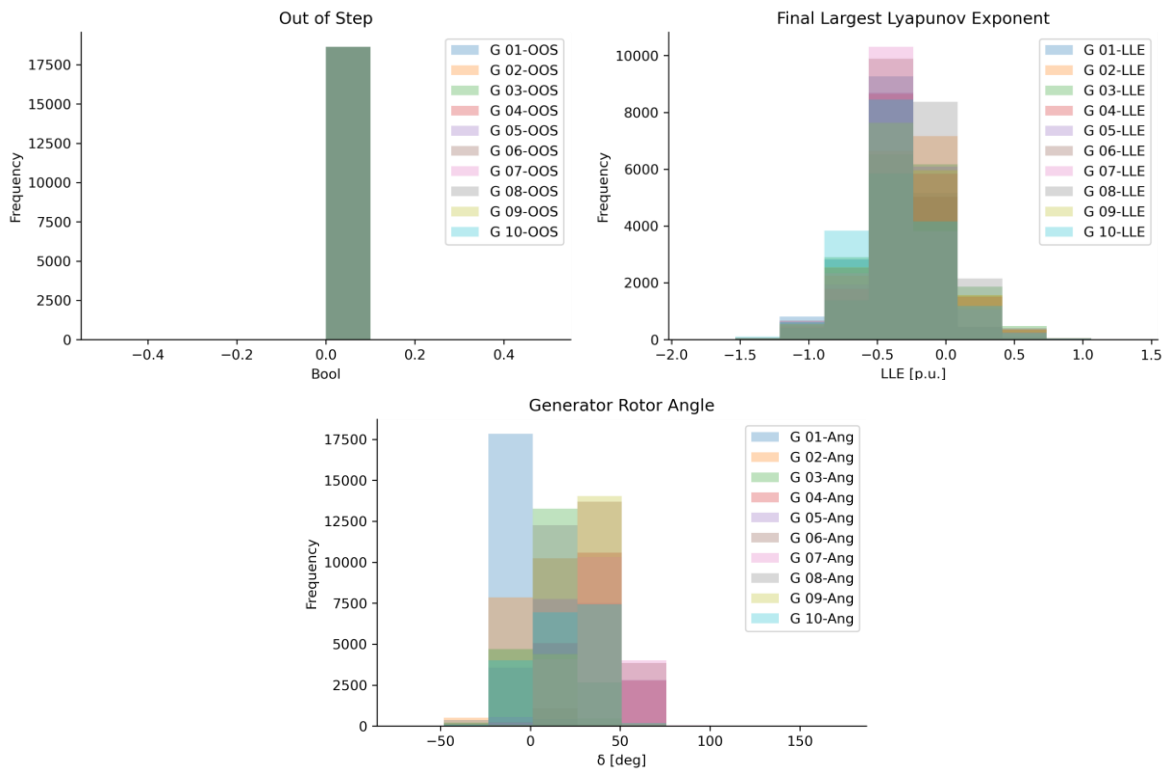


Figura 4.4. Histogramas para eventos estables en el sistema IEEE 39-Bus System

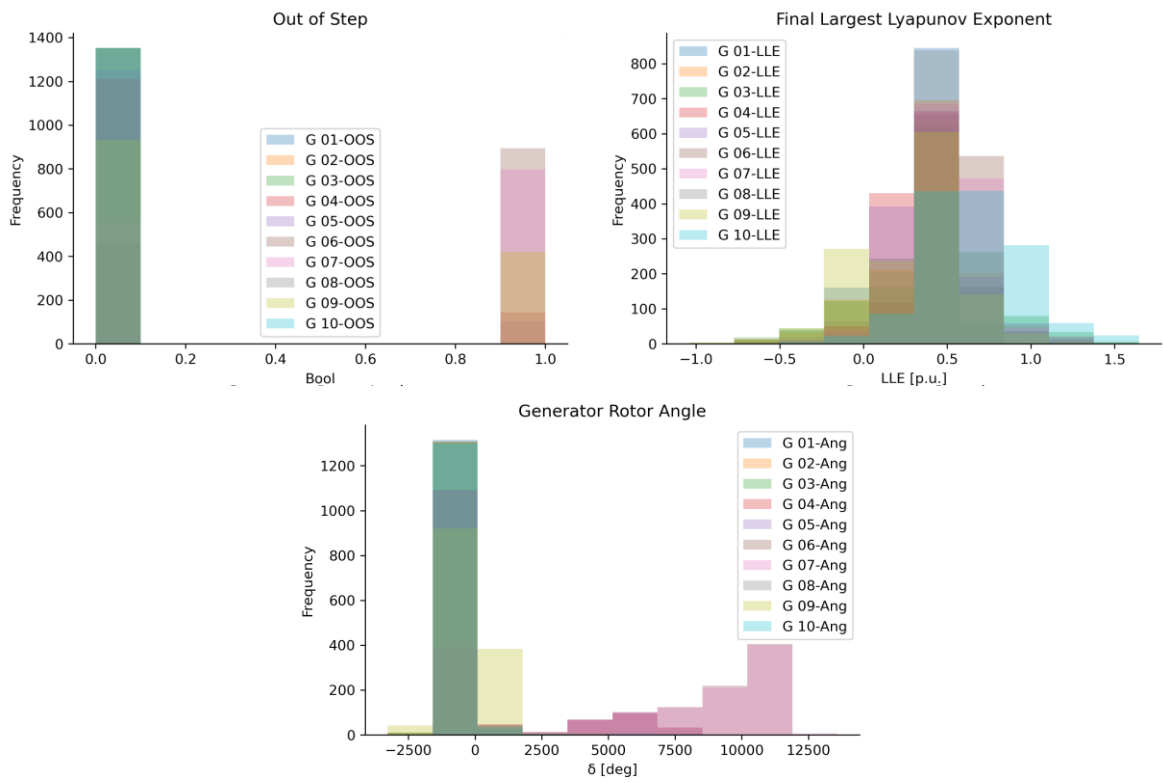


Figura 4.5. Histogramas para eventos inestables en el sistema IEEE 39-Bus System

Finalmente, se plantea la visualización de la dispersión de valores del LLE en cada generador. Esto con la finalidad de identificar posibles relaciones del indicador entre generadores. Para este caso, en la Figura 4.6 se presenta la matriz de dispersión correspondiente. Se evidencia que los eventos inestables, luego de 5 segundos, tienden a ubicarse hacia una región diferente que los eventos estables, específicamente, en donde los valores del LLE son positivos. No obstante, existe un alto grado de solapamiento y excepcionalmente eventos en donde no se cumple con la característica de que el LLE es negativo para eventos estables y positivo para eventos inestables. Todo esto como un resultado de que el LLE no converge de forma temprana.




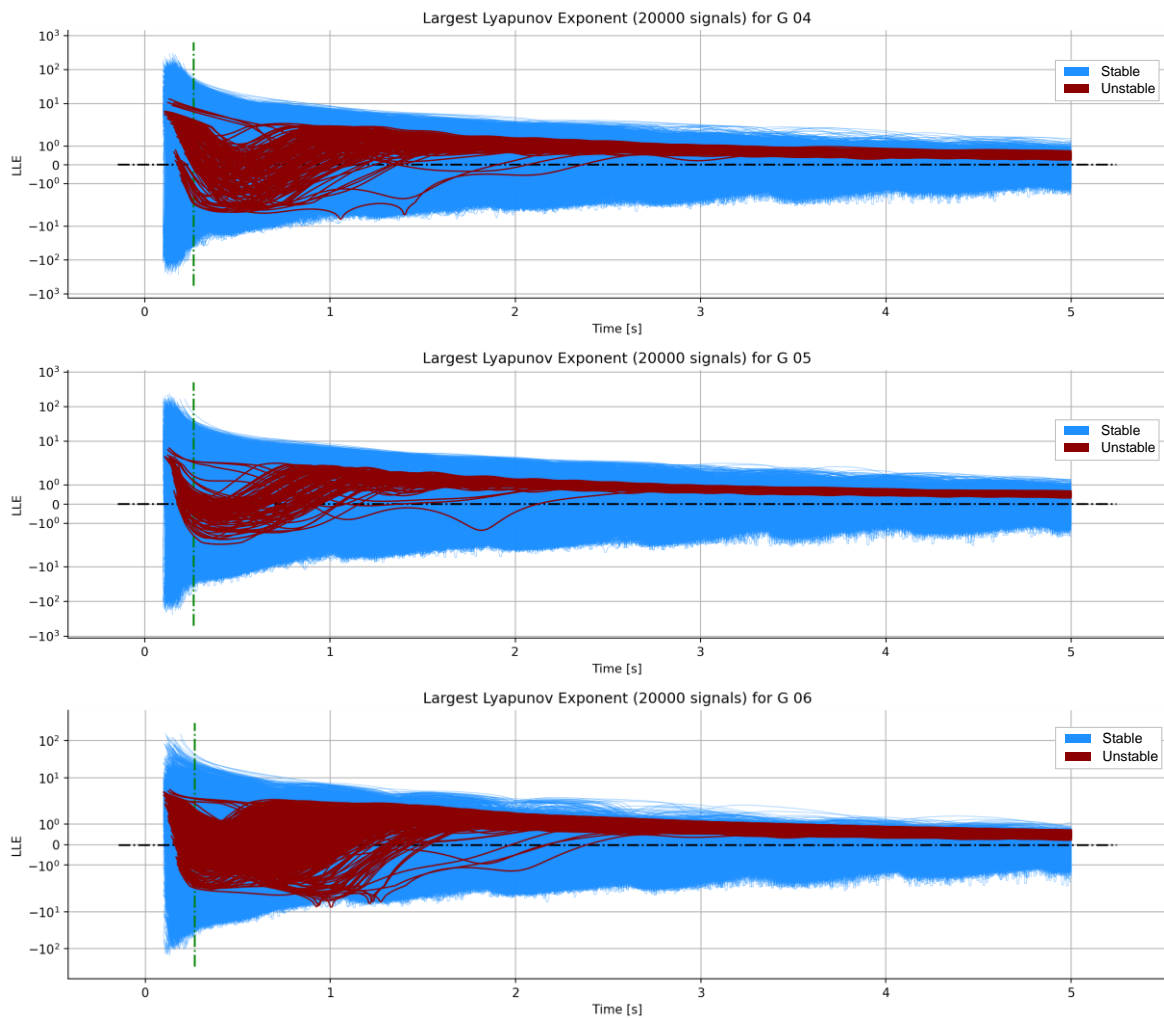
Figura 4.6. Matriz de dispersión del LLE en el sistema IEEE 39-Bus System

4.2. Aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria

4.2.1. Evolución dinámica del LLE

En la Figura 4.7 se presenta el comportamiento de la evolución dinámica del LLE. Se observa que la dinámica inicial presenta fluctuaciones que impiden determinar de manera pronta el signo final del LLE. Generalmente, se encuentra en el comportamiento variable del signo del LLE, que se requiere de tiempos extensos para que el LLE se estabilice en el valor correcto.

Además, una perspectiva visual del comportamiento de las series de tiempo de LLE evidencia el alto grado de solapamiento entre casos estables e inestables.







Figura 4.7. Evolución dinámica del LLE para el conjunto de generadores críticos {G 04, G 05, G 06, G 07, G 09}

Por otro lado, en la Figura 4.8 se observan los histogramas formados a partir de los valores finales del LLE. En este resultado se observan ciertas propiedades de precisión del LLE para describir la estabilidad del sistema transcurridos 5 segundos. Se obtiene que en los generadores {G 04, G 05, G 06, G 07} el LLE de todos los eventos inestables presenta un signo positivo. No obstante, en el caso del generador G 09, y para los eventos estables en todos los generadores, el LLE no presenta un signo consistente.






Figura 4.8. Histogramas del valor del LLE alcanzado a $t = 5$ seg., para los generadores críticos {G 04, G 05, G 06, G 07, G 09}.

De este modo, se encuentra que la simple observación del LLE no constituye una vía válida para la evaluación de la Estabilidad Transitoria con criterios de precisión y rapidez.

4.2.2. Número de muestras de análisis del LLE

Con los datos obtenidos de las simulaciones de Montecarlo para el sistema de prueba IEEE 39-Bus System, se presenta en la Figura 4.9 la variabilidad existente entre los tiempos de despeje de las fallas y los tiempos asociados con el disparo de unidades de generación (inicio de eventos en cascada). Con base en esta información, se tiene la estadística de tiempos de los eventos que se expone en la Tabla 4.3.




Figura 4.9. Histogramas de tiempos de eventos de contingencias en el sistema IEEE 39-Bus System

Tabla 4.3. Resumen estadístico de tiempo de eventos de contingencias en el sistema IEEE 39-Bus System

Variable temporal	Tiempo (ms)
$t_{clear} - \text{mean}$	106.4
$t_{clear} - \text{min}$	64.0
$t_{clear} - \text{max}$	214.9
$t_{\min Out st}$	G 04: 533.3
	G 05: 550.0
	G 06: 483.3
	G 07: 475.0
	G 09: 425.0
$t_{\min Out st} - \text{mean}$	493.3
$t_{\max} \leq$	276.3
$TW \leq$	170.0

De acuerdo con los resultados mostrados en la Tabla 4.3, y considerando las ventanas de tiempo admisibles para una frecuencia de muestreo de 120 Hz, se selecciona por aproximación una ventana de tiempo de análisis de $TW = 150 \text{ ms}$, equivalente a un número de muestras $TW_{samples} = \left(1 + \frac{0.150 \text{ s}}{\frac{1}{120} \text{ s}}\right) = 19$. Considerando la expresión 3.1, el número de muestras del LLE requerido para el análisis es:

$$n_{LLE} = TW_{samples} - (2N + 1 - shrink) = 19 - (2 \cdot 2 + 1 - 1) = 15$$

Con base en la estadística de tiempos mostrada, se justifica que el uso de 15 muestras del LLE proporciona tiempos medios de predicción que permiten el desarrollo de acciones de control oportunas en el WAMPAC. Con la información de los tiempos de disparo de las unidades de generación, es posible analizar estadísticamente los tiempos disponibles para el desarrollo de acciones de control, lo cual se expone en la Figura 4.10.




Figura 4.10. Resumen estadístico de tiempo de disponibilidad en el sistema IEEE 39-Bus System

En general, los tiempos de disponibilidad resultantes confirman la posibilidad de llevar a cabo acciones de control correctivas previas a la actuación de una protección local. Esto

considerando que estos tiempos son considerablemente superiores que los retardos asociados al sistema WAMPAC. Por lo tanto, se justifica como la evaluación de Estabilidad Transitoria en tiempo real propuesta es capaz de alertar sobre la necesidad de acciones de control globales antes del comienzo de un evento en cascada.

4.2.3. Análisis del LLE en el sistema IEEE 39-Bus System

En este apartado se estudian los resultados obtenidos con las 15 primeras muestras del LLE para las 20000 simulaciones de Montecarlo desarrolladas en este sistema. En las Figuras 4.11-4.15 se presenta la evolución del LLE para esta ventana de tiempo de análisis y la cuantificación de las medidas de dispersión: rango y varianza para la magnitud del LLE.

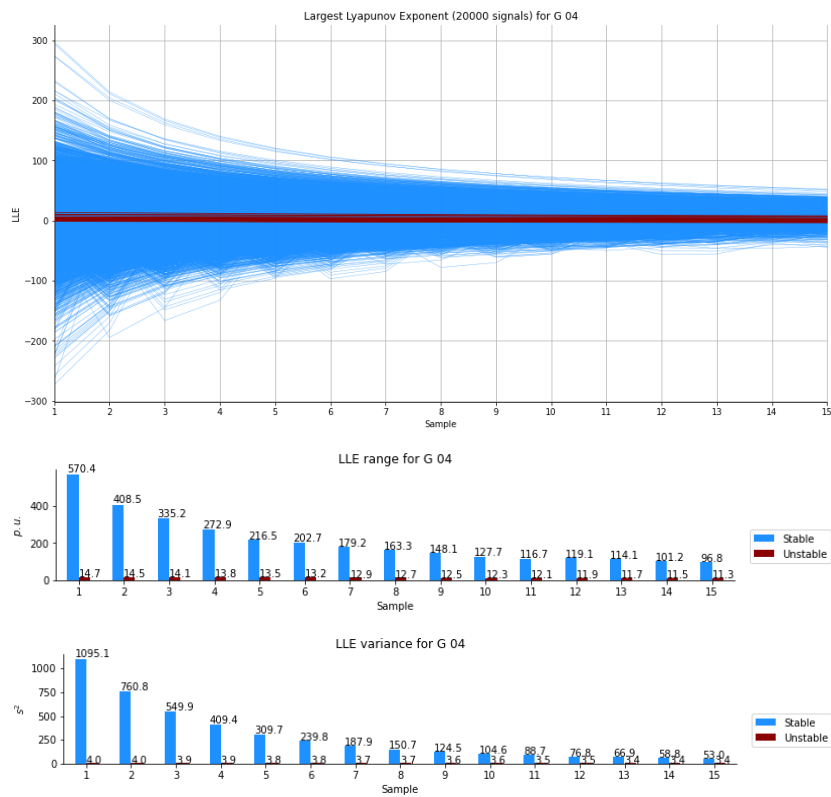


Figura 4.11. Dinámica del LLE en una ventana de observación reducida en G 04

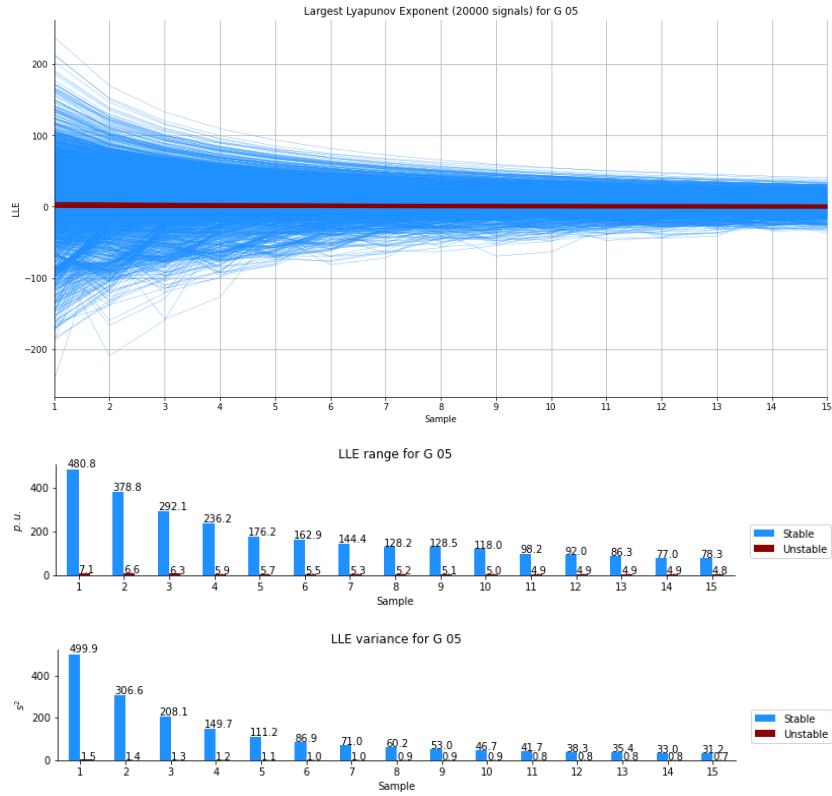


Figura 4.12. Dinámica del LLE en una ventana de observación reducida en G 05

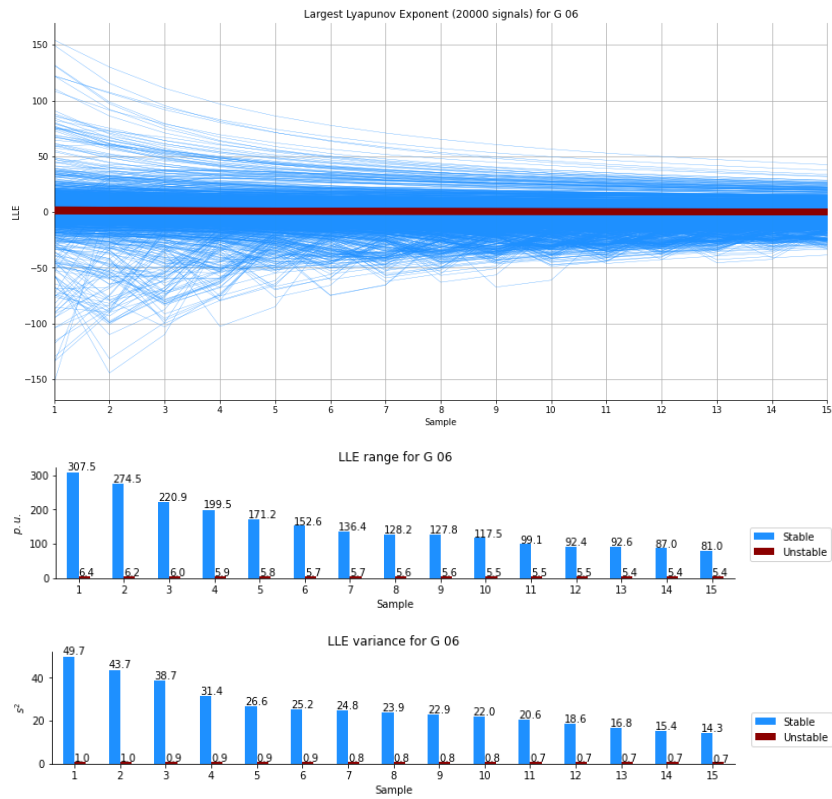


Figura 4.13. Dinámica del LLE en una ventana de observación reducida en G 06

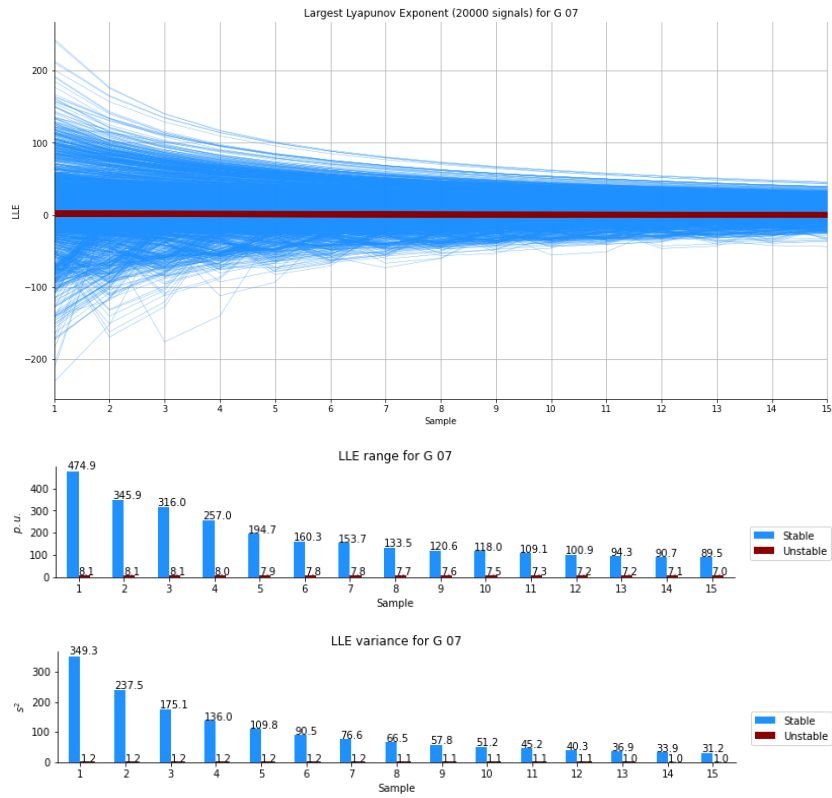


Figura 4.14. Dinámica del LLE en una ventana de observación reducida en G 07

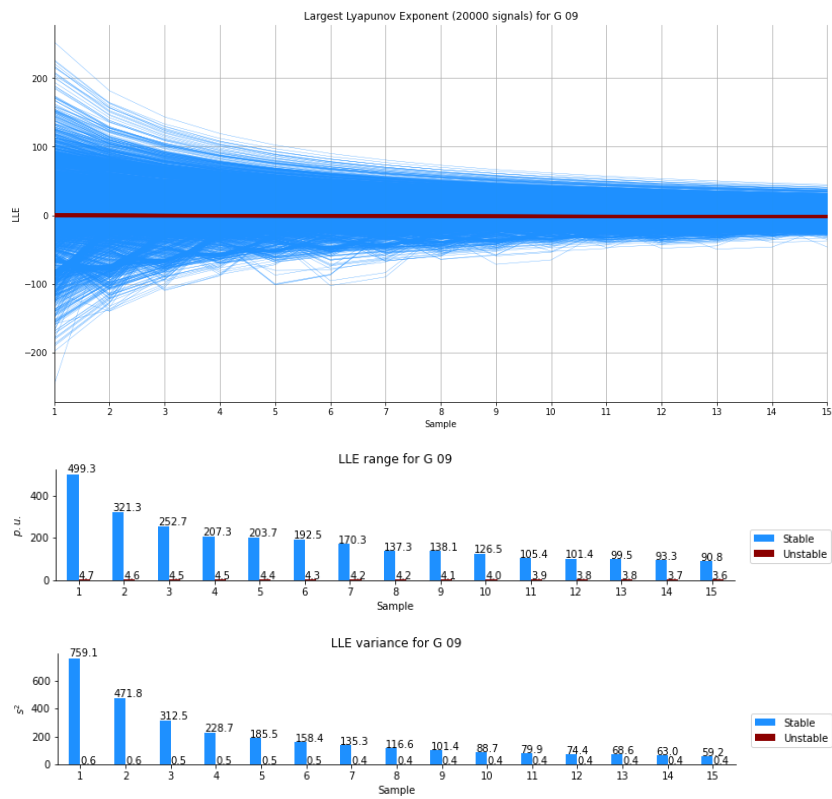


Figura 4.15. Dinámica del LLE en una ventana de observación reducida en G 09

En la información mostrada se observa que la magnitud del LLE obtenida para eventos inestables es menor en comparación con las magnitudes que puede alcanzar el LLE para eventos estables. En este sentido, el LLE correspondiente a eventos inestables ocupa un espacio vectorial más reducido.

Además, se evidencia que la dispersión del LLE de eventos inestables es muy baja en comparación con la dispersión del LLE de eventos estables. El rango de magnitudes del LLE en eventos inestables alcanza valores menores a 14.7 p.u., mientras que el rango de eventos estables alcanza valores hasta de 570.4 p.u. Por otro lado, se aprecia que la varianza del LLE de eventos inestables es en la mayoría de los casos menor que el 1% de la varianza del LLE de eventos estables.

Se debe notar también que existe un alto grado de solapamiento entre los eventos estables e inestables, el cual impide una mejor discriminación entre el LLE obtenido para estos dos tipos de eventos.

4.3. Minería de Datos

En este apartado se presentan los principales resultados de la aplicación de Minería de Datos en el LLE. Esto con la finalidad de identificar reglas o patrones embebidos en el LLE. Las técnicas de Minería de Datos también fueron aplicadas para las señales del ángulo del rotor de los generadores. En el ANEXO F se presentan estos resultados complementarios.

4.3.1. Funciones Empíricas Ortogonales

En la Figura 4.16 se observan las EOF obtenidas de las series de tiempo del LLE de las 20000 simulaciones de Montecarlo del sistema IEEE 39-Bus System. El análisis proporciona 15 vectores EOF que son capaces de reconstruir cualquier señal del LLE del conjunto simulado. Se destaca que las primeras EOF poseen una dinámica más simple que las EOF de orden superior. Es así como en las primeras EOF se concentra la forma básica o esencial de las series de tiempo del LLE.

Asimismo, a partir del presente análisis, en la Figura 4.17 se ilustran las DVR formadas por el espacio vectorial de las EOF scores: {EOF1, EOF2, EOF3} para el conjunto de generadores críticos. En este resultado se aprecia que los eventos inestables ocupan una región altamente concentrada del espacio vectorial indicado. Además, se identifica que los eventos inestables se encuentran localizados en una región cercana al origen.

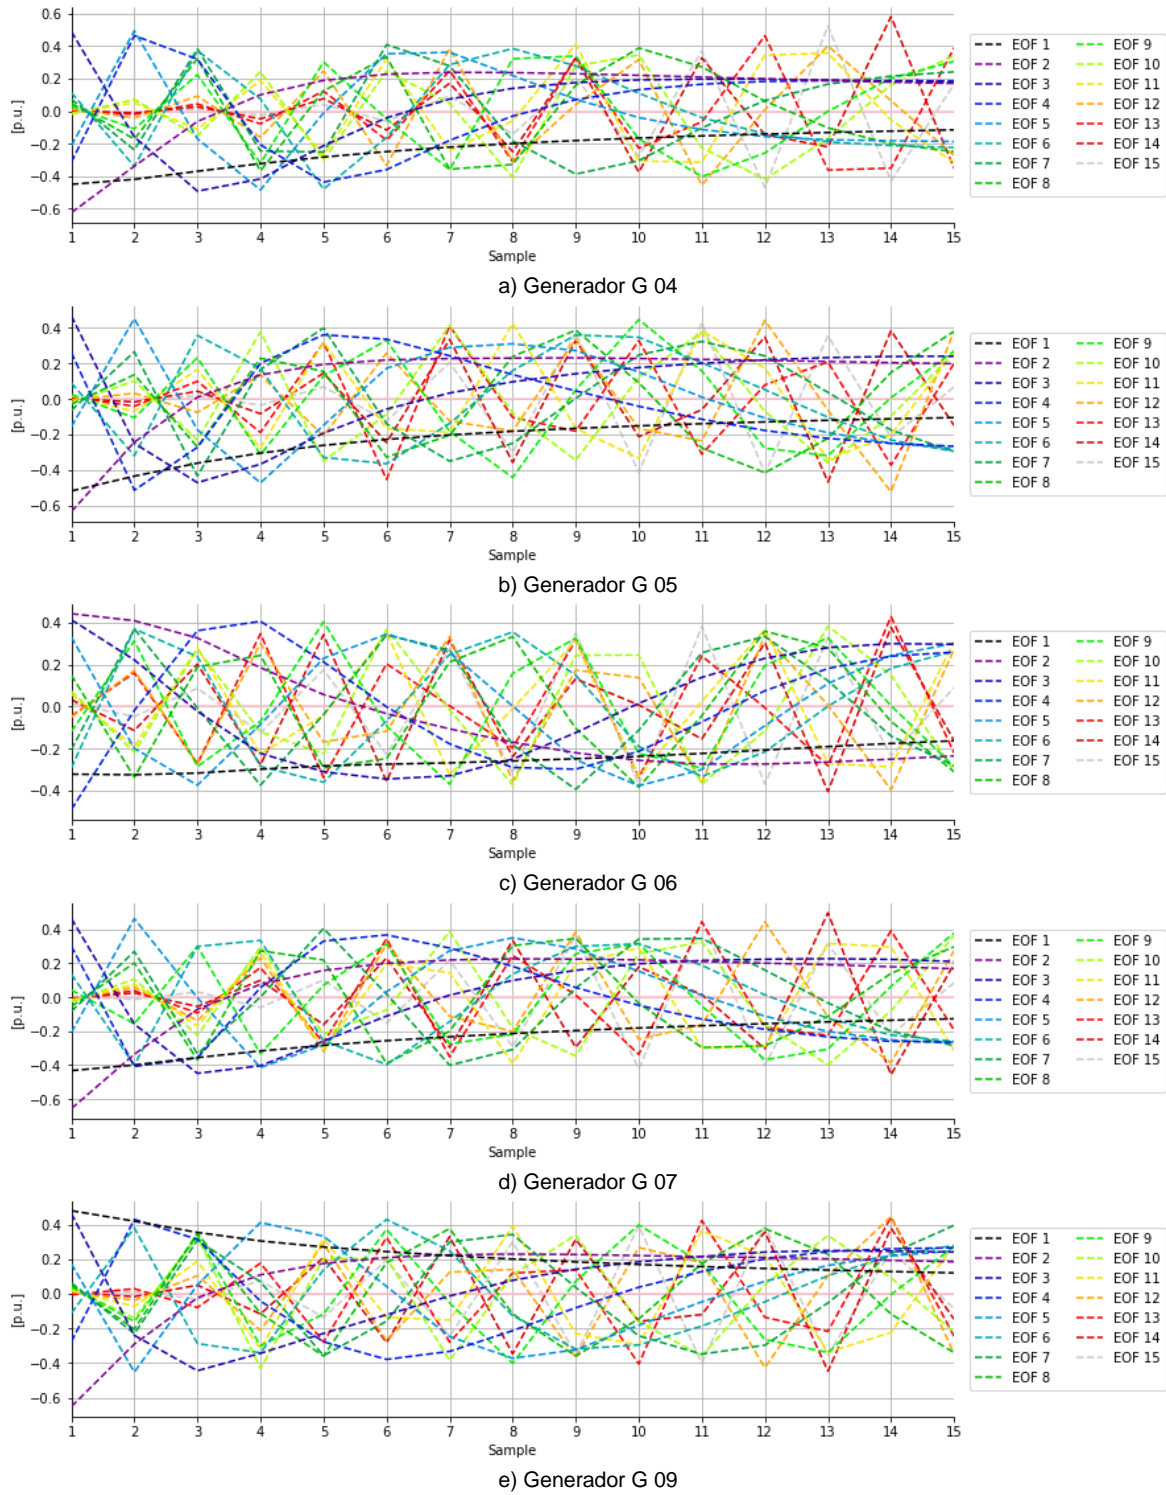


Figura 4.16. Funciones Empíricas Ortogonales de las series de tiempo del LLE

Adicionalmente, se evidencia la presencia de solapamiento y una frontera ligeramente ambigua entre eventos estables e inestables.

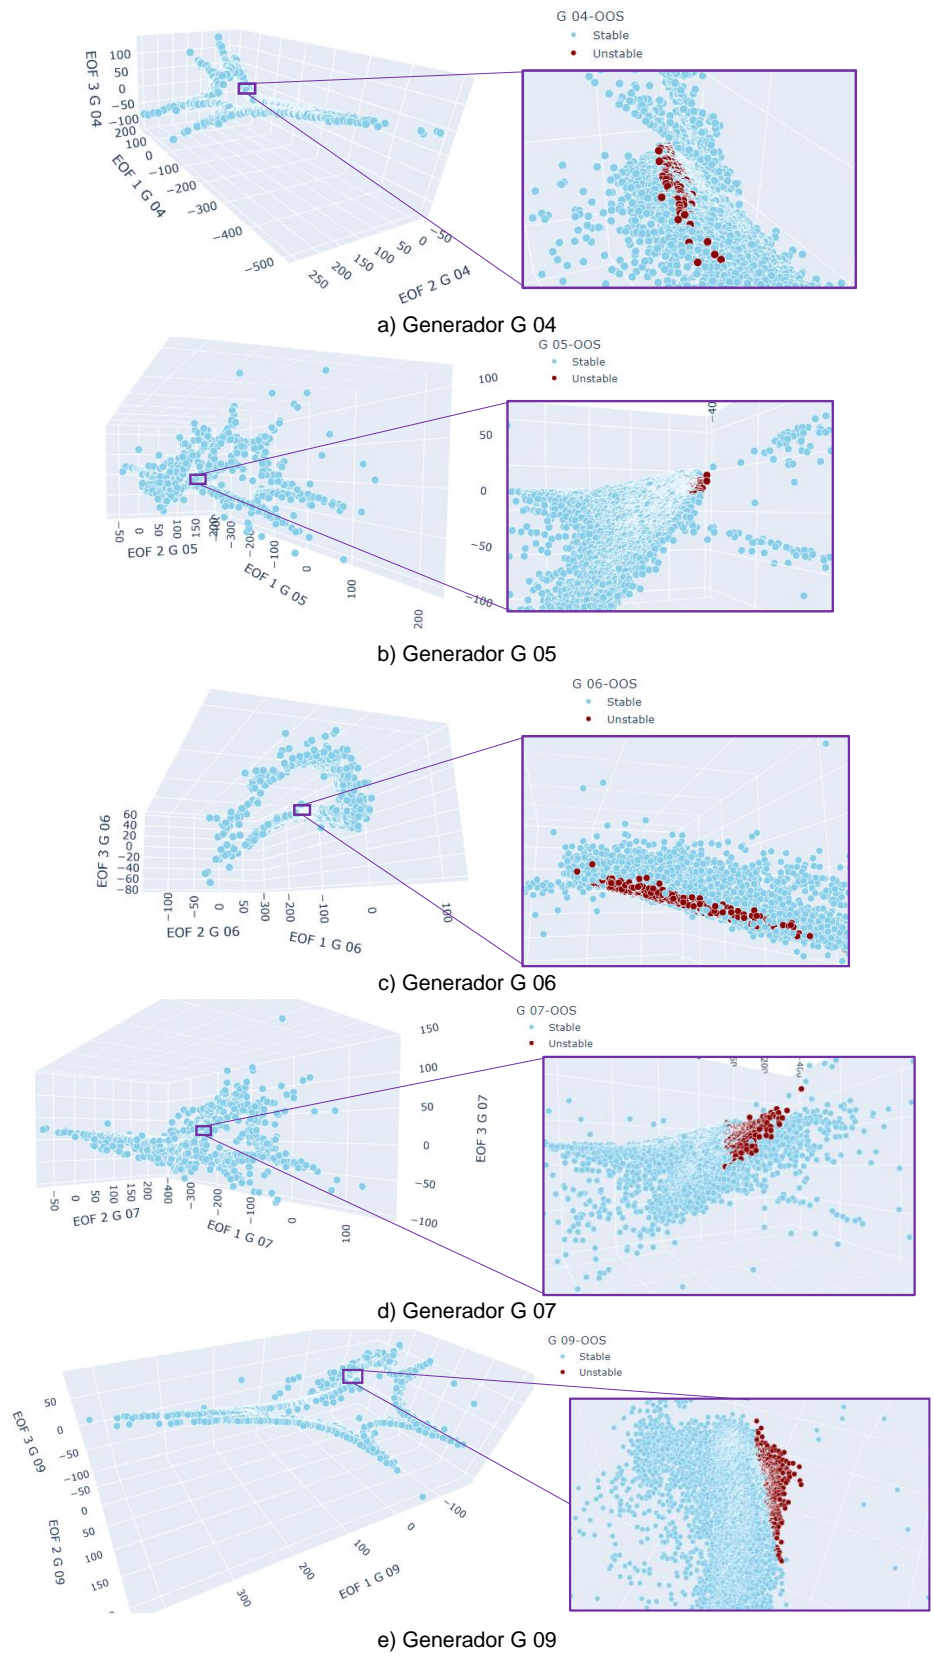


Figura 4.17. Representación tridimensional de las DVR formadas con el espacio vectorial $\{EOF1, EOF2, EOF3\}$ para generadores críticos

4.3.2. Ingeniería de Características

En la Figura 4.18 se ilustra la variabilidad explicada de las 15 EOF obtenidas para el conjunto de generadores críticos. En el diagrama de codo mostrado se identifica que el punto de inflexión del codo de la curva se forma con alrededor de 3 a 5 EOF. En este sentido, el análisis gráfico sugiere el uso de al menos 5 EOF. Se considerará, con la finalidad de mantener una mayor precisión en los resultados, el uso de las 6 primeras EOF. Se observa que las 6 primeras EOF permiten alcanzar una variabilidad superior al 85%.




Figura 4.18. Variabilidad Explicada de las EOF para el conjunto de generadores críticos

4.3.3. Visualización de Datos

4.3.3.1. Visualización de Coordenadas Paralelas

En la Figura 4.19 se presenta la ilustración de las coordenadas paralelas de las EOF scores obtenidas para el conjunto de generadores críticos. Un aspecto que destaca en este resultado es que las EOF scores de eventos inestables se concentran en una región reducida del espacio vectorial, lo cual se relaciona con las estimaciones previas de dispersión (rango y varianza) del LLE. Además, se observa que esta concentración se encuentra cercana al origen del espacio vectorial, lo cual constituye una regularidad adicional en la magnitud del LLE de eventos inestables.

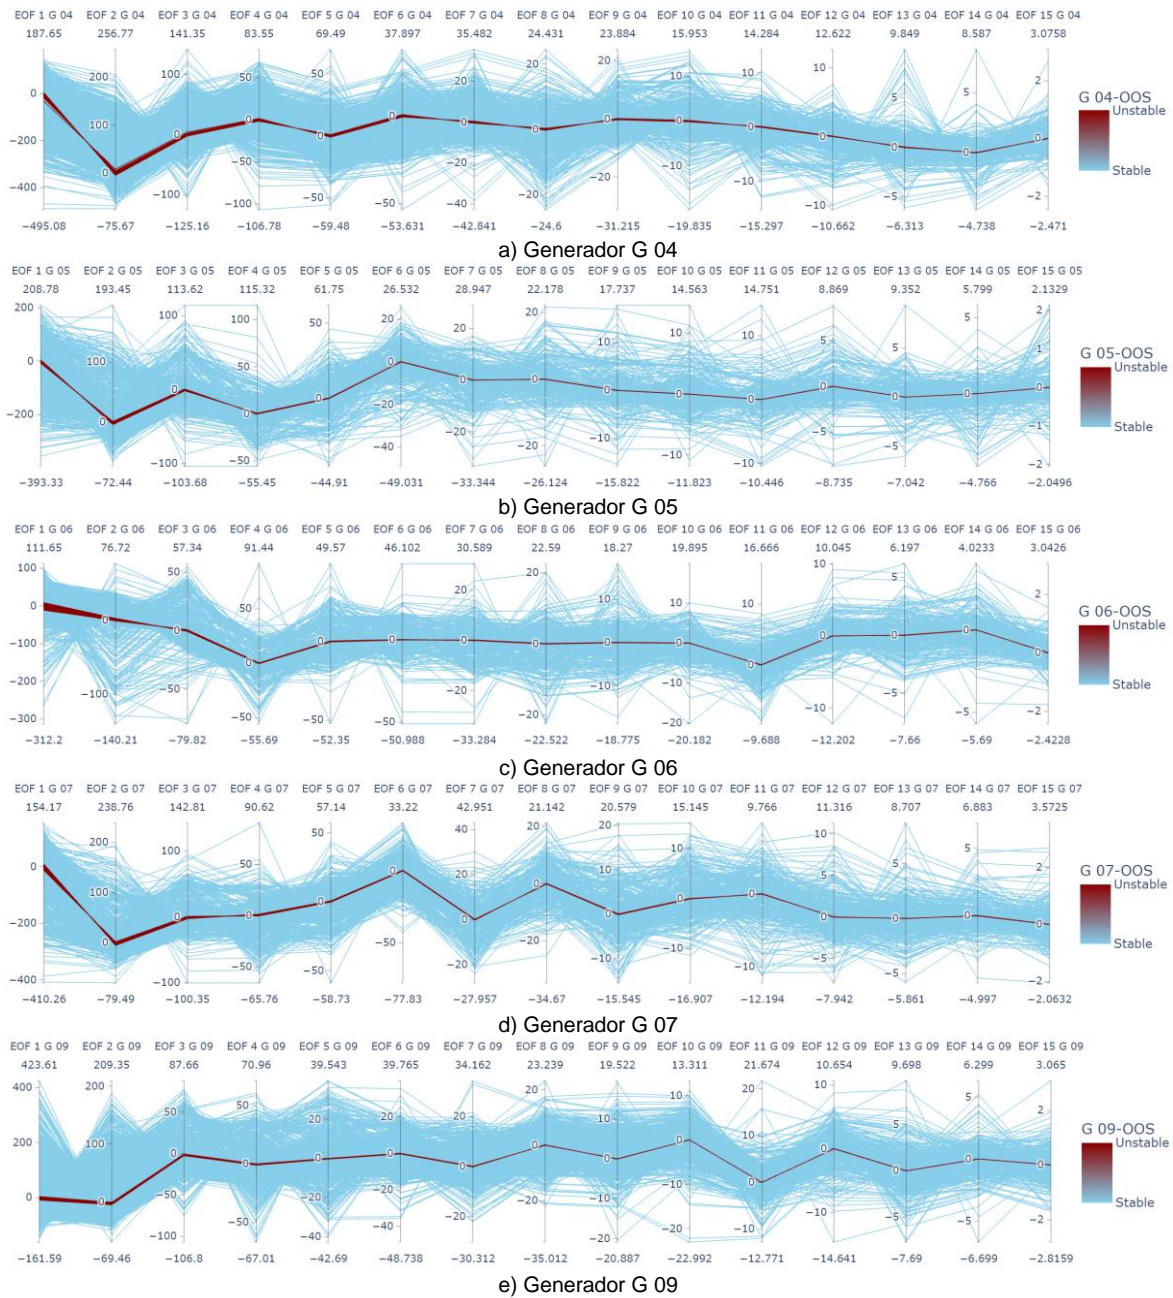


Figura 4.19. Coordenadas Paralelas de las 15 EOF scores de generadores críticos

4.3.3.2. Visualización de las Curvas de Andrews

En la Figura 4.20 se observan las Curvas de Andrews construidas a partir de 15 EOF scores. En estas curvas puede identificarse la concentración de los eventos inestables en una región espacial pequeña, de manera muy similar a lo que se ha analizado hasta este momento con otras representaciones gráficas. En consecuencia, se aprecia con un nuevo algoritmo la concentración de eventos inestables G 04 en una región reducida.

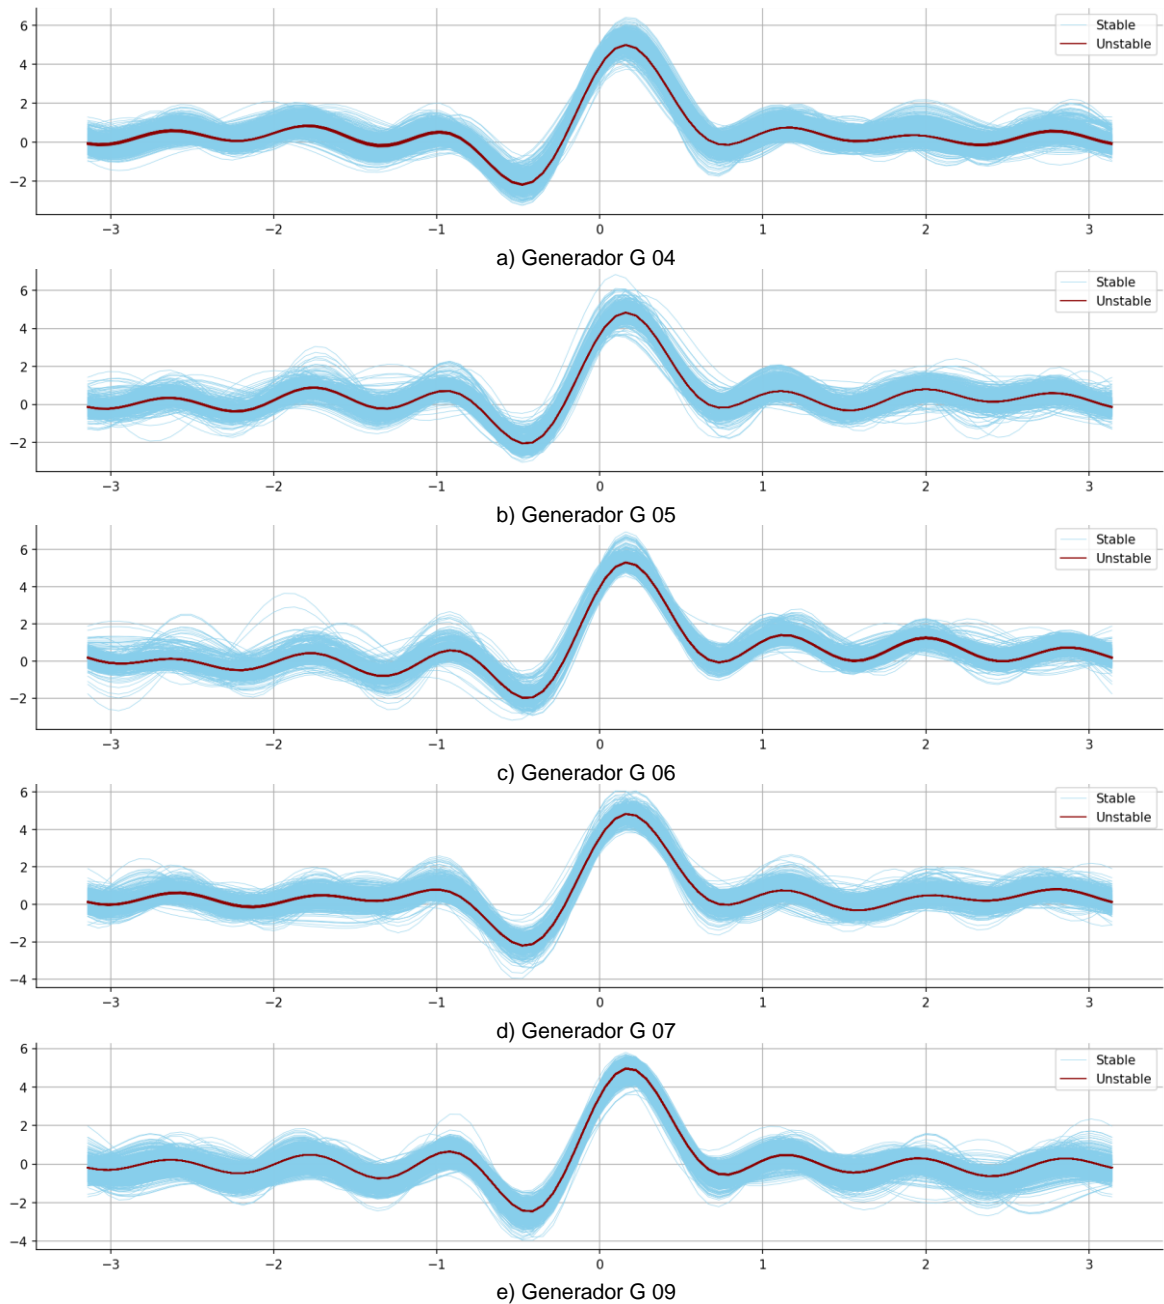


Figura 4.20. Ilustración de las Curvas de Andrews formadas a partir de las 15 EOF scores de los generadores críticos (EOF scores normalizadas entre 0 y 1)

4.3.3.3. Visualización Multidimensional del Algoritmo de RadViz

En la Figura 4.21 se ilustra la representación de RadViz para las EOF scores de los generadores críticos. En esta visualización se identifica con más claridad que los eventos inestables se localizan en una región concentrada definida por el espacio vectorial de las 15 EOF scores. Esta localización se encuentra cercana al origen. Además, se observa que existe solapamiento entre eventos estables e inestables.

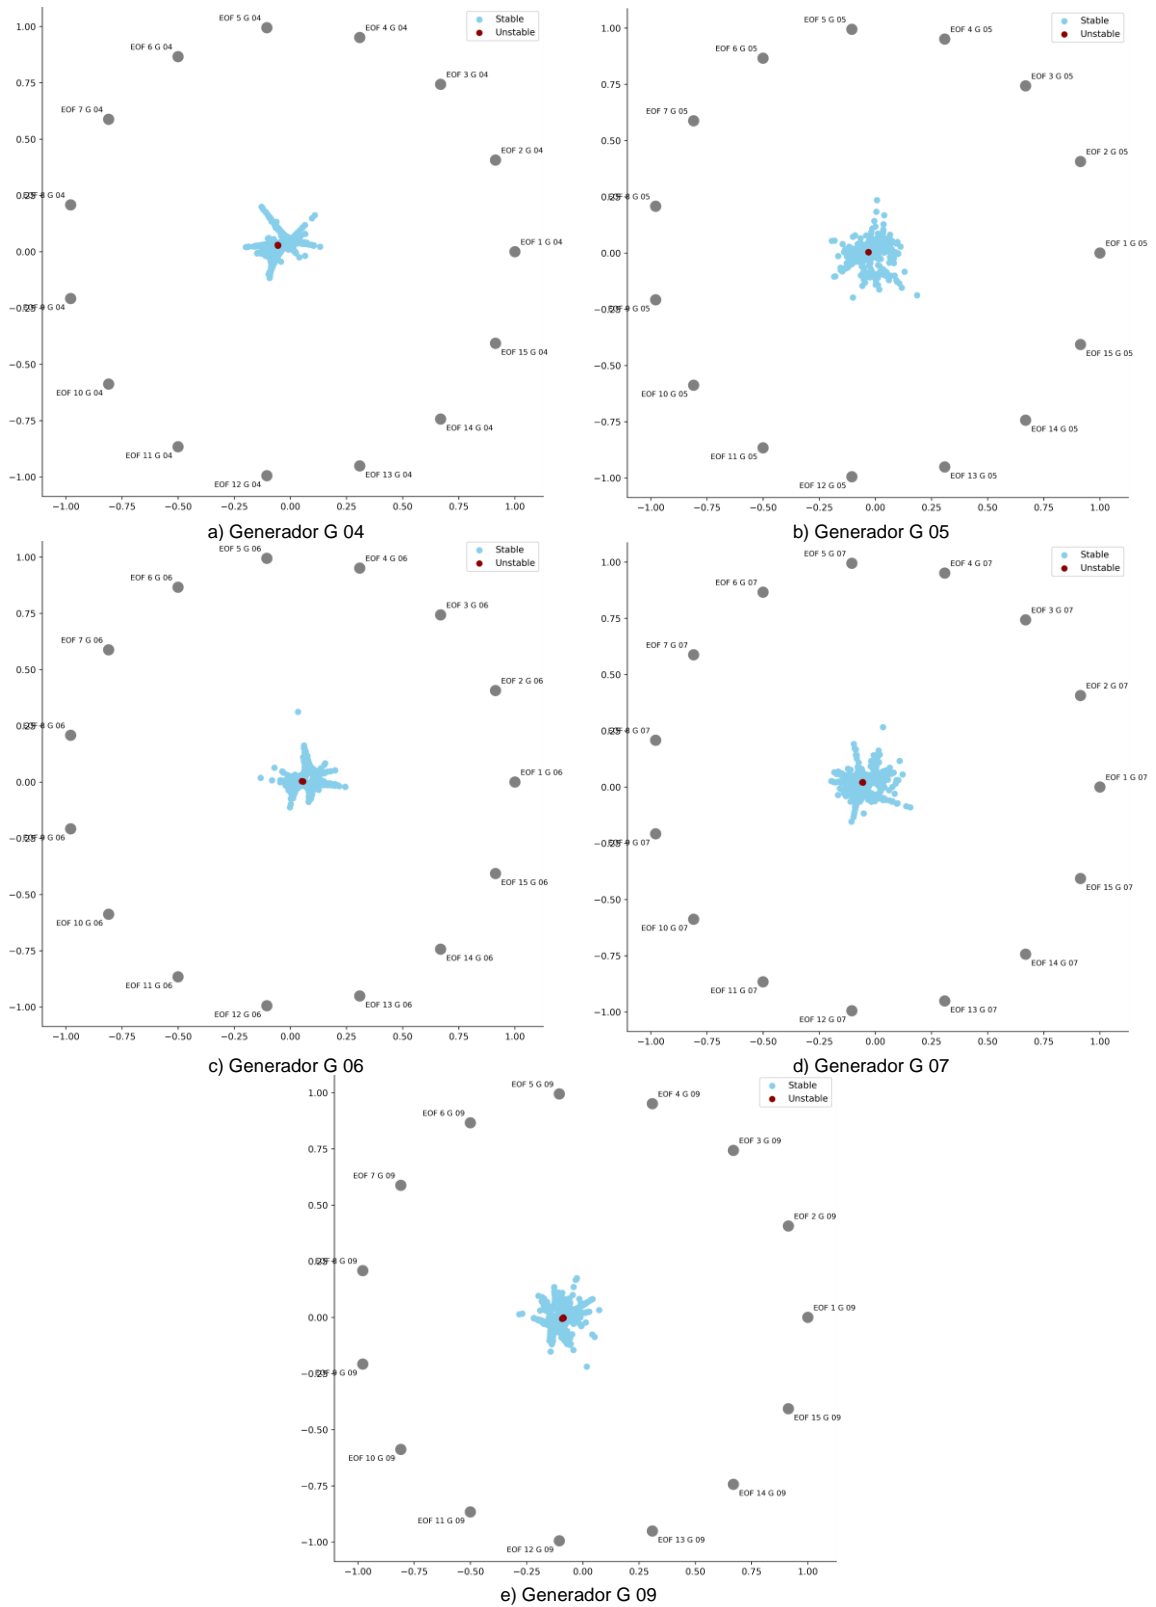


Figura 4.21. Representación bidimensional del espacio vectorial compuesto por las 15 EOF scores obtenidas para el conjunto de generadores críticos

4.3.4. Equilibrio de Clases

Con relación a la aplicación del equilibrio de clases, en la Figura 4.22 se observa el resultado obtenido con el algoritmo de submuestreo en las EOF scores de cada generador crítico. Esta aplicación permite omitir o eliminar aquellas observaciones estables alejadas de la región de concentración de eventos inestables. Aquellas observaciones estables cercanas a las inestables se mantienen y pueden permitir definir apropiadamente una frontera entre casos estables e inestables.

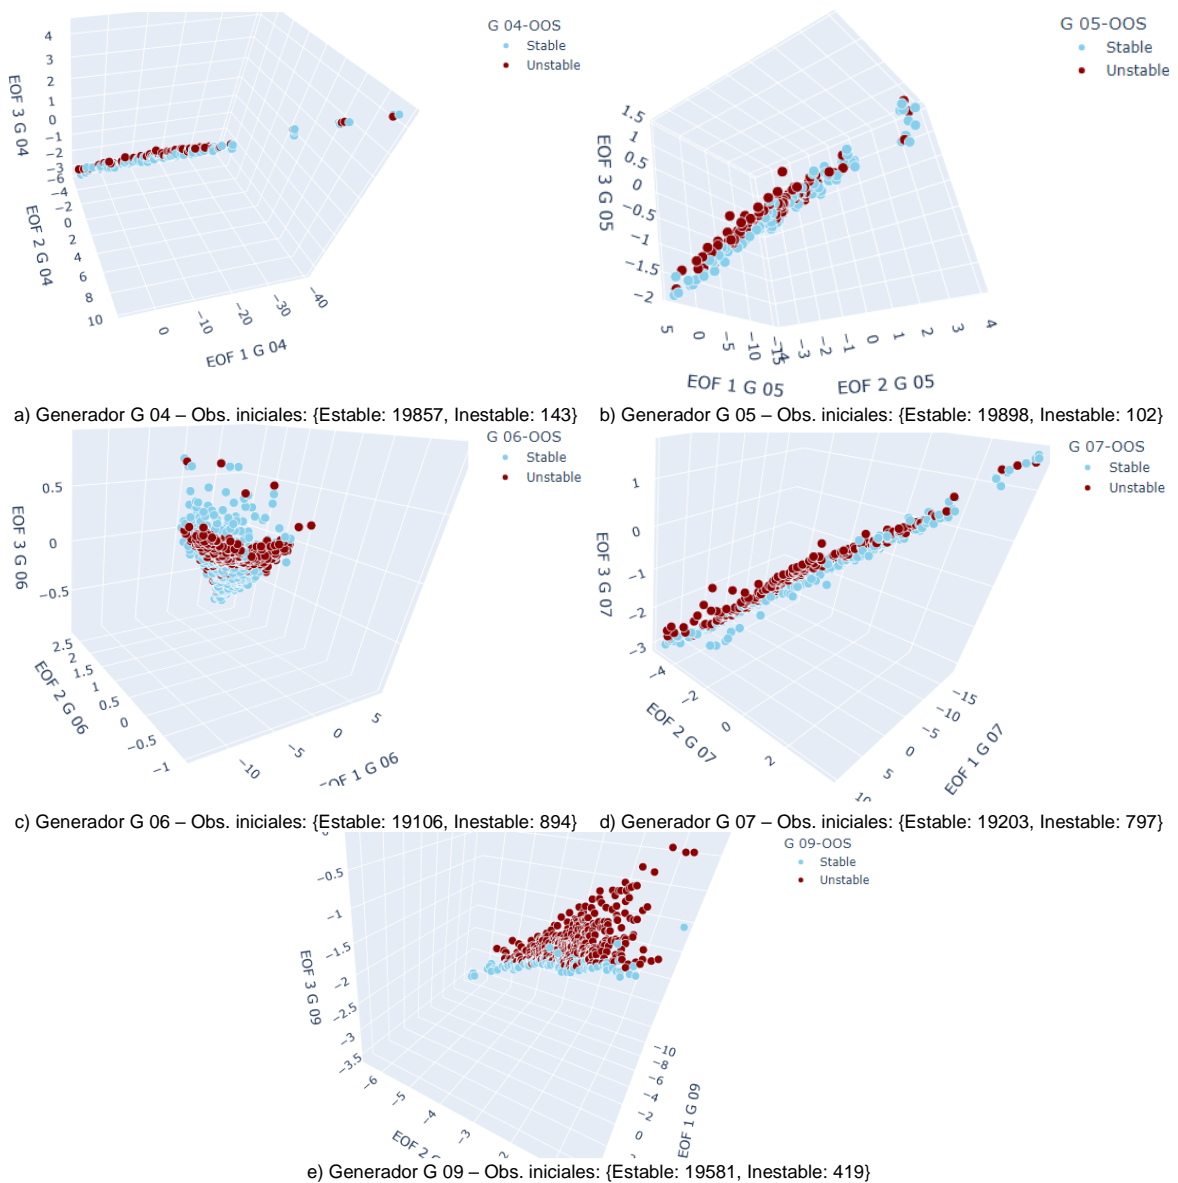


Figura 4.22. Aplicación del algoritmo NearMiss version 3 en EOF scores en el conjunto de generadores críticos

A través de la técnica de submuestreo, se observa con mayor claridad el solapamiento entre las observaciones estables e inestables. Esto representa un problema para la definición de una frontera que brinde una precisión total para la distinción de eventos estables e inestables.

4.3.5. Correlación de Información

En la Figura 4.23 se expone la matriz de correlación obtenida para las EOF de los generadores críticos. Se aprecia que las correlaciones son inferiores a 0.45 en todos los casos. En consecuencia, como se observa que en general las correlaciones son relativamente bajas, no es posible considerar que existe una alta dependencia lineal entre las EOF scores. De este modo, no se tiene evidencia suficiente para omitir a alguna EOF del análisis.




Figura 4.23. Matriz de correlación obtenida para el sistema de prueba IEEE 39-Bus System

4.4. Evaluación Predictiva de Estabilidad Transitoria

En este apartado se exponen los resultados de la aplicación de algoritmos de Aprendizaje Automático para la evaluación predictiva de Estabilidad Transitoria. Se presenta inicialmente, mediante la Figura 4.24, un ejemplo del resultado de clasificación para el generador G 04. Se presenta la matriz de confusión con diferentes algoritmos y varios criterios de tratamiento de datos en la matriz de EOF scores del LLE.

Para la obtención de estos resultados iniciales, se consideran los hiperparámetros por defecto de los clasificadores. El resultado de la Figura 4.24 muestra que es posible obtener diversidad en el desempeño de los clasificadores y, por lo tanto, la posibilidad de encontrar los mejores algoritmos de clasificación.

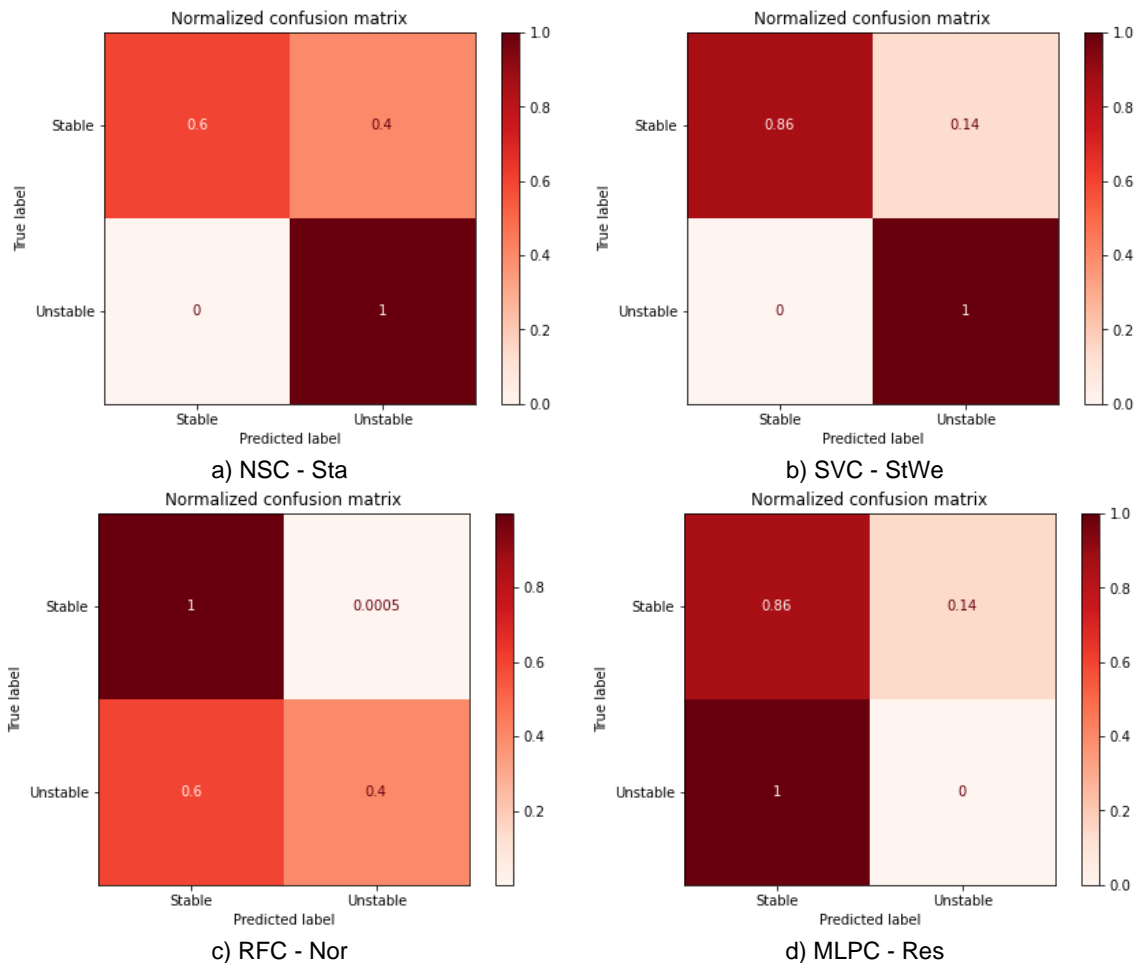


Figura 4.24. Ejemplo de resultados de Matriz de Confusión obtenida para los algoritmos de clasificación considerando las EOF scores del LLE del generador G 04

Se observa en la matriz de confusión que el *accuracy* en cada clase tiene variaciones significativas entre algoritmos. Evidentemente, el desbalance de clases influye sobre esta métrica. Además, se observa cómo hay algoritmos que abordan de mejor forma la predicción de solo eventos estables o solo inestables.

Por otro lado, en la Figura 4.25 se presenta el resultado de la métrica *balanced accuracy* para el generador G 05. En el *balanced accuracy* se evidencian las mejoras en el desempeño de los clasificadores que causa la introducción de las EOF scores del LLE y la matriz mixta.




Figura 4.25. Resultado de la métrica *balanced accuracy* para el generador G 05

Los resultados de las métricas *recall* para eventos estables e inestables, junto con el *balanced accuracy*, para el conjunto de generadores críticos y para el análisis global se presentan en el ANEXO G.

En relación con estos resultados, en la información mostrada en las Tablas 4.4-4.6 se presentan las estimaciones del *balanced accuracy* considerando las matrices de datos Matriz LLE, Matriz Ang y Matriz LLEAng.

Tabla 4.4. Resultados de *balanced accuracy* de la matriz de datos del LLE para el sistema IEEE 39-Bus System

Clasificador-Tratamiento	Balanced Accuracy – Matriz LLE					
	G 04	G 05	G 06	G 07	G 09	Global
NearestCentroid-Ori	0.7788	0.7246	0.7175	0.7086	0.7472	0.7056
SVC-Ori	0.5000	0.5000	0.5000	0.5000	0.5000	0.5349
RandomForestClassifier-Ori	0.7497	0.7056	0.8921	0.9338	0.9778	0.9221
MLPClassifier-Ori	0.8490	0.7647	0.8857	0.9269	0.9716	0.8781
NearestCentroid-Sta	0.7990	0.7656	0.7960	0.6962	0.7390	0.6439
SVC-Sta	0.5000	0.5000	0.5000	0.5000	0.4997	0.5518
RandomForestClassifier-Sta	0.7246	0.7350	0.9011	0.9273	0.9778	0.9277
MLPClassifier-Sta	0.7747	0.6765	0.8852	0.9386	0.9775	0.8914
SVC-StWe	0.9324	0.9667	0.9430	0.9521	0.9843	0.8863
RandomForestClassifier-StWe	0.6995	0.7645	0.9103	0.9311	0.9778	0.9151
NearestCentroid-Nor	0.7883	0.7265	0.7772	0.6968	0.7419	0.6285
SVC-Nor	0.5000	0.5000	0.5000	0.5000	0.5000	0.5172
RandomForestClassifier-Nor	0.6997	0.7350	0.8951	0.9244	0.9776	0.9206
MLPClassifier-Nor	0.5000	0.5000	0.5000	0.5000	0.5000	0.5604
NearestCentroid-Res	0.6357	0.5882	0.5847	0.5903	0.7193	0.5787
SVC-Res	0.6440	0.7210	0.6547	0.5860	0.5000	0.6629
RandomForestClassifier-Res	0.6738	0.6316	0.7799	0.7665	0.7881	0.9118
MLPClassifier-Res	0.4286	0.6836	0.6684	0.6537	0.5000	0.8304

Tabla 4.5. Resultados de *balanced accuracy* de la matriz de datos del ángulo del rotor para el sistema IEEE 39-Bus System

Clasificador-Tratamiento	Balanced Accuracy – Matriz Ang					
	G 04	G 05	G 06	G 07	G 09	Global
NearestCentroid-Ori	0.9335	0.9188	0.8519	0.7476	0.9562	0.6615
SVC-Ori	0.5499	0.5000	0.7911	0.5662	0.9097	0.7917
RandomForestClassifier-Ori	0.8997	0.8527	0.9774	0.9382	0.9659	0.9654
MLPClassifier-Ori	0.8745	0.5000	0.9238	0.8510	0.9056	0.9767
NearestCentroid-Sta	0.9657	0.9723	0.9792	0.9620	0.9840	0.8061
SVC-Sta	0.8747	0.8822	0.9750	0.9388	0.9771	0.9730
RandomForestClassifier-Sta	0.8746	0.8233	0.9745	0.9289	0.9549	0.9674
MLPClassifier-Sta	0.9244	0.9116	0.9781	0.9319	0.9824	0.9785
SVC-StWe	0.9947	0.9975	0.9889	0.9840	0.9914	0.9887
RandomForestClassifier-StWe	0.8496	0.8233	0.9778	0.9220	0.9494	0.9585
NearestCentroid-Nor	0.9656	0.9758	0.9701	0.9561	0.9813	0.7674
SVC-Nor	0.8996	0.8527	0.9749	0.9324	0.9717	0.9697
RandomForestClassifier-Nor	0.8997	0.8528	0.9776	0.9349	0.9549	0.9657
MLPClassifier-Nor	0.8994	0.8524	0.9691	0.9251	0.9715	0.9830
NearestCentroid-Res	0.7152	0.5691	0.7057	0.7328	0.8718	0.6484
SVC-Res	0.6992	0.6854	0.7200	0.8524	0.6071	0.9139
RandomForestClassifier-Res	0.6411	0.6790	0.7768	0.7571	0.7843	0.8711
MLPClassifier-Res	0.6162	0.6726	0.7196	0.8211	0.6071	0.9289

Tabla 4.6. Resultados de *balanced accuracy* de la matriz de datos del LLE y del ángulo del rotor para el sistema IEEE 39-Bus System

Clasificador-Tratamiento	Balanced Accuracy – Matriz LLEAng					
	G 04	G 05	G 06	G 07	G 09	Global
NearestCentroid-Ori	0.9332	0.9177	0.8525	0.7537	0.9654	0.6891
SVC-Ori	0.5250	0.5000	0.8675	0.6230	0.9041	0.8367
RandomForestClassifier-Ori	0.8747	0.9116	0.9863	0.9419	0.9888	0.9728
MLPClassifier-Ori	0.6000	0.9986	0.8888	0.8890	0.9778	0.9453
NearestCentroid-Sta	0.9628	0.9719	0.9792	0.9603	0.9831	0.8673
SVC-Sta	0.8746	0.8528	0.9780	0.9291	0.9716	0.9375
RandomForestClassifier-Sta	0.8499	0.9411	0.9806	0.9449	0.9831	0.9710
MLPClassifier-Sta	0.9246	0.9118	0.9782	0.9413	0.9827	0.9802
SVC-StWe	0.9921	0.9962	0.9910	0.9834	0.9964	0.9782
RandomForestClassifier-StWe	0.8497	0.9115	0.9724	0.9391	0.9888	0.9623
NearestCentroid-Nor	0.9651	0.9756	0.9701	0.9560	0.9812	0.7685
SVC-Nor	0.8996	0.8527	0.9749	0.9324	0.9663	0.9680
RandomForestClassifier-Nor	0.8497	0.9116	0.9776	0.9448	0.9831	0.9687
MLPClassifier-Nor	0.8995	0.8528	0.9797	0.9523	0.9609	0.9801
NearestCentroid-Res	0.6954	0.7161	0.7411	0.6848	0.8782	0.6509
SVC-Res	0.6769	0.6854	0.7636	0.8241	0.5357	0.8798
RandomForestClassifier-Res	0.8014	0.7737	0.8346	0.7824	0.8915	0.9180
MLPClassifier-Res	0.6916	0.7302	0.8318	0.7741	0.6786	0.9250

De manera general, se aprecia que las métricas más bajas tienden a presentarse en el caso del tratamiento de submuestreo (Res) y en el caso de uso de datos originales (Ori). Se evidencia, por otro lado, que las métricas más elevadas frecuentemente se presentan en el caso de los demás tratamientos de datos (Sta, StWe y Nor).

Adicionalmente, se observa que la tendencia de resultados se mantiene entre unidades de generación y también en el análisis global. Es decir, que aquellos clasificadores con el mejor desempeño mantienen esta característica en todas las unidades de generación y en el análisis global.

Finalmente, se debe mencionar que, para el análisis global, las métricas determinadas tienden a ser menores que en el análisis individual de EOF scores por unidad de generación.

4.5. Análisis del desempeño de algoritmos de Aprendizaje Automático

En este apartado se presenta la comparación entre los resultados obtenidos para los diferentes algoritmos de clasificación y el tratamiento de datos asociado. Además, se exponen los resultados proporcionados por el proceso de optimización de hiperparámetros. Esto con la finalidad de encontrar aquellos algoritmos más adecuados para el problema analizado.

4.5.1. Comparación entre algoritmos de clasificación

En la Tabla 4.7 se expone el resumen de las mejores métricas obtenidas en el caso del sistema de prueba IEEE 39-Bus System. En este detalle se muestran los clasificadores que proveen los valores más elevados del *balanced accuracy*, considerando las EOF scores del LLE, del ángulo y ambas. Además, se añaden los resultados para el enfoque individual de evaluación por generador y para el enfoque global.

Tabla 4.7. Compendio de resultados del mejor *balanced accuracy* por tipo de EOF score para el sistema IEEE 39-Bus System

Clasificador- Tratamiento	Best Balanced Accuracy					Global
	G 04	G 05	G 06	G 07	G 09	
MLPClassifier-Ori		1) LLE+Ang (0.9986)				
RandomForestClassifier-Sta						3) LLE (0.9277)
MLPClassifier-Sta						2) LLE+Ang (0.9802)
SVC-StWe	1) Ang (0.9947) 2) LLE+Ang (0.9921) 3) LLE (0.9324)	2) Ang (0.9975) 3) LLE (0.9667)	1) LLE+Ang (0.9910) 2) Ang (0.9889) 3) LLE (0.9430)	1) Ang (0.9840) 2) LLE+Ang (0.9834) 3) LLE (0.9521)	1) LLE+Ang (0.9964) 2) Ang (0.9914) 3) LLE (0.9843)	1) Ang (0.9887)

En este resultado se observa que el clasificador SVC, con el tratamiento StWe, tiende a presentar los mejores resultados. No obstante, para que el proceso de optimización cuente con una mayor diversidad de algoritmos, se lleva a cabo un análisis en el que se identifican las mejores métricas por clasificador. En este contexto, en la Tabla 4.8 se muestran los mejores resultados obtenidos en cada caso. Se resaltan las mejores opciones obtenidas para cada unidad de generación y para el análisis global.

Posteriormente, las alternativas de clasificación que presentan la mejor métrica de desempeño son escogidas para un proceso de optimización de hiperparámetros. De este modo, el proceso de optimización considera las particularidades de diferentes algoritmos de Aprendizaje Automático dentro de un análisis para identificar aquellos algoritmos más adecuados.

Tabla 4.8. Compendio de resultados del mejor *balanced accuracy* por clasificador para el sistema IEEE 39-Bus System

Clasificador-Tratamiento	Best Balanced Accuracy					
	G 04	G 05	G 06	G 07	G 09	Global
NearestCentroid-Ori	Ang (0.9335)	Ang (0.9188)	LLE+Ang (0.8525)	LLE+Ang (0.7537)	LLE+Ang (0.9654)	LLE (0.7056)
SVC-Ori	Ang (0.5499)	LLE (0.5000)	LLE+Ang (0.8675)	LLE+Ang (0.6230)	Ang (0.9097)	LLE+Ang (0.8367)
RandomForestClassifier-Ori	Ang (0.8997)	LLE+Ang (0.9116)	LLE+Ang (0.9863)	LLE+Ang (0.9419)	LLE+Ang (0.9888)	LLE+Ang (0.9728)
MLPClassifier-Ori	Ang (0.8745)	LLE+Ang (0.9986)	Ang (0.9238)	LLE (0.9269)	LLE+Ang (0.9778)	Ang (0.9767)
NearestCentroid-Sta	Ang (0.9657)	Ang (0.9723)	Ang (0.9792)	Ang (0.9620)	Ang (0.9840)	LLE+Ang (0.8673)
SVC-Sta	Ang (0.8747)	Ang (0.8822)	LLE+Ang (0.9780)	Ang (0.9388)	Ang (0.9771)	Ang (0.9730)
RandomForestClassifier-Sta	Ang (0.8746)	LLE+Ang (0.9411)	LLE+Ang (0.9806)	LLE+Ang (0.9449)	LLE+Ang (0.9831)	LLE+Ang (0.9710)
MLPClassifier-Sta	LLE+Ang (0.9246)	LLE+Ang (0.9118)	LLE+Ang (0.9782)	LLE+Ang (0.9413)	LLE+Ang (0.9827)	LLE+Ang (0.9802)
SVC-StWe	Ang (0.9947)	Ang (0.9975)	LLE+Ang (0.9910)	Ang (0.9840)	LLE+Ang (0.9964)	Ang (0.9887)
RandomForestClassifier-StWe	LLE+Ang (0.8497)	LLE+Ang (0.9115)	Ang (0.9778)	LLE+Ang (0.9391)	LLE+Ang (0.9888)	LLE+Ang (0.9623)
NearestCentroid-Nor	Ang (0.9656)	Ang (0.9758)	Ang (0.9701)	Ang (0.9561)	Ang (0.9813)	LLE+Ang (0.7685)
SVC-Nor	Ang (0.8996)	Ang (0.8527)	Ang (0.9749)	Ang (0.9324)	Ang (0.9717)	Ang (0.9697)
RandomForestClassifier-Nor	Ang (0.8997)	LLE+Ang (0.9116)	Ang (0.9776)	LLE+Ang (0.9448)	LLE+Ang (0.9831)	LLE+Ang (0.9687)
MLPClassifier-Nor	LLE+Ang (0.8995)	LLE+Ang (0.8528)	LLE+Ang (0.9797)	LLE+Ang (0.9523)	Ang (0.9715)	Ang (0.9830)
NearestCentroid-Res	Ang (0.7152)	LLE+Ang (0.7161)	LLE+Ang (0.7411)	Ang (0.7328)	LLE+Ang (0.8782)	LLE+Ang (0.6509)
SVC-Res	Ang (0.6992)	LLE (0.7210)	LLE+Ang (0.7636)	Ang (0.8524)	Ang (0.6071)	Ang (0.9139)
RandomForestClassifier-Res	LLE+Ang (0.8014)	LLE+Ang (0.7737)	LLE+Ang (0.8346)	LLE+Ang (0.7824)	LLE+Ang (0.8915)	LLE+Ang (0.9180)
MLPClassifier-Res	LLE+Ang (0.6916)	LLE+Ang (0.7302)	LLE+Ang (0.8318)	Ang (0.8211)	LLE+Ang (0.6786)	Ang (0.9289)

4.5.2. Optimización Bayesiana de hiperparámetros

En este apartado se presentan los resultados concernientes al proceso de Optimización Bayesiana, desarrollado a partir de los algoritmos resaltados en la Tabla 4.8. A continuación, se presentan, como ejemplo, los resultados obtenidos para el generador G 09. En el ANEXO H el lector puede consultar los resultados completos de optimización en todos los generadores críticos y aquellos obtenidos para el enfoque de análisis global.

Mediante los resultados de las Figuras 4.26-4.29, se observa la convergencia del proceso de Optimización en relación con la métrica considerada. Para este trabajo se probaron entre 40 y 50 iteraciones del algoritmo optimizador. En la formulación del algoritmo esto conlleva a que se prueba entre 40 y 50 valores para cada hiperparámetro. Los valores óptimos obtenidos constituyen las mejores representaciones encontradas de los clasificadores para este problema particular.




Figura 4.26. Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09




Figura 4.27. Optimización Bayesiana en el algoritmo SVC-StWe generador G 09




Figura 4.28. Optimización Bayesiana en el algoritmo NSC-Sta generador G 09




Figura 4.29. Optimización Bayesiana en el algoritmo RFC-StWe generador G 09




Figura 4.30. Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09

A través del módulo *BayesSearchCV* se observan los valores de los hiperparámetros que han sido probados en el análisis de optimización. De manera ilustrativa, la Figura 4.30 presenta la gráfica correspondiente para la Optimización Bayesiana en el algoritmo MLP-Classifier en el generador G 09. En este caso se identifican las diferentes alternativas de hiperparámetros que fueron consideradas y los correspondientes valores óptimos. De esta manera, es posible observar la localización más probable de los valores óptimos, lo cual orienta al analista de datos a la toma de decisiones acerca de los valores de hiperparámetros más útiles.

Por otro lado, en la Figura 4.31 se observa la dependencia parcial del proceso de Optimización Bayesiana, en donde se identifica que el número de neuronas en ciertas capas presenta una dependencia parcial aproximadamente constante. Es decir, estos hiperparámetros podrían eventualmente ser omitidos del proceso de optimización; puesto que su variación no cambia significativamente los resultados del modelo.

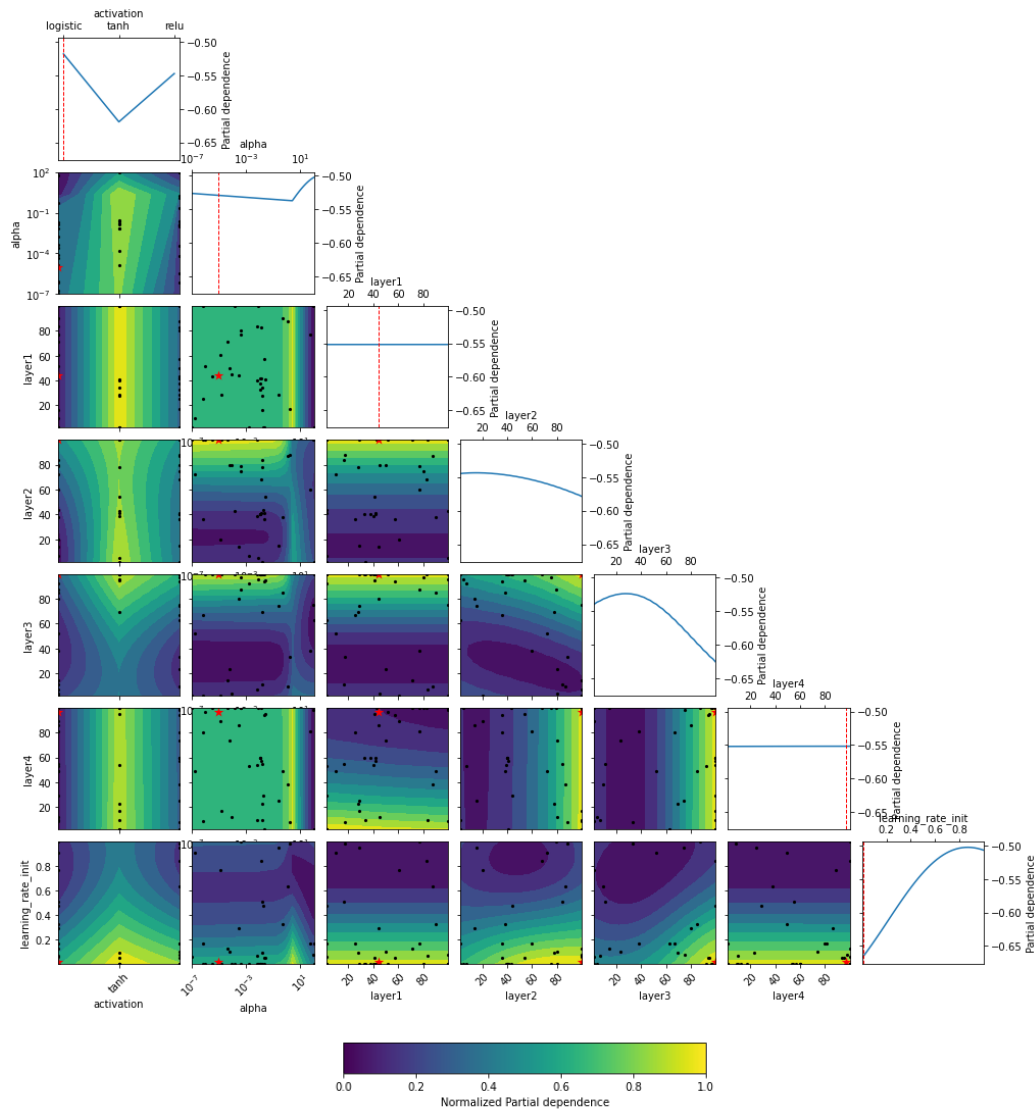


Figura 4.31. Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09

Por otra parte, a través del módulo *permutation_importance* se cuantifica la significancia de las diferentes características usadas en el entrenamiento. En la Figura 4.32 se ilustra la significancia obtenida en el caso del clasificador MLPC-Sta. Se observa la predominancia de ciertas características en el modelo de Aprendizaje. De manera particular, la significancia es prioritaria para las señales del ángulo del rotor, lo cual se espera considerando que son las señales esenciales de análisis de la dinámica de estabilidad transitoria. A su vez, las EOF del LLE presentan significancias bajas; no obstante, se refleja que si intervienen en el desempeño del clasificador.




Figura 4.32. Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09

A continuación, en la Tabla 4.9 se presenta un resumen de los resultados obtenidos. Como se observa en los valores presentados, la mejor opción es el algoritmo SVC-StWe por presentar la métrica más elevada. Esta situación ocurre en todas las unidades de generación y en el análisis global.

En referencia a las estimaciones de tipo Training CV y Testing, se evidencia que existe una tendencia del algoritmo SVC-StWe a presentar los mejores resultados. No obstante, de manera excepcional, en el caso del generador G 09, el algoritmo RFC-StWe es el que presenta la mejor métrica.

Con relación al tipo de EOF utilizada, se tiene que, para dos unidades de generación, la matriz combinada (LLE+Ang) es la que permite la mejor métrica en el algoritmo SVC-StWe. En los casos restantes las métricas más elevadas ocurren con la matriz Ang. Aun así, se ha encontrado en este análisis que existen ligeras diferencias entre el uso de la Matriz LLEAng y la Matriz Ang.

En el ANEXO H pueden consultarse los resultados completos de optimización de todos los Algoritmos de Clasificación.

Tabla 4.9. Compendio de Resultados de Optimización Bayesiana de hiperparámetros

Enfoque	Algoritmo optimizado	Tipo de EOF usada	Balanced accuracy		
			Training CV	Testing	CV
G 04	MLPC-Sta	LLE+Ang	0.8286	0.9737	0.8728
	SVC-StWe	Ang	0.9871	0.9911	0.9918
	NSC-Sta	Ang	0.9478	0.9653	0.9513
	RFC-Nor	Ang	0.8196	0.8747	0.8176
G 05	MLPC- Ori	LLE+Ang	0.9028	0.9411	0.9064
	SVC-StWe	Ang	0.9938	0.9955	0.9895
	NSC-Nor	Ang	0.9534	0.9735	0.9578
	RFC-Sta	LLE+Ang	0.8754	0.9411	0.8925
G 06	MLPC-Nor	LLE+Ang	0.9526	0.8685	0.9497
	SVC-StWe	LLE+Ang	0.9887	0.9943	0.9909
	NSC-Sta	Ang	0.9775	0.9792	0.9783
	RFC-Ori	LLE+Ang	0.9589	0.9839	0.9583
G 07	MLPC-Nor	LLE+Ang	0.9179	0.9523	0.9247
	SVC-StWe	Ang	0.9846	0.9841	0.9837
	NSC-Sta	Ang	0.9567	0.9620	0.9578
	RFC-Sta	LLE+Ang	0.9285	0.9482	0.9323
G 09	MLPC-Sta	LLE+Ang	0.9795	0.9610	0.9830
	SVC-StWe	LLE+Ang	0.9962	0.9865	0.9901
	NSC-Sta	Ang	0.9853	0.9838	0.9851
	RFC-StWe	LLE+Ang	0.9887	0.9937	0.9850
Global	MLPC-Nor	Ang	0.9685	0.9886	0.9703
	SVC-StWe	Ang	0.9881	0.9908	0.9882
	NSC-Sta	LLE+Ang	0.8797	0.8681	0.8769
	RFC-Ori	LLE+Ang	0.9507	0.9747	0.9564

4.6. Discusión

El presente trabajo se constituye de varios hitos en torno a la evaluación predictiva de Estabilidad Transitoria, los cuales consideran herramientas matemáticas y computacionales sofisticadas. En este contexto, se proporcionan varios análisis innovadores que destacan y plantean mejoras a los resultados de investigaciones relacionadas. Por ejemplo:

1. Se incluye el comportamiento estocástico de un SEP en el análisis del LLE mediante simulaciones de Montecarlo.
2. Se propone una modificación en el cálculo del LLE, a través del parámetro *shrink*, para reducir el número de muestras de las series de tiempo del ángulo del rotor reservadas para su estimación.
3. Se demuestra, a partir de un volumen considerable de simulaciones, inconsistencias que presenta el signo del LLE alcanzado en estado estacionario frente al tipo de evento simulado (estable o inestable).
4. Se identifican regularidades del LLE no asociadas únicamente a su signo. En este sentido, se determinan claros patrones de localización y concentración del LLE estimado para eventos inestables.

5. Se prescinde de la simple observación del signo del LLE en estado estacionario. En su lugar, se plantean métodos sofisticados e innovadores de Minería de Datos y Aprendizaje Automático.
6. Se plantea un análisis multidimensional a partir de herramientas gráficas especiales, como las Coordenadas paralelas, Curvas de Andrews y el algoritmo de RadViz bidimensional y tridimensional, el cual permite la observación de patrones de EOF scores en espacios vectoriales superiores al tridimensional.
7. Se propone una estrategia para el balanceo de clases que reduce la posibilidad de sobreentrenamiento y trata de evitar la eliminación de información significativa.
8. Se plantea una metodología para la evaluación predictiva de Estabilidad Transitoria que ostenta alta precisión y rapidez. Esto faculta su aplicabilidad en tiempo real.
9. Se compara el desempeño de diferentes algoritmos de clasificación, tipos de EOF scores y alternativas de tratamiento de datos.
10. Se incluye una etapa de optimización de hiperparámetros, basada en el concepto del Teorema de Bayes, para encontrar las mejores opciones algorítmicas al problema en estudio.

A continuación, se exponen interpretaciones y declaraciones de los resultados obtenidos en este trabajo vinculadas con la pregunta de investigación.

4.6.1. Análisis Exploratorio de Datos

De acuerdo con los resultados observados en el apartado 4.1, la estadística de las simulaciones de Montecarlo muestra que la cantidad de eventos inestables puede ser ínfima en comparación con la cantidad de eventos estables. Esta condición provoca diversas dificultades para la solución del problema de evaluación predictiva de Estabilidad Transitoria. Esto considerando que la cantidad de información que se puede extraer de los eventos inestables es mucho menor que para eventos estables. De esta manera, se ejecutó una cantidad de simulaciones elevada para superar esta situación. Una consideración que se ha practicado usualmente en varias investigaciones relacionadas [1], [69].

Adicionalmente, se observan coeficientes de homogeneidad elevados para ciertas variables, como un resultado de la diferencia de magnitud que existe entre eventos estables e inestables. Por esta razón, se identifica que el índice de error de Montecarlo no constituye un parámetro suficiente para determinar un número vasto de simulaciones al ser extremadamente alto para las variables a las que se hace referencia.

Por otro lado, el análisis exploratorio proporciona un primer indicio de que el signo del LLE en estado estacionario (transcurrido 5 segundos de los eventos de cortocircuito) no proporciona información consistente con el tipo de evento simulado (estable o inestable). Esta condición, evidenciada gráficamente a través de la Figura 4.6, compromete el análisis a partir de simple observación del LLE. En consecuencia, se demuestra en este trabajo la falencia de investigaciones relacionadas que están basadas en una supuesta confiabilidad del signo del LLE alcanzada después de varios segundos [4], [5], [7]. Además, se observa que la convergencia tardía del LLE provoca traslapes en la identificación de eventos estables e inestables.

Finalmente, se debe destacar que elevar la ventana de observación por encima de 5 segundos, para pretender observar la convergencia del LLE con suficiente precisión, supone una acción contraproducente en el sentido de que los eventos de estabilidad transitoria requieren un monitoreo y control dentro de pocos segundos [12].

4.6.2. Aplicación del Máximo Exponente de Lyapunov

La evolución dinámica del LLE es inherentemente caótica [34]. Además, en relación con el LLE estimado a partir del ángulo del rotor, se presentan fluctuaciones y oscilaciones que irrumpen en el signo final del LLE en estado estacionario. Como consecuencia, tal y como se ha evidenciado en los resultados de este trabajo (ver sección 3.4 y 4.2), la evaluación del signo del LLE no es posible para el análisis de Estabilidad Transitoria. De esta forma, este trabajo proporciona un criterio para obviar el análisis del signo del LLE en el estudio de estabilidad y proponer metodologías más precisas de inspección, que superen los problemas de imprecisión y retardo del LLE. Por ejemplo, la identificación de patrones.

Estas consideraciones, que han sido plenamente justificadas en este trabajo, ponen en debate los resultados desarrollados actualmente en torno a esta temática por otros autores [4], [5], [8]. Si bien es cierto, para el sistema de prueba IEEE 9-Bus System y IEEE 39-Bus System, en la mayoría de los casos, la evolución dinámica del LLE converge de tal manera que el signo final concuerda con el tipo de eventos inestables, se debe destacar que no es suficiente. Esto debido a que los eventos estables no son generalmente distinguidos consistentemente por el signo del LLE (ver Figura 4.8). Además, la determinación de estabilidad en periodos largos de análisis no es factible [12].

Por otro lado, con relación al período reservado para la estimación del LLE en una ventana de tiempo reducida, se ha demostrado que, pese a que se comprometen varios milisegundos de retardo, aun así, es posible el desarrollo de acciones de control oportunas

en el WAMPAC. Las justificaciones se han desarrollado en torno a la estadística de tiempos de contingencias asociadas con el disparo de las unidades de generación (contingencias N-2) y que están basadas en el análisis propuesto en [1]. En este sentido, de acuerdo con los resultados de la sección 4.2.2, se justifica que existen holguras de tiempo amplias y suficientes para que se desarrollen acciones de control que mitiguen y eviten la ocurrencia de eventos en cascada.

Asimismo, se debe destacar que en la evolución dinámica del LLE para una ventana de observación reducida (ver Figuras 4.11-4.15) existe un primer indicio de la presencia de patrones en el LLE que permiten una discriminación entre eventos estables e inestables. En esta perspectiva, el presente trabajo evidencia varias regularidades del LLE; principalmente, la característica de que el LLE correspondiente a eventos inestables ocupa un espacio vectorial más reducido o concentrado que el LLE relacionado con eventos estables, el cual se muestra como más disperso. Este fenómeno se explica en el sentido de que luego del despeje de una falla, la tasa de convergencia estimada con el LLE para eventos inestables tiende a ser más reducida que en el caso de eventos estables. Por esta razón, las magnitudes del LLE de eventos inestables son generalmente reducidas. Este resultado se utiliza en los algoritmos de clasificación como un soporte o una característica adicional para el Aprendizaje Automático y la predicción de estabilidad del SEP. Esto con la finalidad de mejorar las métricas de clasificación de estos algoritmos.

Finalmente, cabe destacar que los resultados de este trabajo muestran que la magnitud del LLE de eventos inestables en muchos casos presenta una varianza menor al 1% que la correspondiente varianza en eventos estables. Este patrón no ha sido identificado antes en ninguna investigación relacionada y sirve como un sustento base para la Minería de Datos desarrollada consecuentemente.

4.6.3. Minería de Datos

La aplicación de la técnica EOF en series de tiempo de señales de una SEP constituye una estrategia novedosa planteada en [52] que ha sido aprovechada en este trabajo para la desagregación de las series de tiempo del LLE en vectores ortogonales y EOF scores asociados. De esta manera, se consigue, tal y como lo ejemplifican las investigaciones relacionadas [1], [52], una interpretación matemática que se adapta mejor a la forma peculiar de la evolución dinámica poscontingencia del LLE. Esto proporciona mejores prestaciones para el reconocimiento de patrones y, por lo tanto, una mejor capacidad para la evaluación de Estabilidad Transitoria.

Asimismo, uno de los resultados más vistosos de la aplicación de EOF scores en las series de tiempo del LLE es la visualización de datos multidimensional, la cual permitió identificar la concentración de eventos inestables en un espacio vectorial reducido cercano al origen. Esta característica no se presenta en el ángulo del rotor. De este modo, lo mostrado en este trabajo constituye un resultado novedoso que contribuye al área de investigación relacionada. El impacto y utilidad de este hallazgo resalta al considerar que la identificación de patrones del ángulo del rotor proporciona resultados generalmente más ambiguos y complejos, como los mostrados en [52].

Adicionalmente, a través de Coordenadas Paralelas, curvas de Andrews y el algoritmo de RadViz se determinaron claras concentraciones del LLE de eventos inestables en espacios vectoriales reducidos, lo cual puede ser visto como una característica adicional para la etapa de entrenamiento de máquinas de Aprendizaje Automático. En este contexto, según lo demuestra la Ingeniería de Características, la inclusión de nueva información extraída de la original puede brindar mejores precisiones en el entorno de aprendizaje [76], [80], [81]. En consecuencia, este resultado puede permitir incluir más información en la aplicación de EOF scores del ángulo del rotor, lo cual constituye un aporte para mejorar el trabajo doctoral desarrollado en [1].

Por otro lado, en el contexto del equilibrio de clases propuesto, se planteó una técnica como alternativa para evitar la pérdida significativa de información y a la vez reducir la posibilidad de sobreentrenamiento en los algoritmos de aprendizaje. En primer lugar, se considera que se evita la pérdida significativa de información porque las observaciones que se omiten en el submuestreo corresponden a eventos estables lejanos a las regiones de frontera. Es decir, observaciones que pueden considerarse como no críticas para el análisis. Esto concuerda con lo puntualizado por varios autores en análisis similares de submuestreo para otros fenómenos, en donde existe elevado desbalance y solapamiento de clases [77]. Con relación a la reducción de la posibilidad de sobreentrenamiento, se tiene que en esencia el submuestreo planteado no multiplica observaciones inestables, evitando así que la validación cruzada K-fold empleada en el aprendizaje considere las mismas observaciones para los conjuntos de prueba y entrenamiento.

Finalmente, se debe resaltar que la inclusión del estudio de correlación entre EOF scores constituye una estrategia para identificar posibles relaciones simples que orienten hacia la eliminación de posibles EOF scores redundantes. No obstante, el resultado de correlación obtenido en este trabajo muestra que no existen relaciones lineales elevadas entre estas

características. Esta condición sugiere que cada una de las EOF scores proporciona información valiosa e íntegra para una etapa de Aprendizaje Automático.

4.6.4. Evaluación Predictiva de Estabilidad Transitoria

La consideración de diferentes algoritmos de Aprendizaje Automático, junto con alternativas de tratamiento de datos, permite el análisis de resultados frente a una diversidad de criterios y multiplicidad de formulaciones matemáticas para la clasificación inteligente de observaciones estables o inestables. Esto proporciona la capacidad para encontrar los mejores algoritmos y prestaciones para la evaluación precisa de Estabilidad Transitoria.

A partir de los resultados de la metodología propuesta, se evidencia que las EOF scores del LLE permiten una predicción más temprana de estabilidad que la simple observación de las series de tiempo del ángulo del rotor. Como se muestra en el ejemplo de la Figura 4.33, la inestabilidad ocurre luego de aproximadamente 1 segundo del evento de falla. No obstante, después de la estimación del LLE y las EOF scores asociadas en una ventana de tiempo definida, se tiene que a $t=0.275$ s ya se logra predecir que el evento es inestable. Este ejemplo demuestra que la inestabilidad se predice mucho antes que la ocurrencia de un evento en cascada. Además, se tiene la suficiente anticipación para el desarrollo de acciones de control correctivo apropiadas a través del WAMPAC.




Figura 4.33. Evolución dinámica de un evento inestable causado por una falla en la línea Line 16 – 17 despejada a $t=0.112$ seg. (Simulación Nro. 32)

Con respecto a los resultados de clasificación obtenidos, se debe notar que la alta concentración de EOF scores del LLE de eventos inestables incrementa en muchos casos la fiabilidad y seguridad conseguida con los algoritmos de clasificación. Esto considerando que la característica de localización introduce en los algoritmos de aprendizaje un criterio adicional sobre la ubicación espacial de estas DVR en el espacio vectorial correspondiente. En este sentido, en la Figura 4.34 se ejemplifica el resultado obtenido en el generador G 05 para la métrica *recall* de eventos inestables (fiabilidad). Se observa que, para los diferentes algoritmos de clasificación y tratamiento de datos, en muchos casos las métricas son mejores al utilizar la Matriz LLE o la Matriz LLEAng. Esto constituye una evidencia de que el LLE sí permite proporcionar información adicional embebida en el ángulo del rotor.

Asimismo, se demuestra que la combinación de señales (LLE y ángulo del rotor) puede mejorar aún más la precisión de la clasificación.

Adicionalmente, se observa que el uso preliminar de hiperparámetros por defecto en los algoritmos de clasificación proporciona métricas elevadas inclusive iguales a la unidad (para el caso de un conjunto de prueba y entrenamiento aleatorio).




Figura 4.34. Resultado de la métrica *recall* en el generador G 05 – eventos inestables

Por otro lado, en lo concerniente al compendio de resultados del balanced accuracy obtenido con las diferentes matrices de datos (LLE, Ang, LLE+Ang), se han obtenido tendencias para ciertos algoritmos, los cuales presentan generalmente los mejores resultados; como es el caso del algoritmo SVC-StWe.

Además, se encuentra que el análisis global no brinda una mayor robustez en el estudio. Esto considerando que las métricas obtenidas son generalmente menores que aquellas obtenidas para cada generador de manera individual. Asimismo, se observa que la contribución de la adición del LLE es mejor en el enfoque individual. Cuando se analiza el desempeño del análisis global, la contribución del LLE es inapreciable.

4.6.5. Análisis del desempeño de algoritmos de Aprendizaje Automático

Los resultados generales previos al proceso de Optimización Bayesiana sugieren que el algoritmo SVC-StWe es el que presenta las mejores métricas de desempeño. No obstante,

el proceso mencionado tiene la capacidad para mejorar el desempeño de otros algoritmos que tentativamente podrían superar las prestaciones del algoritmo SVC. En este sentido, la metodología incluyó en el proceso los 4 algoritmos de clasificación considerados, con sus mejores prestaciones de tratamiento de datos. De esta manera, se planteó considerar una mayor diversidad de algoritmos.

Sin embargo, el proceso final de optimización reflejó que el algoritmo SVC-StWe continuó mostrándose superior. En consecuencia, el trabajo muestra que, para este fenómeno y sistema de prueba, se puede generalizar el resultado de que el mejor algoritmo es el SVC con el tratamiento de datos de ponderación en el desbalance de clases.

Adicionalmente, se debe destacar que las estimaciones conseguidas alcanzan métricas similares a las obtenidas en [1]. En este trabajo se alcanzan valores de balanced accuracy superiores a 0.99 con validación cruzada en el modelo con hiperparámetros óptimos. De este modo, se evidencia que el proceso de optimización es satisfactorio y mejora significativamente las métricas, determinando los algoritmos más adecuados para el fenómeno estudiado.

Por otro lado, se observa que el enfoque individual para cada generador proporciona generalmente mejores métricas que considerar el análisis global. Es decir, la conjunción de las EOF scores de los generadores críticos no contribuye a mejorar el desempeño de los clasificadores (se presenta mayor distorsión en el espacio multidimensional de las DVR).

Entre tanto, con respecto a los tipos de EOF scores usados (LLE, Ang y LLEAng), se observa que, en muchos casos, la mejor opción corresponde a la matriz Ang. No obstante, se evidencia también que la adición del LLE permite la mejora de las métricas proporcionadas en varios casos. Desde esta perspectiva, se identifica que, a pesar de que las EOF del ángulo del rotor presentan métricas aceptables, las diferencias con respecto a lo obtenido para la matriz mixta son ligeras. En consecuencia, se demuestra que el LLE sí puede ser utilizado para la evaluación predictiva de Estabilidad Transitoria con criterios de precisión y rapidez.

Por otra parte, se debe notar que el número de iteraciones consideradas para el proceso de optimización Bayesiana conlleva a que se probaron entre 40 y 50 valores en cada hiperparámetro de los algoritmos correspondientes. De esta manera, el proceso exploró un espacio de búsqueda vasto para la ubicación de valores óptimos (ver ejemplo de la Figura 4.30).

Con relación a la caracterización de hiperparámetros a través de la herramienta *partial dependence*, las gráficas proporcionadas permiten identificar el espacio de búsqueda que se consideró para cada algoritmo de clasificación, así como las localizaciones más probables en las que se ubican los valores óptimos de los hiperparámetros. Aun así, se debe destacar que, de acuerdo con la formulación matemática utilizada en Python [63], este tipo de gráfica se construye a partir de estimaciones aproximadas. Por este motivo, este tipo de resultados debe ser tomado con la reserva del caso. Además, se debe entender que la dependencia parcial no es equivalente al valor de accuracy, lo que se traduce en que una variable puede incidir significativamente en el desempeño de un algoritmo, pero aun así no permitir métricas elevadas.

En lo que respecta a la información de *feature importance*, los resultados proporcionados pueden orientar sobre aquellas características con menor influencia en los modelos. Esta propiedad puede ser aprovechada como un criterio de selección de características. Sin embargo, también se debe tener en cuenta que el resultado depende, como tal, de la efectividad del algoritmo de optimización. Es decir, un modelo con hiperparámetros no óptimos puede indicar erróneamente bajos valores de significancia para características que si serían relevantes para el mismo modelo adecuadamente optimizado.

Finalmente, cabe mencionar que las ilustraciones de *partial dependence* y *feature importance* constituyen herramientas de análisis de gran utilidad que proporciona el proceso de optimización y que incluyen información acerca de la influencia entre hiperparámetros y características con respecto al modelo o clasificador. En este contexto, la examinación de las propiedades de los resultados de *partial dependence* y *feature importance* corresponde a una estrategia de análisis detallada, lo cual no se extiende en este trabajo porque escapa del alcance del presente documento.

5. CONCLUSIONES Y RECOMENDACIONES

5.1. Conclusiones

En relación con el objetivo general:

- En este trabajo se desarrolló una metodología para la evaluación Predictiva de Estabilidad Transitoria de Sistemas Eléctricos de Potencia en tiempo real mediante Aprendizaje Automático y la identificación de patrones del Máximo Exponente de Lyapunov. En esta propuesta se incluye el uso de herramientas matemáticas y computacionales novedosas que demuestran su aplicabilidad con prestaciones de rapidez, precisión y flexibilidad. Por lo tanto, la metodología planteada es una contribución innovadora que propone mejoras a los resultados de investigaciones relacionadas y también demuestra la potencialidad de ser aplicada en el SNI ecuatoriano.

En relación con los objetivos específicos:

- En este trabajo se describió la funcionalidad del esquema WAMPAC para desarrollar aplicaciones de Evaluación de la Vulnerabilidad Dinámica en tiempo real en el marco de las Redes Eléctricas Inteligentes. En esta descripción, se identificaron diferentes etapas interrelacionadas que constituyen la infraestructura básica de un esquema WAMPAC, y que tienen la capacidad de permitir ejecutar acciones de control correctivo inteligentes con características de rapidez, precisión y flexibilidad.
- Se consiguió analizar la aplicación del Máximo Exponente de Lyapunov para el estudio de Estabilidad Transitoria en SEP. El análisis se formuló en un inicio con base en simplificaciones de un modelo OMIB, lo cual proporcionó patrones preliminares del LLE. Luego, con un análisis de dispersión, para las primeras muestras del LLE, se identificaron regularidades del LLE con respecto a las magnitudes reducidas ocupadas por eventos inestables. Es así como se evidenciaron características del LLE que pueden ser sintetizadas matemáticamente con identificación de patrones a través de Minería de Datos y así permitir una aplicación más generalizable y precisa del LLE para estudios de estabilidad.
- Con la aplicación de técnicas de Minería de Datos sobre señales del Máximo Exponente de Lyapunov se lograron identificar varios patrones inmersos que se constituyen en información o características útiles para un proceso de evaluación

predictiva de Estabilidad Transitoria. Entre estos patrones se encontró la significativa concentración de las EOF scores del LLE en un espacio vectorial reducido. Además, se identificó que este espacio se encuentra cercano al origen. Se destaca la exclusividad de este resultado, tomando en cuenta que estos patrones no se identificaron en las EOF scores asociadas al ángulo del rotor.

- A través de la identificación de patrones de señales del Máximo Exponente de Lyapunov se consiguió estructurar una metodología de evaluación predictiva de Estabilidad Transitoria. En este contexto, el planteamiento demuestra su potencialidad para aplicaciones en tiempo real por los tiempos reducidos asociados, el grado de precisión alcanzado y la flexibilidad de la propuesta. Además, se demuestra que el LLE puede incluir información adicional en el proceso de Aprendizaje Automático, de tal manera que las métricas de desempeño de evaluación pueden incrementarse con su uso.
- Se logró examinar el desempeño de diferentes algoritmos de Aprendizaje Automático para la evaluación predictiva de Estabilidad Transitoria de un SEP. En esta tarea comparativa se identificaron las mejores prestaciones que pueden proporcionar varios de estos algoritmos. Asimismo, para ampliar esta comparación, se incluyeron alternativas de tratamiento de datos y tipos de EOF scores. Además, se añadió un proceso de optimización de hiperparámetros que permitió encontrar los algoritmos más adecuados para el problema analizado.

Conclusiones adicionales:

- El presente trabajo se constituye como el pionero en el análisis del LLE, obtenido de series de tiempo, para la evaluación de Estabilidad Transitoria en tiempos reducidos, en donde se prescinde de la evaluación del signo final del LLE (que además fue descartado en este trabajo como un indicador robusto) para plantear, en su lugar, la identificación de patrones en las primeras muestras del LLE para la etapa poscontingencia de la evolución de eventos. El planteamiento es atractivo y robusto porque constituye un método directo simplificado, en el que no se requiere el modelo analítico del sistema y, por lo tanto, puede ser aplicado en un SEP real con ayuda de la tecnología de medición sincrofasorial.
- El fundamento detrás del uso del LLE, en lugar o en complemento a las señales originales del ángulo del rotor, nace desde una perspectiva teórica. Esto considerando que, en la formulación del LLE, varios autores demuestran que el

indicador permite desentrañar la dinámica de una señal de una manera más amplia. Es así como se determina que el LLE puede abordar de mejor forma comportamientos caóticos y evitar predicciones erróneas. En este trabajo, se obtuvo que el LLE puede exhibir patrones exclusivos que no aparecen significativamente en el ángulo del rotor.

- La concentración de patrones, en una región reducida de un espacio vectorial, evidenciada en las EOF scores del LLE de eventos inestables, puede ser vista también como la adición de una característica agregada a los algoritmos de Aprendizaje Automático, la cual puede ser interpretada matemáticamente por estos durante el proceso interno de entrenamiento. Según se demuestra en este trabajo, la inclusión del LLE puede brindar mejores precisiones en el entorno del aprendizaje.
- El uso de técnicas de Minería de Datos y algoritmos de Aprendizaje Automático es necesario para un esquema WAMPAC en el desarrollo de una Red Inteligente autocurable. Esto bajo la perspectiva de que se trata de herramientas que facultan análisis con suficiente rapidez computacional y precisión para ser aplicados en tiempo real.

5.2. Recomendaciones

- Utilizar los aportes de este trabajo como una guía para desarrollos futuros que se concentren en el análisis predictivo de Estabilidad Transitoria. Algunos de estos aportes son: la inclusión del parámetro *shrink* en la estimación oportuna del LLE, el planteamiento de identificación de patrones en las primeras muestras del LLE mediante Minería de Datos, el análisis multidimensional de EOF scores y el uso de la Optimización Bayesiana para la mejora de los modelos de Aprendizaje Automático.
- Se recomienda la comparación de la presente metodología con aquellas disponibles en la literatura, que también han mostrado importantes resultados. Esto con la finalidad de encontrar las metodologías que proporcionen las mejores prestaciones para su aplicación en el SNI del Ecuador. La comparación requerirá el análisis no solo de los tiempos oportunos de evaluación, sino también de la complejidad de los algoritmos empleados, los esfuerzos computacionales involucrados, la flexibilidad de su aplicación real, entre otros temas de interés.

- Considerar la aplicación de la presente metodología en modelos simulados de Sistemas de Potencia reales, por ejemplo, el SNI del Ecuador. Esto con la finalidad de explorar con mayor detalle la aplicación de lo propuesto en este trabajo y la viabilidad de implementación en el sector eléctrico. Además, se recomienda la medición de los tiempos de ejecución de las diferentes etapas de la metodología en tiempo real, para así determinar los retardos que surgen en aplicaciones prácticas.
- Ampliar la investigación presentada incluyendo el estudio de la evolución dinámica completa de los eventos. Es decir, añadiendo el análisis de las acciones de control correctivo en el SEP y el desempeño más aproximado de las protecciones eléctricas. De este modo, será posible explorar con más detalle la función del WAMPAC para evitar eventos en cascada que conduzcan a colapsos parciales o totales.
- Las ventanas de tiempo de análisis, el número de muestras del LLE, las condiciones iniciales en el cálculo del LLE y otros criterios relacionados, han sido obtenidos en este trabajo de forma simplificada, por lo que se recomienda para un trabajo futuro el análisis del impacto de estas variables en la precisión de los algoritmos de clasificación.
- Se recomienda la formulación de nuevos planteamientos para la estimación de un LLE global, con el fin de evitar resultados parciales por generador y obtener menos indicadores en el análisis. De esta manera el problema podría simplificarse conservando las características de precisión, rapidez y flexibilidad.

5.3. Trabajos Futuros

- Planteamiento de mejoras en la estimación del LLE e inclusive el uso de un nuevo índice adaptado específicamente para el análisis de Estabilidad Transitoria. Esto con el fin de reducir los tiempos de estimación del LLE y garantizar resultados predictivos precisos.
- Planteamiento de diferentes técnicas alternativas de reducción de dimensionalidad de las series de tiempo del LLE, por ejemplo:
 - Principal Component Analysis (PCA)
 - Locally Linear Embedding (LLE*)
 - Local Tangent Space Alignment (LTSA)
 - Hessian Eigenmapping (Hessian LLE*)
 - Modified Locally Linear Embedding
 - Isomap

- Multi-dimensional Scaling (MDS)
- Spectral Embedding (SE)
- t-distributed Stochastic Neighbor Embedding (t-SNE)

En la Figura 5.1 se observa la aplicación de estas técnicas para las series de tiempo del LLE en el generador G3 del sistema IEEE 9-Bus System. La visualización de resultados sugiere el potencial de búsqueda de nuevos patrones en el indicador LLE que eventualmente podrían proporcionar mejores resultados que las EOF scores.

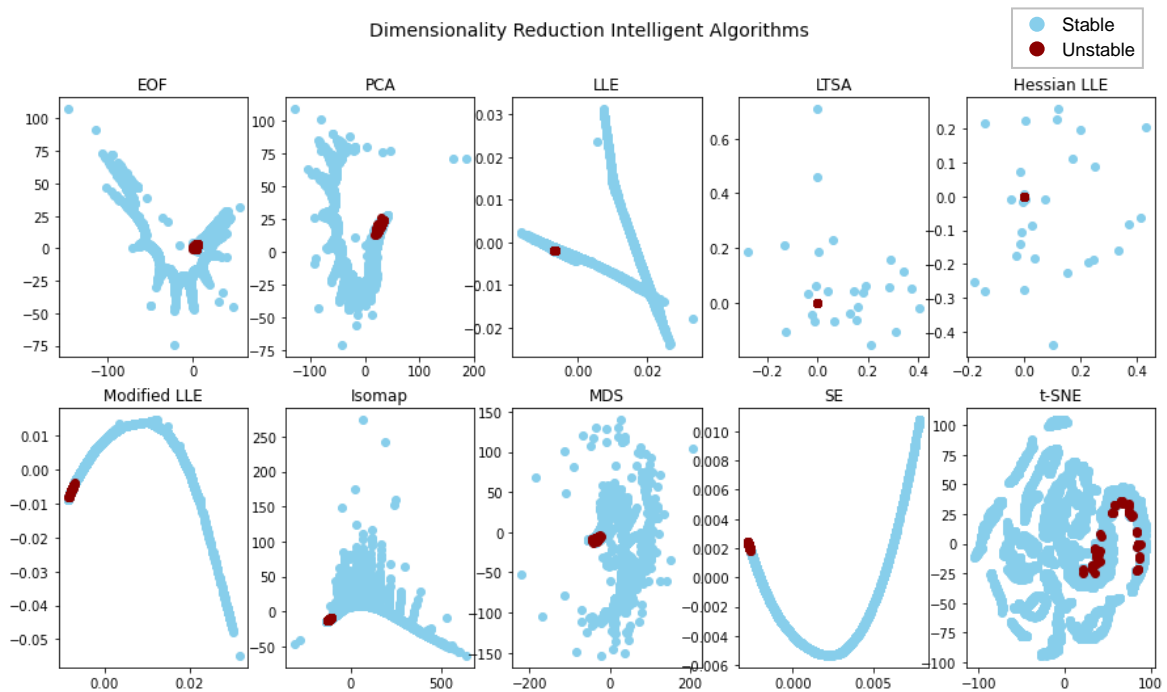


Figura 5.1. Representación bidimensional de la reducción de dimensionalidad de las series de tiempo del LLE para el generador G3 del sistema IEEE 9-Bus System

- Uso de distintos algoritmos de Aprendizaje Automático que permitan una mejor adaptación al problema analizado proporcionando métricas de evaluación más elevadas.
- Analizar la posibilidad de aplicar el LLE, junto con la metodología de identificación de patrones y de evaluación predictiva presentada a otros fenómenos de estabilidad tales como la estabilidad de voltaje de corto plazo o la estabilidad de frecuencia de corto plazo.

6. REFERENCIAS BIBLIOGRÁFICAS

- [1] J. C. Cepeda Campaña, Evaluación de la Vulnerabilidad del Sistema Eléctrico de Potencia en Tiempo Real Usando Tecnología de Medición Sincrofasorial, San Juan: Instituto de Energía Eléctrica, Universidad Nacional de San Juan, 2013.
- [2] R. Baldick, B. Chowdhury, I. Dobson, Z. Dong, B. Gou and D. Hawkins, "Vulnerability assessment for cascading failures in electric power systems," in *2009 IEEE/PES Power Systems Conference and Exposition*, Seattle, 2009.
- [3] L. Wang and A. Girgis, "A new Method for Power System Transient Instability Detection," *IEEE Transactions on Power Delivery*, vol. 12, no. 3, pp. 1082-1089, 1997.
- [4] D. Huang, Q. Chen, S. Ma, Y. Zhang and S. Chen, "Wide-Area Measurement—Based Model-Free Approach for Online Power System Transient Stability Assessment," *Energies* 2018, vol. 11, no. 958, 2018.
- [5] S. Dasgupta and U. Vaidya, "PMU-Based Model-Free Approach for Real-Time Rotor Angle Monitoring," *IEEE TRANSACTIONS ON POWER SYSTEMS*, 2014.
- [6] S. Wei, M. Yang, J. Qi, J. Wang, S. Ma and X. Han, "Model-Free MLE Estimation for Online Rotor Angle Stability Assessment with PMU Data," *IEEE Transactions on Power Systems*, vol. 33, no. 3, pp. 2463 - 2476, 2018.
- [7] S. Dasgupta, M. Paramasivam, U. Vaidya and V. Ajarapu, "PMU-based model-free approach for short term voltage stability monitoring," in *2012 IEEE Power and Energy Society General Meeting*, San Diego, 2012.
- [8] C.-W. Liu, J. S. Thorp, J. Lu and R. J. Thomas, "Detection of Transiently Chaotic Swings in Power Systems Using Real-Time Phasor Measurements," *IEEE Transactions on Power System*, vol. 9, no. 3, pp. 1285-1292, 1994.
- [9] J. Yan, C.-C. Liu and U. Vaidya, "PMU-Based Monitoring of Rotor Angle Dynamics," *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2125-2133, 2011.
- [10] G. S. Vassell, "Northeast Blackout of 1965," *IEEE Power Engineering Review*, vol. 11, no. 1, p. 4, 1991.
- [11] P. Kundur, J. Paserba, V. Ajarapu, G. Andersson, A. Bose, C. Canizares, N. D. Hatziargyriou, D. Hill and A. M. Stanković, "Definition and classification of power system stability IEEE/CIGRE joint task force on stability terms and definitions," *IEEE Transactions on Power Systems*, vol. 19, no. 3, pp. 1387 - 1401, 2004.
- [12] P. Kundur, *Power System Stability and Control*, McGraw Hill, 1994.
- [13] N. Hatziargyriou, J. Milanovic, C. Rahmann, V. Ajarapu, C. Canizares, I. Erlich, D. Hill, I. Hiskens, I. Kamwa, B. Pal, P. Pourbeik, A. Stankovic, V. Vittal and C. Vournas,

- "Definition and Classification of Power System Stability – Revisited & Extended," *IEEE Transactions on Power Systems*, vol. 36, no. 4, pp. 3271 - 3281, 2020.
- [14] M. Pavella, D. Ernst and D. Ruiz, "Transient Stability of Power Systems - A Unified Approach to Assessment and Control," Kluwer Academic Publishers, London, 2000.
- [15] M. Melendez, *Análisis y Aplicación del Método de la Función de la Energía Transitoria a la Solución del Problema de Estabilidad de Sistemas Eléctricos de Potencia*, Monterey: Universidad Autónoma de Nuevo León, 1985.
- [16] Z. Shi, W. Yao, L. Zeng and J. Wen, "Convolutional neural network-based power system transient stability assessment and instability mode prediction," *Applied Energy*, vol. 263, no. 114586, 2020.
- [17] A. Pikovsky and A. Politi, *Lyapunov Exponents - A Tool to Explore Complex Dynamics*, Cambridge University Press, 2016.
- [18] Y. Xue, T. Van Cutsem y M. Ribbens-Pavella, «Extended equal area criterion justifications, generalizations, applications,» *IEEE Transactions on Power Systems*, vol. 4, nº 1, pp. 44 - 52, 1989.
- [19] J. Cepeda, P. Salazar, D. Echeverría and H. Arcos, "Implementation of the Single Machine Equivalent (SIME) Method for Transient Stability Assessment in DIGSILENT PowerFactory," in *Advanced Smart Grid Functionalities Based on PowerFactory*, Springer International Publishing, 2018, pp. 319-353.
- [20] L. Ramesh, S. P. Chowdhury and S. Chowdhury, "Wide area monitoring protection and control - A comprehensive application review," in *10th IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change*, Manchester, 2010.
- [21] R. Baldick, B. Chowdhury, I. Dobson, Z. Dong, B. Gou and D. Hawkins, "Vulnerability assessment for cascading failures in electric power systems," in *2009 IEEE/PES Power Systems Conference and Exposition*, Seattle, 2009.
- [22] J. Cepeda and J. L. Rueda Torres, "Introduction: The Role of Wide Area Monitoring Systems in Dynamic Vulnerability Assessment," in *Dynamic Vulnerability Assessment and Intelligent Control for Sustainable Power Systems*, John Wiley & Sons, 2018, pp. 1-20.
- [23] J. Cepeda and D. Colome, "Vulnerability Assessment of Electric Power Systems Through Identification and Ranking of Vulnerable Areas," *International Journal of Emerging Electric Power Systems*, vol. 13, no. 1, 2012.
- [24] T. Amraee and S. Ranjbar, "Transient Instability Prediction Using Decision Tree Technique," *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 3028 - 3037, 2013.
- [25] A. N. AL-Masri, M. Z. A. Ab Kadir and H. Hizam, "A Novel Implementation for Generator Rotor Angle Stability Prediction Using an Adaptive Artificial Neural

- Network Application for Dynamic Security Assessment," *IEEE Transactions on Power Systems*, vol. 28, no. 3, pp. 2516 - 2525, 2013.
- [26] Y. Zhou, J. Wu and Z. Yu, "A Hierarchical Method for Transient Stability Prediction of Power Systems Using the Confidence of a SVM-Based Ensemble Classifier," *Energies*, vol. 9, no. 10, pp. 778-785, 2016.
- [27] Y. Li and Z. Yang, "Application of EOS-ELM With Binary Jaya-Based Feature Selection to Real-Time Transient Stability Assessment Using PMU Data," *IEEE Access*, vol. 5, pp. 23092 - 23101, 2017.
- [28] Z. Dong and P. Zhang, *Emerging Techniques in Power System Analysis*, Springer, 2010.
- [29] D. Echeverría, J. Cepeda and G. Colomé, "Real-time transient stability assessment of electric power systems using predictive-SIME based on machine learning," in *2017 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*, Quito, 2017.
- [30] P. Zhang and D. Zhao, *Program on Technology Innovation: Application of Data Mining Method to Vulnerability Assessment*, Electric Power Research Institute (EPRI), 2007.
- [31] N. K. Andrews, *Numerical Approximation of Lyapunov Exponents and its Applications in Control Systems*, Georgia Southern University, 2021.
- [32] P. Banerjee, S. Srivastava and K. Srivastava, "A Lyapunov Exponent based Method for Online Transient Stability Assessment," in *2014 Eighteenth National Power Systems Conference (NPSC)*, Guwahati, 2014.
- [33] L. Barreira, *Lyapunov Exponents*, Lisboa: Springer International Publishing, 2017.
- [34] M. Rosenstein, J. Collins and C. Luca, *A practical method for calculating largest Lyapunov exponents from small data sets*, Boston: NeuroMuscular Research Center and Department of Biomedical Engineering, 1992.
- [35] P. Wadduwage, C. Q. Wub and U. Annakkage, "Power system transient stability analysis via the concept of Lyapunov Exponents," *Electric Power Systems Research*, vol. 104, pp. 183-192, 2013.
- [36] T. Trappenberg y A. Back, «A classification scheme for applications with ambiguous data,» de *Proceedings of the IEEE-INNS-ENNS International Joint Conference on Neural Networks. IJCNN 2000. Neural Computing: New Challenges and Perspectives for the New Millennium*, Como, 2000.
- [37] I. Kamwa, "PMU-Based Vulnerability Assessment using Wide-Area Severity Indices and Tracking Modal Analysis," in *IEEE Power Systems Conference and Exposition*, Atlanta, 2006.

- [38] A. Phadke and J. Thorp, *Synchronized Phasor Measurements and Their Applications*, Virginia: Virginia Polytechnic Institute and State University, 2008.
- [39] C. Martinez, M. Parashar, J. Dyer and J. Coroas, "Phasor Data Requirements for Real Time Wide-Area Monitoring, Control and Protection Applications," *EIPP – Real Time Task Team*, 2005.
- [40] S. Gamboa and E. Orduña, "Hierarchically Distributed Architecture for Large-scale Integrated WAMPAC System," in *2015 International Conference on Electronics, Communications and Computers (CONIELECOMP)*, Cholula, 2015.
- [41] L. Ramesh, S. Chowdhury and S. Chowdhury, "Wide Area Monitoring Protection and Control - A Comprehensive Application Review," in *10th IET International Conference on Developments in Power System Protection (DPSP 2010). Managing the Change*, Manchester, 2010.
- [42] A. De La Torre, J. Cepeda and J. Herrera, "Implementación de un Sistema de Monitoreo de Área Extendida WAMS en el Sistema Nacional Interconectado del Ecuador SNI," *Ingenius. Revista de Ciencia y Tecnología*, vol. 1, no. 10, pp. 34-43, 2013.
- [43] J. Cepeda, D. Echeverría and G. Argüello, "Cenace's experiences on implementing a wide area monitoring system (WAMS) in the Ecuadorian power system," in *2014 IEEE Central America and Panama Convention (CONCAPAN XXXIV)*, Panamá, 2014.
- [44] R. Segundo, Y. Liu, E. Barocio and P. Korba, "Application of spatio-temporal data-driven and machine learning algorithms for security assessment," Technical Report PES-TR104 IEEE Power & Energy Society, 2022.
- [45] J. Eckmann and D. Ruelle, "Ergodic theory of chaos and strange attractors," *Reviews of Modern Physics*, vol. 57, no. 3, pp. 617-656, 1985.
- [46] J.-P. Eckmann, S. O. Kamphorst and S. Ciliberto, "Liapunov exponents from time series," *Physical review A, Atomic, molecular, and optical physics*, vol. 34, no. 6, pp. 4971--4979, 1986.
- [47] F. Takens, "Detecting strange attractors in turbulence, Warwick 1980," in *Dynamical Systems and Turbulence*, Heidelberg, Springer, 1981, p. 366–381.
- [48] L. Di Caro, V. Frias and E. Frias, "Analyzing the Role of Dimension Arrangement for Data Visualization in Radviz," in *Advances in Knowledge Discovery and Data Mining, Part II: 14th Pacific-Asia Conference, PAKDD 2010, Hyderabad, Indi3a, June 21-24, 2010, Proceedings*, Berlin, Springer, 2010, pp. 147-132.
- [49] M. Kantardzic, *Data Mining - Concepts, Models, Methods, and Algorithms*, New Jersey: John Wiley & Sons, 2020.
- [50] D. Peña, *Análisis de Datos Multivariantes*, McGraw-Hill Interamericana, 2002.

- [51] P. Duboue, *The Art of Feature Engineering - Essentials for Machine Learning*, New York: Cambridge University Press, 2020.
- [52] J. C. Cepeda y D. G. Colomé, «Benefits of empirical orthogonal functions in pattern recognition applied to vulnerability assessment,» de *2014 IEEE PES Transmission & Distribution Conference and Exposition - Latin America (PES T&D-LA)*, Medellín, 2014.
- [53] Plotly, "Parallel Coordinates Plot in Python," plotly | Graphing Libraries, 2022. [Online]. Available: <https://plotly.com/python/parallel-coordinates-plot/>. [Accessed 17 06 2022].
- [54] scikit-learn, "Manifold learning," scikit learn, [Online]. Available: <https://scikit-learn.org/stable/modules/manifold.html#manifold>. [Accessed 22 junio 2022].
- [55] G. Bonaccorso, A. Fandango and R. Shanmugamani, *Python: Advanced Guide to Artificial Intelligence*, Birmingham: Packt Publishing, 2018.
- [56] J. Sharko, G. Grinstein and K. A. Marx, "Vectorized Radviz and Its Application to Multiple Cluster Datasets," *IEEE Transactions on Visualization and Computer Graphics*, vol. 14, no. 6, pp. 1444 - 1427, 2008.
- [57] D. Andrews, "Plots of High-Dimensional Data," *International Biometric Society*, vol. 28, no. 1, pp. 125-136, 1972.
- [58] S. Shalev-Shwartz and S. Ben, *Understanding Machine Learning - From Theory to Algorithms*, New York: Cambridge University Press, 2014.
- [59] M. Mohri, A. Rostamizadeh and A. Talwalkar, *Foundations of Machine Learning*, London: The MIT Press, 2018.
- [60] S. Badillo, B. Banfai, F. Birzele, L. Hutchinson and B. Steier, "An Introduction to Machine Learning," *Clinical Pharmacology & Therapeutics*, vol. 4, no. 107, 2020.
- [61] S. Shalev-Shwartz and S. Ben-David, "From Theory to Algorithms," in *Understanding Machine Learning*, New York, Cambridge University Press, 2014, pp. 89-112.
- [62] R. Tibshirani, T. Hastie, B. Narasimhan and G. Chu, "Diagnosis of multiple cancer types by shrunken centroids of gene expression," *Proceedings of the National Academy of Sciences*, vol. 99, no. 10, pp. 6567-6572, 2002.
- [63] scikit-optimize, "Scikit-learn hyperparameter search wrapper," scikit-optimize, [Online]. Available: https://scikit-optimize.github.io/stable/auto_examples/sklearn-gridsearchcv-replacement.html. [Accessed 12 mayo 2022].
- [64] scikit learn, "sklearn metrics confusion_matrix," [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.confusion_matrix.html. [Accessed 24 07 2022].
- [65] W. Koehrsen, "A Conceptual Explanation of Bayesian Hyperparameter Optimization for Machine Learning," *Towards Data Science*, [Online]. Available:

<https://towardsdatascience.com/a-conceptual-explanation-of-bayesian-model-based-hyperparameter-optimization-for-machine-learning-b8172278050f>. [Accessed 15 Junio 2022].

- [66] M. Kraus, "Bayesian Optimization for quicker hyperparameter tuning - Something Powerful," VANTAGE AI, [Online]. Available: <https://www.vantage-ai.com/en/blog/bayesian-optimization-for-quicker-hyperparameter-tuning>. [Accessed 26 Julio 2022].
- [67] N. I. Abdul Wahab and A. Mohamed, "Area-Based COI-Referred Rotor Angle Index for Transient Stability Assessment and Control of Power Systems," *Abstract and Applied Analysis*, vol. 2012, no. 1, pp. 1-23, 2012.
- [68] D. Echeverría and J. Cepeda, "Power System Transient Stability Assessment based on Center of Inertia Concept," *Revista Técnica "energía"*, no. 14, pp. 54-63, 2018.
- [69] M. Chamba, W. Vargas and J. Cepeda, "Probabilistic assessment of transient stability considering the uncertainty of the demand and risk management," *Revista Técnica "energía"*, vol. 1, no. 15, pp. 1-10, 2018.
- [70] J. V. Milanović, "Probabilistic stability analysis: the way forward for stability analysis of sustainable power systems," The Royal Society Publishing, Manchester, 2017.
- [71] S. Vaca, "Desarrollo de una herramienta computacional para la simulación de métodos de polarización de la protección de sobrecorriente direccional de líneas de transmisión," Escuela Politécnica Nacional, Quito, 2019.
- [72] F. Chimarro and V. H. Hinojosa, "Análisis y Determinación de Tiempos de Recierre para Líneas del Sistema Nacional de Transmisión del Ecuador en 138kV," *Revista Técnica Energía*, vol. 4, no. 1, pp. 38-48, 2008.
- [73] F. J. Hickernell, S.-C. T. Choi, L. Jiang and L. A. Jiménez Rugama, "Monte Carlo Simulation, Automatic Stopping Criteria For," *Wiley StatsRef: Statistics Reference Online*, vol. 1, no. 1, pp. 1 - 7, 2018.
- [74] J. Cepeda and S. Chamba, "Battery State of Charge Stochastic Model determination for Microgrids Probabilistic Power Flow computation," *Revista Técnica "energía"*, vol. 16, no. 1, pp. 41-50, 2019.
- [75] Y. Sun, . J. Ma, J. Kurths y M. Zhan, «Equal-area criterion in power systems revisited,» *Proceedings of The Royal Society A Mathematical Physical and Engineering Sciences*, pp. 1-31, 2018.
- [76] M. J. Zaki, J. XuYu and V. Pudi, *Advances in Knowledge Discovery and Data Mining*, Hyderabad: Springer, 2010.
- [77] B. Das, N. C. Krishnan and D. J. Cook, "Handling Class Overlap and Imbalance to Detect Prompt Situations in Smart Homes," in *2013 IEEE 13th International Conference on Data Mining Workshops*, Dallas, 2013.

- [78] M. Mohri, A. Rostamizadeh and A. Talwalkar, "Model Selection," in *Foundations of Machine Learning*, London, The MIT Press, 2018.
- [79] J. Zhang and I. Mani, "kNN approach to unbalanced data distributions: a case study involving information extraction," Proceedings of workshop on learning from imbalanced datasets, Washington DC, 2003.
- [80] P. Duboue, «Features, Expanded: Computable Features, Imputation and Kernels,» de *The Art of Feature Engineering - Essentials for Machine Learning*, New York, University Printing House, Cambridge, 2020, pp. 59-79.
- [81] C. Zita, "5 Effective Ways to Improve the Accuracy of Your Machine Learning Models," Towards Data Science, [Online]. Available: <https://towardsdatascience.com/5-effective-ways-to-improve-the-accuracy-of-your-machine-learning-models-f1ea1f2b5d65>. [Accessed 20 Junio 2022].
- [82] scikit-learn, "sklearn metrics - balanced accuracy score," scikit-learn - Machine Learning in Python, [Online]. Available: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.balanced_accuracy_score.html. [Accessed 10 06 2022].
- [83] scikit-optimize, "Scikit-learn hyperparameter search wrapper," [Online]. Available: https://scikit-optimize.github.io/stable/auto_examples/sklearn-gridsearchcv-replacement.html#sphx-glr-auto-examples-sklearn-gridsearchcv-replacement-py. [Accessed 15 abril 2022].
- [84] "IEEE Guide for Protective Relay Applications to Transmission Lines," *IEEE Std C37.113-2015 (Revision of IEEE Std C37.113-1999)*, pp. 1-141, 2016.
- [85] F. E. Pérez Yauli, "Wavelets adaptivas aplicadas a funciones de protección de líneas de transmisión," Universidad Nacional de San Juan, San Juan, 2012.
- [86] F. R. Gomez, A. D. Rajapakse and U. D. Annakkage, "Support Vector Machine-Based Algorithm for Post-Fault Transient Stability Status Prediction Using Synchronized Measurements," *IEEE Transactions on Power Systems*, vol. 26, no. 3, pp. 1474 - 1483, 2011.
- [87] F. Gordillo, "Estabilidad de Sistemas No Lineales Basada en la Teoría de Liapunov," *Revista Iberoamericana de Automática e Informática Industrial*, vol. 6, no. 2, pp. 5-16, 2009.
- [88] K. Marti, *Stochastic Optimization Methods*, Munich: Springer, 2017.
- [89] Imbalanced learn, "imbalanced-learn documentation," [Online]. Available: <https://imbalanced-learn.org/stable/introduction.html>. [Accessed 29 05 2022].

7. ANEXOS

- ANEXO A. EJEMPLO DE APLICACIÓN DEL MÁXIMO EXPONENTE DE LYAPUNOV
- ANEXO B. DATOS DE LOS SISTEMAS DE PRUEBA
- ANEXO C. CURVAS DE DEMANDA DIARIA
- ANEXO D. MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM
- ANEXO E. RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM
- ANEXO F. MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM
- ANEXO G. MÉTRICAS DE EVALUACIÓN PREDICTIVA – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM
- ANEXO H. RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM

ANEXO A. EJEMPLO DE APLICACIÓN DEL MÁXIMO EXPONENTE DE LYAPUNOV

Uno de los sistemas dinámicos caóticos más populares es el sistema del péndulo doble de la Figura A.1 [17]. En este sistema se utiliza la expresión 2.13 para describir su dinámica a través del LLE. Este sistema es caótico, pero estable desde la perspectiva que las trayectorias de ambos péndulos tienden hacia un atractor fijo constituido por el punto de equilibrio del péndulo. Se consideran dos casos: 1) Simulación con coeficiente de rozamiento positivo, lo cual constituye una situación real en el péndulo y se espera un comportamiento estable y 2) Simulación con coeficiente de rozamiento negativo, lo cual es una situación irrealista, que se simula para explorar la propiedad de inestabilidad en este sistema.








Figura A.1 Sistema dinámico de péndulo doble

En la Figura A.2 y Figura A.3 se presentan las simulaciones para cada caso. Se observa que con rozamiento positivo, el sistema se muestra como estable en la evolución dinámica de los ángulos θ_1 y θ_2 . No obstante, el LLE no puede reflejar una condición estable por las fluctuaciones de la serie de tiempo. Aun así, se aprecia que el LLE tiende a reducirse y a presentar un valor negativo, característico de un sistema estable.

Finalmente, se observa que con rozamiento negativo, el sistema es inestable y el LLE tiende a presentar un valor positivo en estado estacionario. De esta manera, se ejemplifica la caracterización del fenómeno de estabilidad a través del uso de series del LLE.



c)

Figura A.2 Dinámica del péndulo doble con coeficiente de rozamiento positivo. a) Simulación gráfica, b) Respuesta dinámica de θ_1 y θ_2 , c) Estimación del LLE

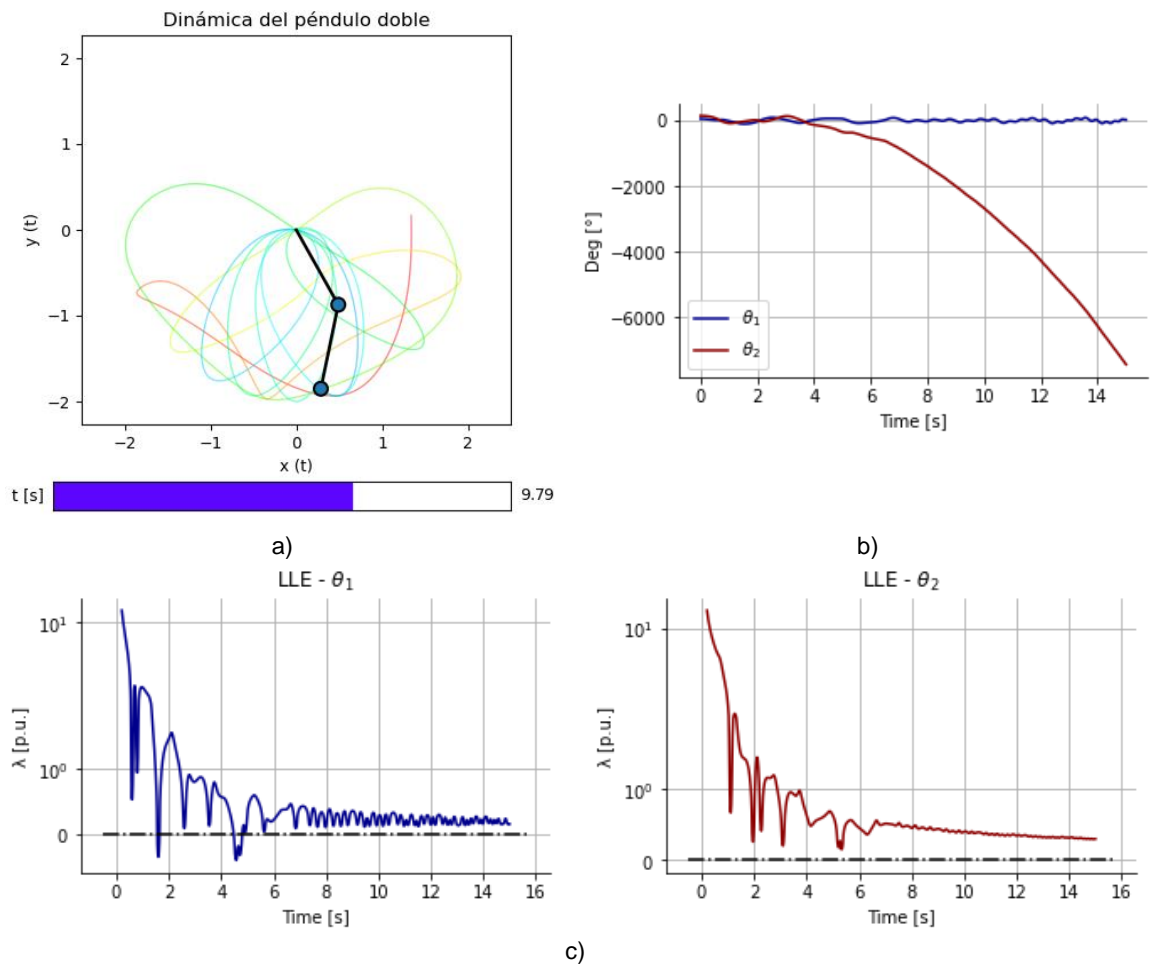


Figura A.3 Dinámica del péndulo doble con coeficiente de rozamiento negativo. a) Simulación gráfica, b) Respuesta dinámica de θ_1 y θ_2 , c) Estimación del LLE

ANEXO B. DATOS DE LOS SISTEMAS DE PRUEBA

A continuación se presentan los datos de los sistemas de prueba IEEE 9-Bus System y IEEE 39-Bus System, los cuales han sido obtenidos de [1].

B.1. Sistema IEEE 9-Bus System

Tabla B.1 Datos de barras

Bus	Tipo	Voltaje(kV)	LOAD				GEN MW
			MW	MVA _r	Tipo	Motor	
01	SL	16.5	-	-	-	-	
02	PV	18	-	-	-	163	
03	PV	13.8	-	-	-	85	
04	PQ	230	-	-	-	-	
05	PQ	230	125	50	I	40%	
06	PQ	230	90	30	C	-	
07	PQ	230	-	-	-	-	
08	PQ	230	100	35	R	-	
09	PQ	230	-	-	-	-	

Tabla B.2 Datos de líneas en por unidad con una base de 100MVA

Bus i	Bus j	Resistencia	Reactancia	Susceptancia
04	06	0.0170	0.0920	0.158
04	05	0.0100	0.0850	0.176
05	07	0.0320	0.1610	0.306
06	09	0.0390	0.1700	0.358
07	08	0.0085	0.0720	0.149
08	09	0.0119	0.1008	0.209

Tabla B.3 Datos de transformadores en por unidad con una base de 100MVA

Bus i	Bus j	Resistencia	Reactancia	Relación de transformación
01	04	0	0.0576	1.0
02	07	0	0.0625	1.0
03	09	0	0.0586	1.0

Tabla B.4 Datos de costos de generación

Generador	c2	c1
01	0.13	5
02	0.085	1.2
03	0.1225	1

*Función de costo: $f(p) = c_2 p^2 + c_1 p$: f (\$/h), p (MW)

Tabla B.5 Datos de generadores

Generador Parámetro	01	02	03
Número de unidades	10	10	10
Potencia nominal (MVA)	24.75	19.20	12.80
Voltaje nominal (kV)	16.5	18.0	13.8
Power Factor	1.0	0.85	0.85
Pmax (MW)	24.75	16.32	10.88
Pmin (MW)	1.50	5	3.50
Qmax (MVAr)	10	8	6
Qmin (MVAr)	-7	-6	-4
H (s)	9.5515	3.3333	2.3516
Ra	0	0	0
Xd	0.36135	1.7199	1.68
Xq	0.23983	1.6598	1.60998
Xd'	0.15048	0.23	0.23206
Xq'	0.23983	0.378	0.32
Xd''	0.10	0.20	0.20
Xq''	0.10	0.20	0.20
Xl	0.08316	0.1	0.09498
Td0' (s)	8.96	6.00	5.89
Tq0' (s)	0	0.535	0.6
Td0'' (s)	0.075	0.0575	0.0575
Tq0'' (s)	0.15	0.0945	0.08
SG10	0.13	0.13	0.13
SG12	0.32	0.32	0.32

B.2. Sistema IEEE 39-Bus System

Tabla B.6 Datos de barras

Bus	Tipo	Voltaje (kV)	LOAD			GEN MW
			MW	MVAr	Tipo	
01	PQ	345	-	-	-	-
02	PQ	345	-	-	-	-
03	PQ	345	322.0	2.4	C	-
04	PQ	345	500.0	184.0	I	40%
05	PQ	345	-	-	-	-
06	PQ	345	-	-	-	-
07	PQ	345	233.8	84.0	C	-
08	PQ	345	522.0	176.0	R	25%
09	PQ	345	-	-	-	-
10	PQ	345	-	-	-	-
11	PQ	345	-	-	-	-
12	PQ	69	7.5	88.0	I	-
13	PQ	345	-	-	-	-
14	PQ	345	-	-	-	-
15	PQ	345	320.0	153.0	C	30%
16	PQ	345	329.0	32.3	R	-
17	PQ	345	-	-	-	-
18	PQ	345	158.0	30.0	R	-
19	PQ	345	-	-	-	-
20	PQ	69	628.0	103.0	R	25%
21	PQ	345	274.0	115.0	C	-
22	PQ	345	-	-	-	-
23	PQ	345	247.5	84.6	I	-
24	PQ	345	308.6	-92.2	I	40%
25	PQ	345	224.0	47.2	R	-
26	PQ	345	139.0	17.0	C	-
27	PQ	345	281.0	75.5	R	-
28	PQ	345	206.0	27.6	R	25%
29	PQ	345	283.5	26.9	I	-
30	PV	13.8	-	-	-	250
31	SL	13.8	9.2	4.6	I	-
32	PV	13.8	-	-	-	650
33	PV	13.8	-	-	-	632
34	PV	13.8	-	-	-	508
35	PV	13.8	-	-	-	650
36	PV	13.8	-	-	-	560
37	PV	13.8	-	-	-	540
38	PV	13.8	-	-	-	830
39	PV	345	1104.	250.0	R	1000

Tabla B.7 Datos de líneas en por unidad con una base de 100MVA

Bus i	Bus j	Resistencia	Reactancia	Susceptancia	Potencia nominal (MVA)
01	02	0.0035	0.0411	0.6987	1,000
01	39	0.0010	0.0250	0.7500	1,000
02	03	0.0013	0.0151	0.2572	1,200
02	25	0.0070	0.0086	0.1460	1,000
03	04	0.0013	0.0213	0.2214	1,000
03	18	0.0011	0.0133	0.2138	1,000
04	05	0.0008	0.0128	0.1342	1,000
04	14	0.0008	0.0129	0.1382	1,000
05	06	0.0002	0.0026	0.0434	1,000
05	08	0.0008	0.0112	0.1476	1,000
06	07	0.0006	0.0092	0.1130	1,000
06	11	0.0007	0.0082	0.1389	1,000
07	08	0.0004	0.0046	0.0780	1,000
08	09	0.0023	0.0363	0.3804	1,000
09	39	0.0010	0.0250	1.2000	1,000
10	11	0.0004	0.0043	0.0729	1,000
10	13	0.0004	0.0043	0.0729	1,000
13	14	0.0009	0.0101	0.1723	1,000
14	15	0.0018	0.0217	0.3660	1,000
15	16	0.0009	0.0094	0.1710	1,200
16	17	0.0007	0.0089	0.1342	1,200
16	19**	0.0032	0.0390	0.1520	1,200
16	21	0.0008	0.0135	0.2548	1,000
16	24	0.0003	0.0059	0.0680	1,000
17	18	0.0007	0.0082	0.1319	1,000
17	27	0.0013	0.0173	0.3216	1,000
21	22	0.0008	0.0140	0.2565	1,200
22	23	0.0006	0.0096	0.1846	1,000
23	24	0.0022	0.0350	0.3610	1,000
25	26	0.0032	0.0323	0.5130	1,000
26	27	0.0014	0.0147	0.2396	1,000
26	28	0.0043	0.0474	0.7802	1,000
26	29	0.0057	0.0625	1.0290	1,000
28	29	0.0014	0.0151	0.2490	1,000

Tabla B.8 Datos de transformadores en por unidad con una base de 100MVA

Bus i	Bus j	Resistencia	Reactancia	Relación de transformación	Potencia nominal (MVA)
02	30	0.0000	0.0181	1.0250	1,000
06	31	0.0000	0.0250	1.0700	1,200
10	32	0.0000	0.0200	1.0700	1,200
12	11	0.0016	0.0435	1.0060	1,000
12	13	0.0016	0.0435	1.0060	1,000
19	20	0.0007	0.0138	1.0600	1,000
19	33	0.0007	0.0142	1.0700	1,000
20	34	0.0009	0.0180	1.0090	1,000
22	35	0.0000	0.0143	1.0250	1,200
23	36	0.0005	0.0272	1.0000	1,000
25	37	0.0006	0.0232	1.0250	1,000
29	38	0.0008	0.0156	1.0250	1,200

Tabla B.9 Datos de costos de generación

Generador	c2	c1
01	0.0042	32.950
02	0.0109	89.702
03	0.0109	89.702
04	0.0019	16.298
05	0.0019	16.298
06	0.0019	16.298
07	0.0019	16.298
08	0.0044	32.956
09	0.0044	32.956
10	0	0

*Función de costo: $f(p) = c_2 p^2 + c_1 p$; f (\$/h), p (MW)

Tabla B.10 Datos de generadores

Generador Parámetro	01	02	03	04	05	06	07	08	09	10
Número de unidades	10	20	20	20	20	20	20	20	20	20
Potencia nominal (MVA)	114.1	49.25	40.75	38.3	32.7	43.1	40.05	37.7	51.75	26.1
Voltaje nominal (kV)	345	13.8	13.8	13.8	13.8	13.8	13.8	13.8	13.8	13.8
Power Factor	0.876	0.964	0.920	0.914	0.917	0.928	0.936	0.928	0.918	0.958
Pmax (MW)	100.0	47.5	37.5	35.0	30.0	40.0	37.5	35.0	47.5	25.0
Pmin (MW)	30.0	7.5	2.5	6.0	7.5	8.0	3.5	5.0	9.0	4.0
Qmax (MVar)	55.0	13.0	16.0	15.5	13.0	16.0	14.0	14.0	20.5	7.5
Qmin (MVar)	-40.0	-10.0	-12.5	-12.5	-10.0	-12.5	-10.0	-10.0	-15.0	-5.0
H (s)	43.82	3.08	4.39	3.73	3.98	4.04	3.30	3.22	3.33	8.05
Ra	0	0	0	0	0	0	0	0	0	0
Xd	0.228	2.906	2.033	2.007	2.747	2.189	2.363	2.187	2.180	0.522
Xq	0.217	2.778	1.932	1.976	2.616	2.077	2.339	2.111	2.122	0.360
Xd'	0.068	0.687	0.433	0.334	0.523	0.431	0.392	0.430	0.590	0.162
Xq'	0.091	1.675	0.714	1.272	1.086	0.702	1.490	0.687	0.608	0.042
Xd''	0.055	0.512	0.310	0.245	0.262	0.302	0.304	0.324	0.445	0.115
Xq''	0.055	0.512	0.310	0.245	0.275	0.302	0.304	0.324	0.445	0.151
XI	0.034	0.345	0.248	0.226	0.229	0.193	0.258	0.211	0.308	0.065
Td0' (s)	7.00	6.56	5.70	5.69	5.40	7.30	5.66	6.70	4.79	10.20
Tq0' (s)	0.70	1.50	1.50	1.50	0.44	0.40	1.50	0.41	1.96	0.00
Td0'' (s)	0.035	0.033	0.029	0.028	0.027	0.037	0.028	0.034	0.024	0.050
Tq0'' (s)	0.035	0.033	0.029	0.028	0.027	0.037	0.028	0.034	0.024	0.090
SG10	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a
SG12	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a	n/a

ANEXO C. CURVAS DE DEMANDA DIARIA

Las curvas de demanda diaria se definen para tres tipos de consumidores: Residencial, Comercial e Industrial y están basadas en las curvas típicas propuestas en [1].




Figura C.1 Curvas de demanda diaria en porcentaje del valor máximo

Tabla C.1 Datos de demanda diaria en porcentaje del valor máximo

Hora	Residencial	Comercial	Industrial
1	30	20	55.5
2	27	19	53
3	24.5	18.5	51.5
4	22	18	50
5	20	20	55
6	30	22	58
7	40	25	70
8	53	40	80
9	54	60	90
10	55	86	98
11	56	90	100
12	60	92	94
13	55.5	89	95
14	50	93	96
15	48	94.5	90
16	50	96	83
17	70	100	78
18	91	88	72
19	100	75	71
20	96	73	70
21	90	65	68
22	80	50	66.5
23	60	28	65
24	45	22	60

ANEXO D. MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM

En este apartado se presentan los resultados de la aplicación de las siguientes técnicas de Minería de Datos sobre las series de tiempo del ángulo del rotor. Para este caso, se debe considerar que la ventana de tiempo de análisis abarca un número de 19 muestras del ángulo del rotor en su dinámica poscontingencia. Es decir, cuatro muestras más que las 15 muestras necesarias para la estimación del LLE correspondiente (ver sección 3.2.2).

- Funciones Empíricas Ortogonales.
- Ingeniería de Características.
- Visualización de Datos.
- Equilibrio de Clases.
- Correlación de Información.

D.1. Funciones Empíricas Ortogonales




Figura D.1 Funciones Empíricas Ortogonales obtenidas para las series de tiempo del ángulo del rotor del generador G2




Figura D.2 Funciones Empíricas Ortogonales obtenidas para las series de tiempo del ángulo del rotor del generador G3

En la Figura D.3 se exponen las DVR obtenidas con el espacio vectorial {EOF1, EOF2, EOF3} para los generadores G2 y G3. En este resultado se aprecia que los eventos inestables no ocupan una región altamente concentrada del espacio vectorial indicado. Además, se presenta solapamiento entre eventos estables e inestables.

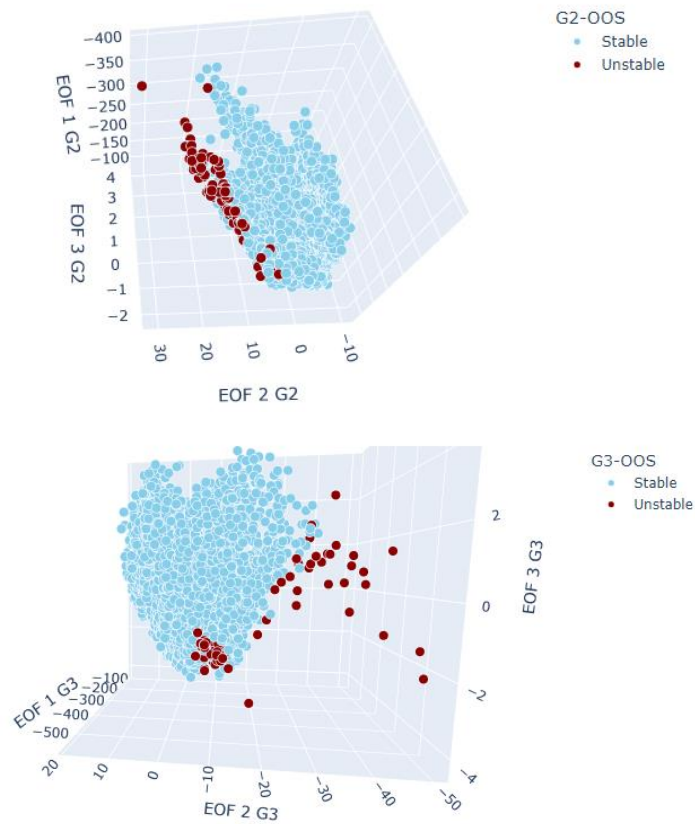



Figura D.3 Representación tridimensional de las DVR formadas con el espacio vectorial {EOF1, EOF2, EOF3} del ángulo del rotor para los generadores G2 y G3


D.2. Ingeniería de Características

En la Figura D.4 y la Figura D.5 se ilustra la variabilidad explicada de las 19 EOF obtenidas. En el diagrama de codo (Elbow plot) mostrado, se identifica que el punto de inflexión del codo de la curva de valores singulares se forma a partir de 2 a 3 EOF. En este sentido, el análisis gráfico de extracción de características sugiere el uso de al menos 2 EOF. Se considerará, con la finalidad de mantener una mayor precisión en los resultados y una visualización tridimensional de las DVR, el uso de las 3 primeras EOF. Se observa que las 3 primeras EOF permiten alcanzar una variabilidad explicada superior al 99.9%.



Nro. EOF	Variabilidad Explicada (%EV)
1	96.088784
2	99.414053
3	99.977035
4	99.997412
5	99.999867
6	99.999991
7	99.999999
8	100.000000
9	100.000000
10	100.000000
11	100.000000
12	100.000000
13	100.000000
14	100.000000
15	100.000000
16	100.000000
17	100.000000
18	100.000000
19	100.000000

Figura D.4 Variabilidad Explicada de las EOF para el generador G2



Nro. EOF	Variabilidad Explicada (%EV)
1	95.402087
2	99.211789
3	99.953289
4	99.995124
5	99.999678
6	99.999971
7	99.999997
8	100.000000
9	100.000000
10	100.000000
11	100.000000
12	100.000000
13	100.000000
14	100.000000
15	100.000000
16	100.000000
17	100.000000
18	100.000000
19	100.000000

Figura D.5 Variabilidad Explicada de las EOF para el generador G3

En la Figura D.6 se muestra un ejemplo de reconstrucción de una señal original aleatoria del ángulo del rotor considerando solamente las 3 primeras EOF en el generador G3. Se evidencia que existe una aproximación casi total a la señal original con una ligera pérdida de información.





Figura D.6 Ejemplo de reconstrucción de una serie de tiempo del Ángulo del rotor del generador G3 considerando las 3 primeras EOF

D.3. Visualización de Datos

D.3.1. Visualización de Coordenadas Paralelas

En la Figura D.7 y la Figura D.8 se presenta el gráfico correspondiente al estudio desarrollado, en donde se trazan las coordenadas paralelas de las EOF scores obtenidas para los generadores G2 y G3.

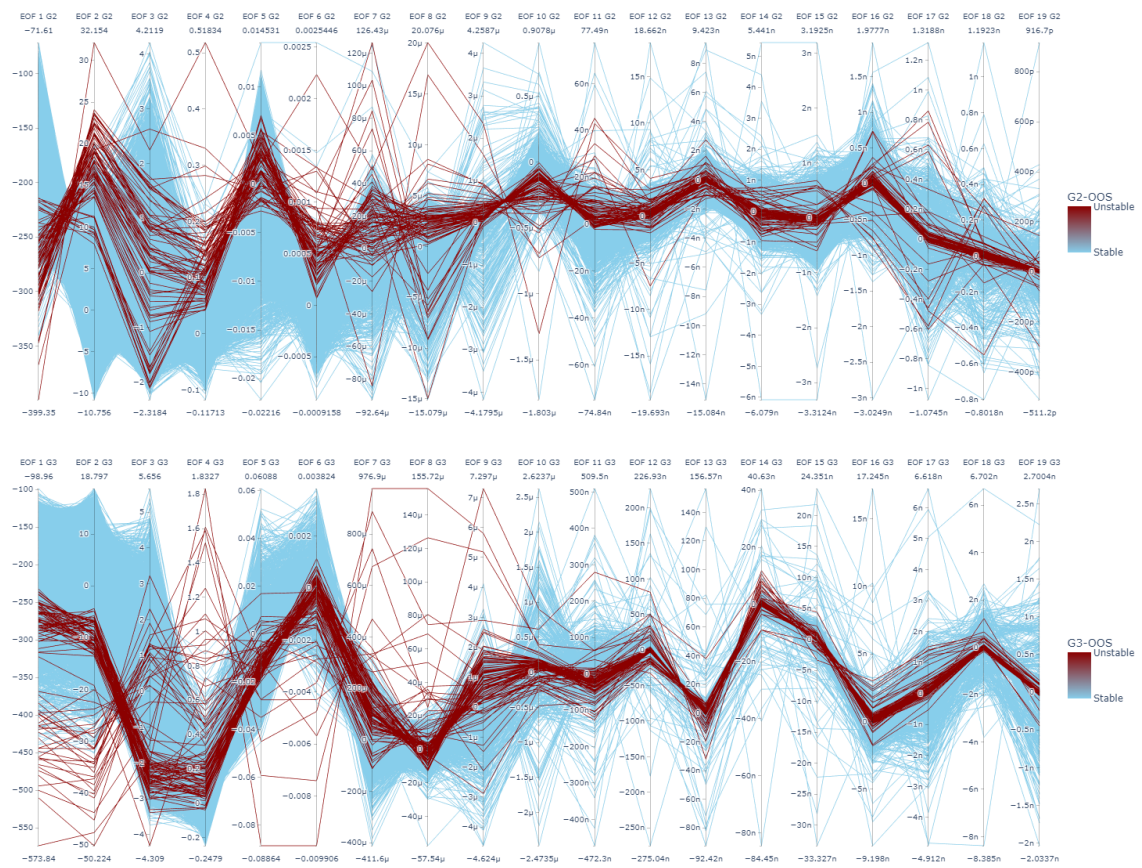



Figura D.7 Ilustración de Coordenadas Paralelas de las 19 EOF scores obtenidas para los generadores G2 y G3







Figura D.8 Ilustración de Coordenadas Paralelas de las 3 primeras EOF scores obtenidas para los generadores G2 y G3

Se observa que las EOF scores de eventos inestables no se concentran en una región reducida del espacio vectorial, como si ocurre con las EOF scores del LLE.

D.3.2. Visualización de las Curvas de Andrews

En la Figura D.9 y la Figura D.10 se observan las Curvas de Andrews construidas a partir de 3 y 19 EOF scores, es decir, las curvas desarrolladas a partir de 3 y 19 términos respectivamente.






Figura D.9 Ilustración de las Curvas de Andrews formadas a partir de las 3 primeras EOF scores obtenidas para los generadores G2 y G3 (EOF scores normalizadas entre 0 y 1)






Figura D.10 Ilustración de las Curvas de Andrews formadas a partir de las 19 EOF scores obtenidas para los generadores G2 y G3 (EOF scores normalizadas entre 0 y 1)

En estas curvas puede identificarse que no existe una concentración de los eventos inestables en una región espacial pequeña, como ocurre con las EOF scores del LLE.

D.3.3. Visualización Multidimensional del Algoritmo de RadViz

En la Figura D.11 se expone la representación de RadViz para la matriz de datos analizada. En esta visualización se identifica con más claridad que los eventos inestables no se localizan en una región altamente concentrada definida por el espacio vectorial de las 19 EOF scores, como si ocurre en el caso de las EOF scores del LLE. Además, se observa que existe solapamiento entre eventos estables e inestables.






Figura D.11 Representación tridimensional y bidimensional del espacio vectorial compuesto por las 19 EOF scores del ángulo del rotor obtenidas para los generadores G2 y G3

D.3.4. Equilibrio de Clases

En la Figura D.12 y la Figura D.13 se observa una comparativa del resultado obtenido con la aplicación del algoritmo de submuestreo en las EOF scores de cada generador.




Figura D.12 Aplicación del algoritmo NearMiss version 3 en EOF scores del generador G2. Nro. observaciones iniciales: {Estable: 9921, Inestable: 79}




Figura D.13 Aplicación del algoritmo NearMiss version 3 en EOF scores del generador G2. Nro. observaciones iniciales: {Estable: 9903, Inestable: 97}

Luego de aplicar la técnica de submuestreo se observa con mayor claridad el solapamiento entre las observaciones estables e inestables. Esta es una situación existente también para las EOF scores del LLE.

D.3.5. Correlación de Información

En la Figura D.14 se expone la matriz de correlación obtenida considerando como características las EOF scores obtenidas en el presente análisis. Como se observa que en general las correlaciones son relativamente bajas, no es posible considerar que existe una alta dependencia lineal entre las EOF scores. De este modo, no se tiene evidencia suficiente para omitir a alguna EOF del análisis.




Figura D.14 Matriz de correlación obtenida considerando como características las EOF scores obtenidas en el sistema de prueba IEEE 9-Bus System

ANEXO E. RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 9-BUS SYSTEM

E.1. Resultados en el Generador G2




Figura E.1 Resultado de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2




Figura E.2 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

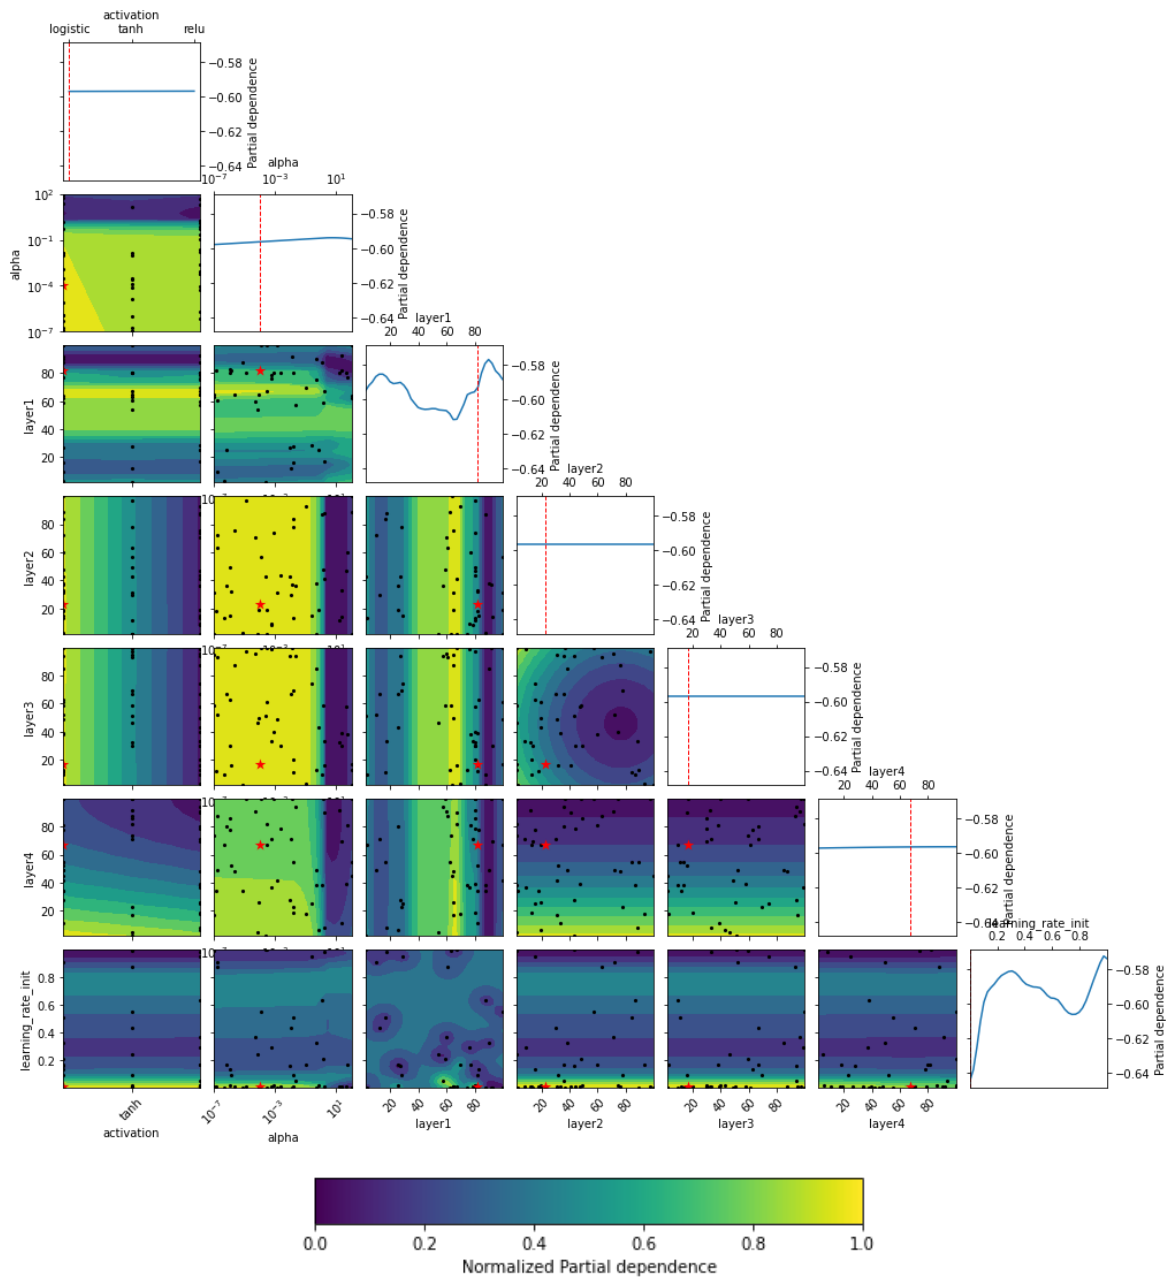


Figura E.3 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2




Figura E.4 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G2

- Optimización Bayesiana SVC-StWe**
- Best balanced_accuracy (Training CV) = 0.9923
 - balanced_accuracy (Testing) = 0.9935
 - balanced_accuracy (CV) = 0.9930
 - Best Parameters:
 - ('C', 13.7835)
 - ('gamma', 0.008914)




Figura E.5 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G2




Figura E.6 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G2




Figura E.7 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G2




Figura E.8 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G2




Figura E.9 Resultado de Optimización Bayesiana en el algoritmo NSC-Nor generador G2




Figura E.10 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G2




Figura E.11 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G2




Figura E.12 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G2

- Optimización Bayesiana RFC-Res**
- Best balanced_accuracy (Training CV) = 0.7155
 - balanced_accuracy (Testing) = 0.8375
 - balanced_accuracy (CV) = 0.8086
 - Best Parameters:
 - ('bootstrap', True)
 - ('criterion', entropy)
 - ('max_depth', 10)
 - ('min_samples_leaf', 2)
 - ('min_samples_split', 2)
 - ('n_estimators', 100)




Figura E.13 Resultado de Optimización Bayesiana en el algoritmo RFC-Res generador G2

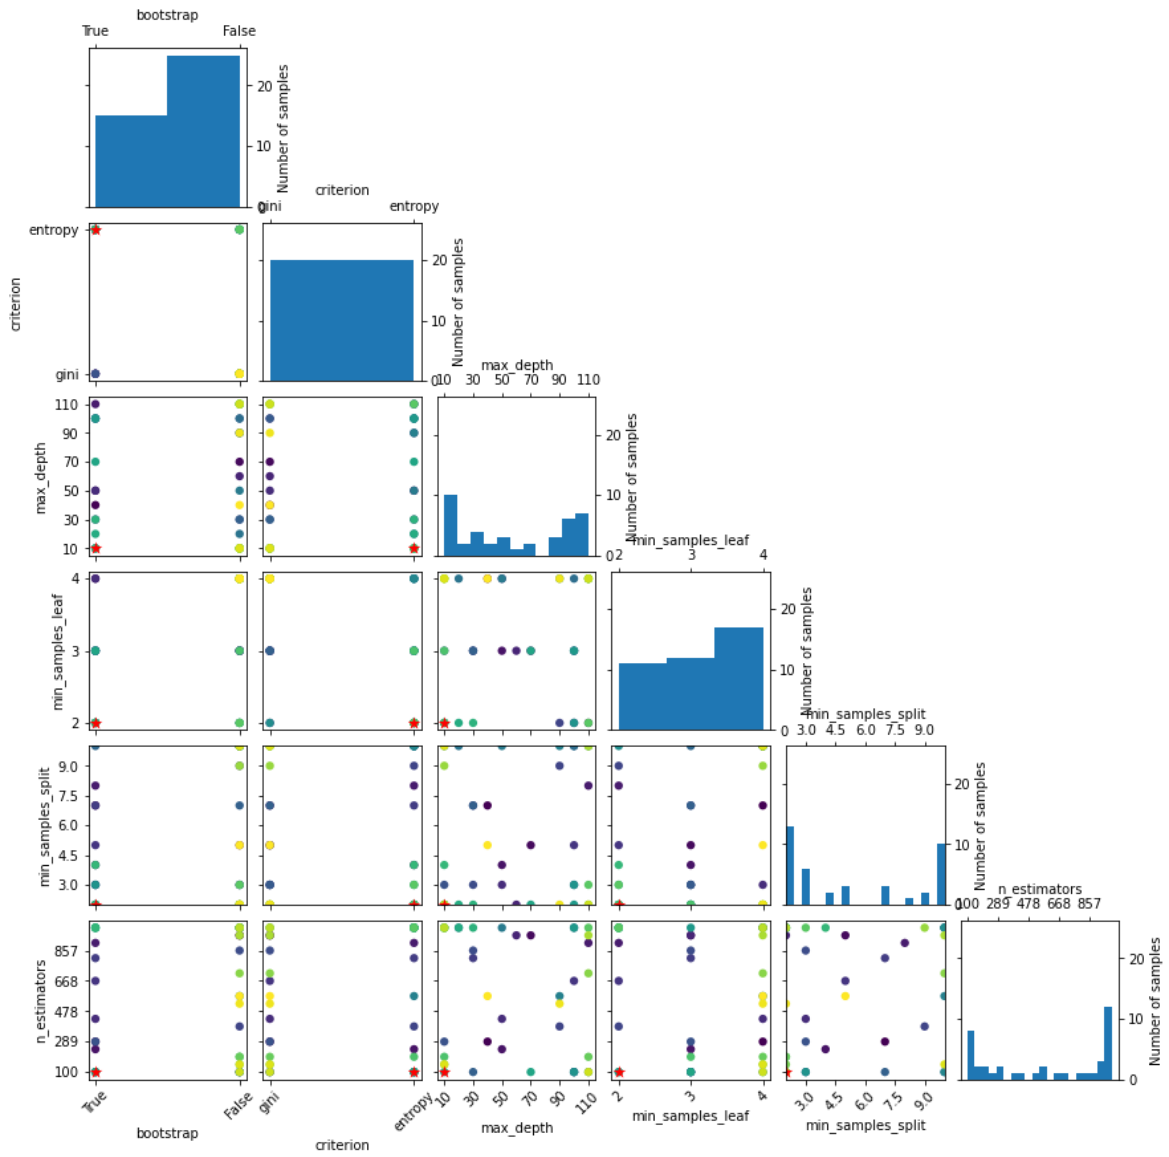


Figura E.14 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Res generador G2




Figura E.15 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Res generador G2




Figura E.16 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Res generador G2

E.2. Resultados en el Generador G3

Optimización Bayesiana MLPC-Res

- Best balanced_accuracy (Training CV) = 0.8071
- balanced_accuracy (Testing) = 0.8135
- balanced_accuracy (CV) = 0.8280
- Best Parameters:
 - ('activation', ' tanh')
 - ('alpha', 3.6842e-05)
 - ('layer1', 94)
 - ('layer2', 100)
 - ('layer3', 75)
 - ('layer4', 79)
 - ('learning_rate_init', 0.0001)




Figura E.17 Resultado de Optimización Bayesiana en el algoritmo MLPC-Res generador G3




Figura E.18 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Res generador G3




Figura E.19 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Res generador G3




Figura E.20 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Res generador G3




Figura E.21 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G3




Figura E.22 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G3

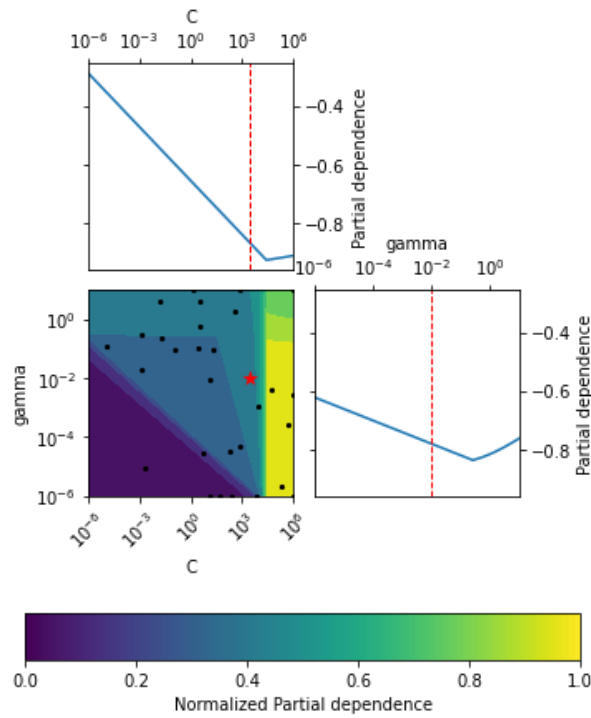


Figura E.23 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G3




Figura E.24 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G3




Figura E.25 Resultado de Optimización Bayesiana en el algoritmo NSC-Nor generador G3




Figura E.26 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G3




Figura E.27 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G3




Figura E.28 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G3




Figura E.29 Resultado de Optimización Bayesiana en el algoritmo RFC-Res generador G3

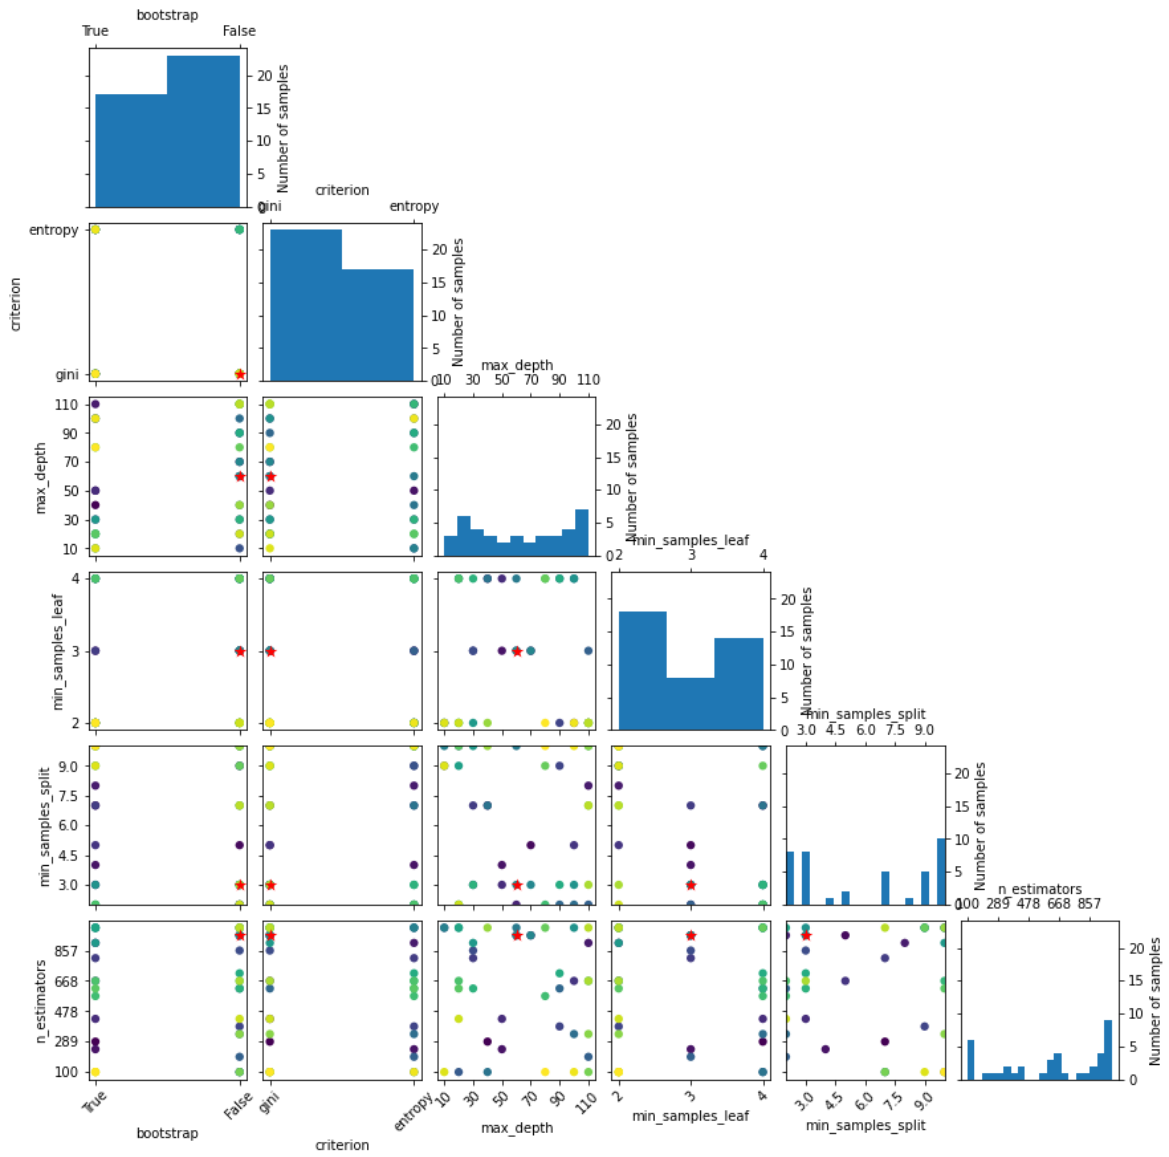


Figura E.30 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC -Res generador G3

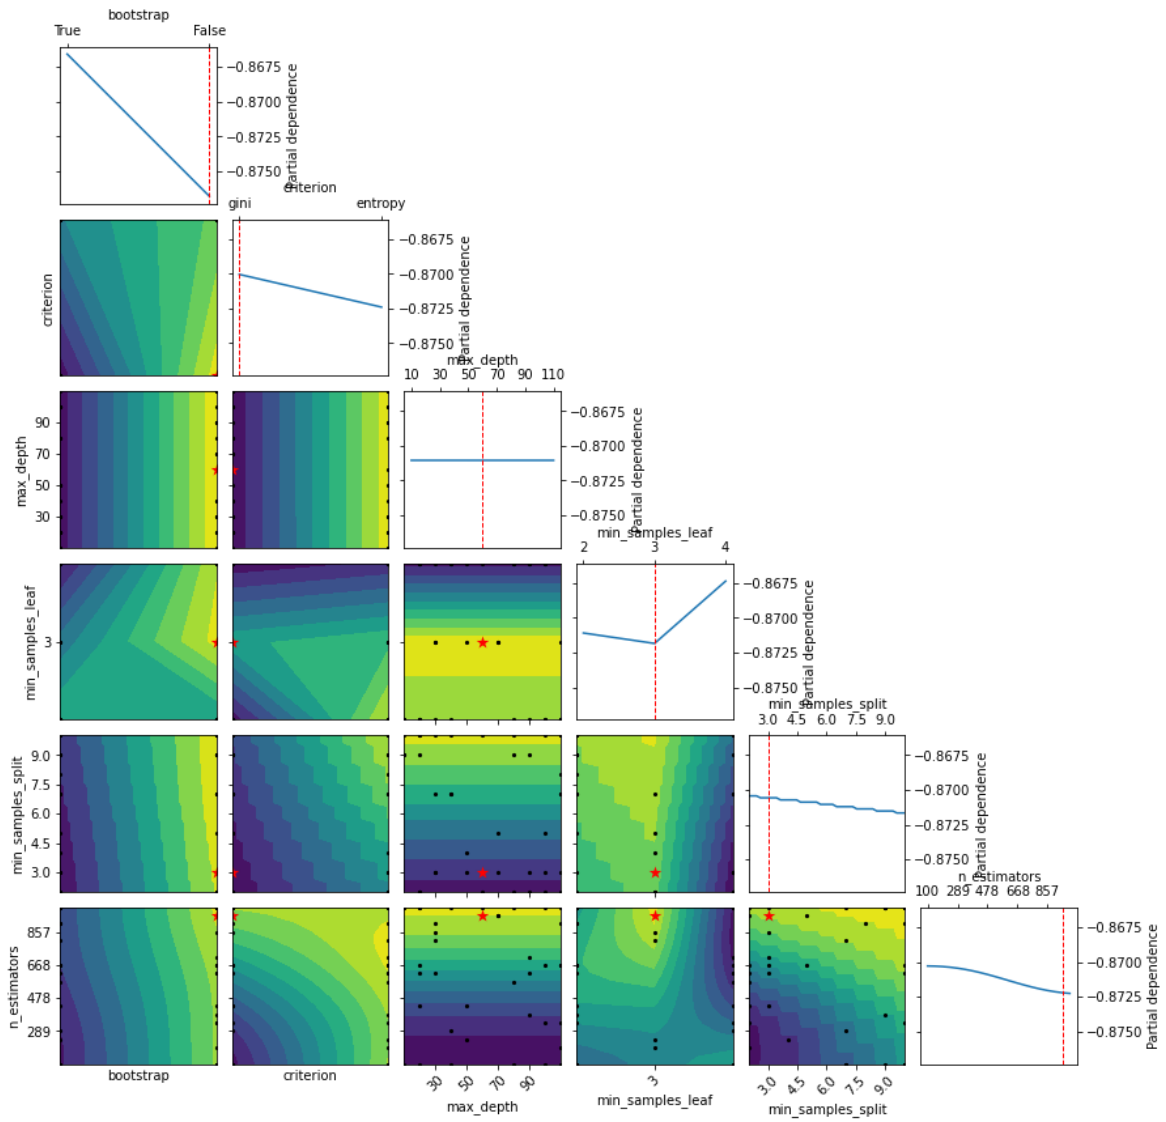


Figura E.31 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC -Res generador G3




Figura E.32 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC -Res generador G3

E.3. Resultados globales




Figura E.33 Resultado de Optimización Bayesiana en el algoritmo MLPC-Res




Figura E.34 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Res

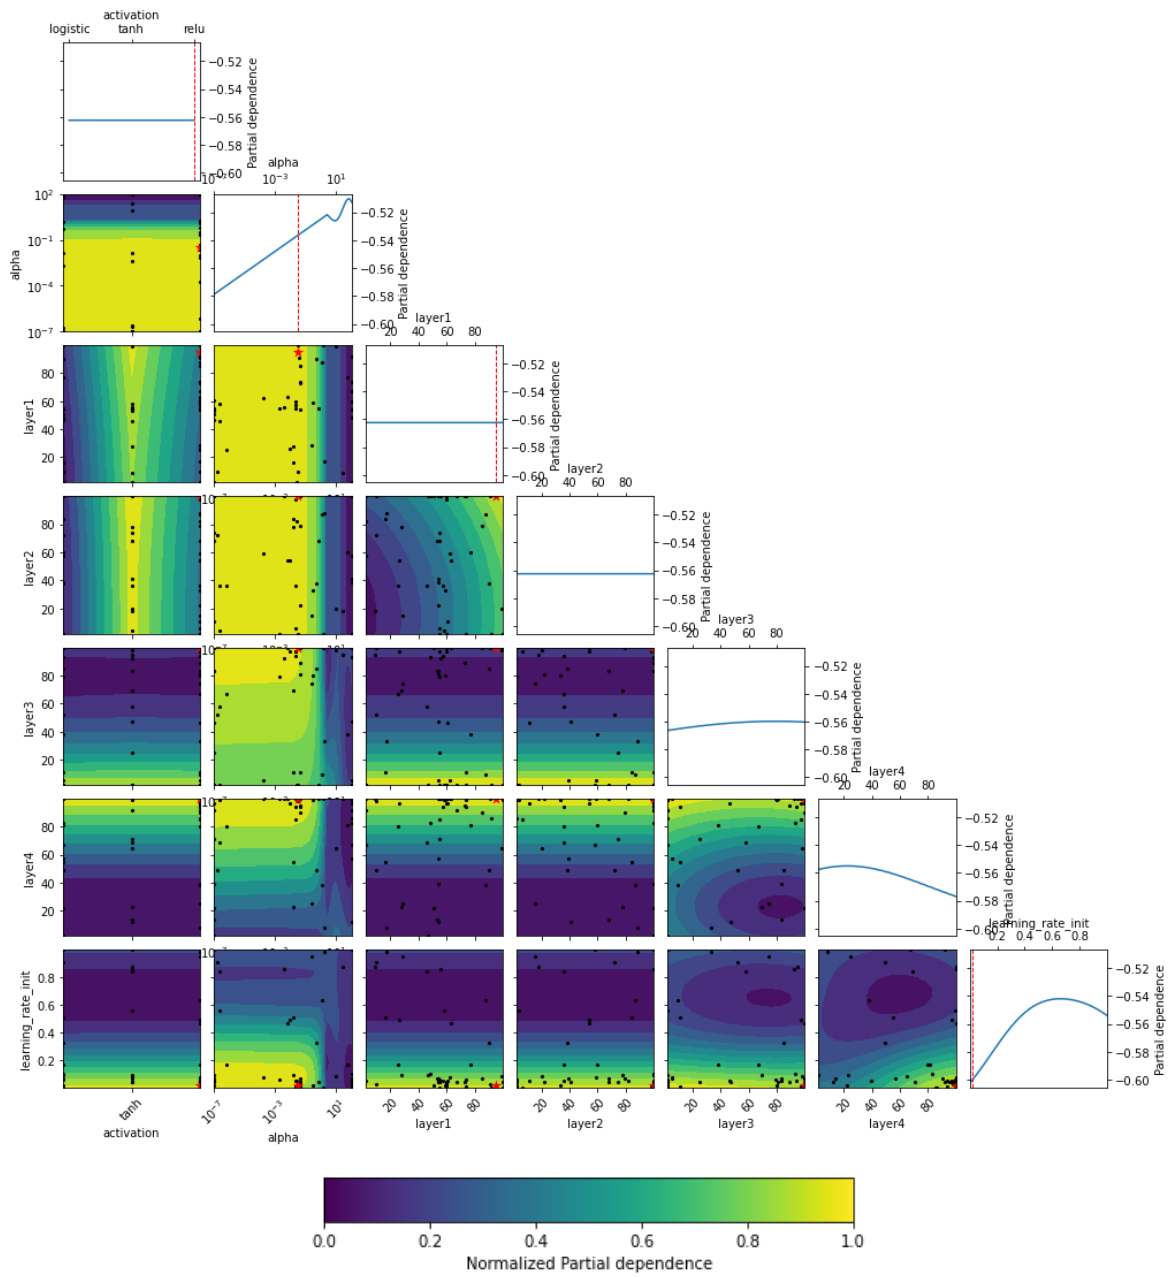


Figura E.35 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLP-Res




Figura E.36 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Res




Figura E.37 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe




Figura E.38 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe

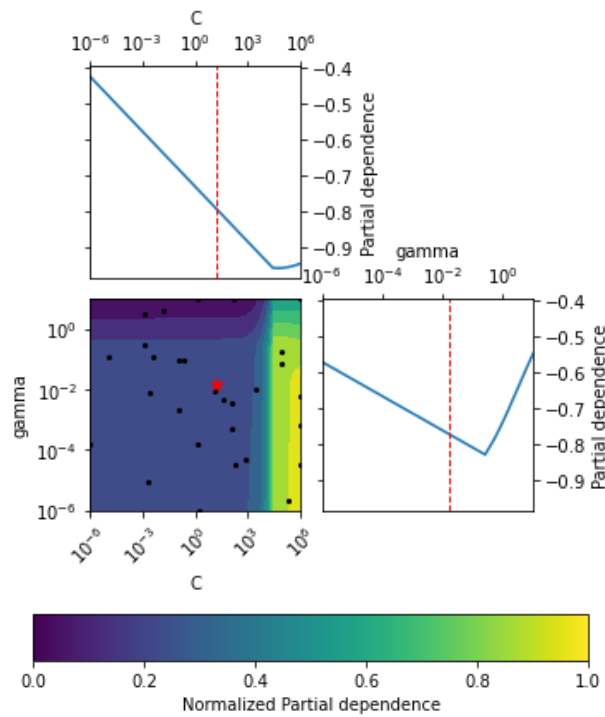


Figura E.39 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe




Figura E.40 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe




Figura E.41 Resultado de Optimización Bayesiana en el algoritmo NSC-Nor




Figura E.42 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Nor

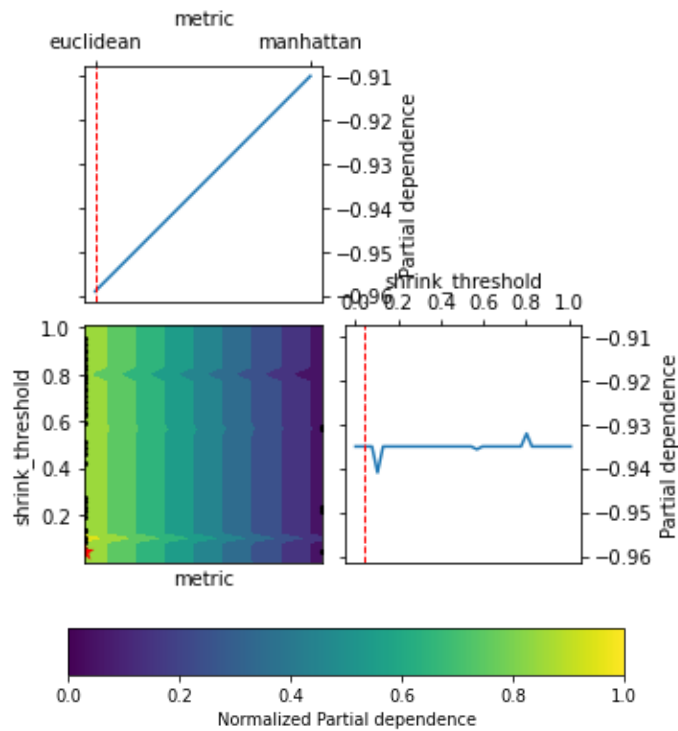


Figura E.43 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Nor




Figura E.44 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Nor




Figura E.45 Resultado de Optimización Bayesiana en el algoritmo RFC-Res

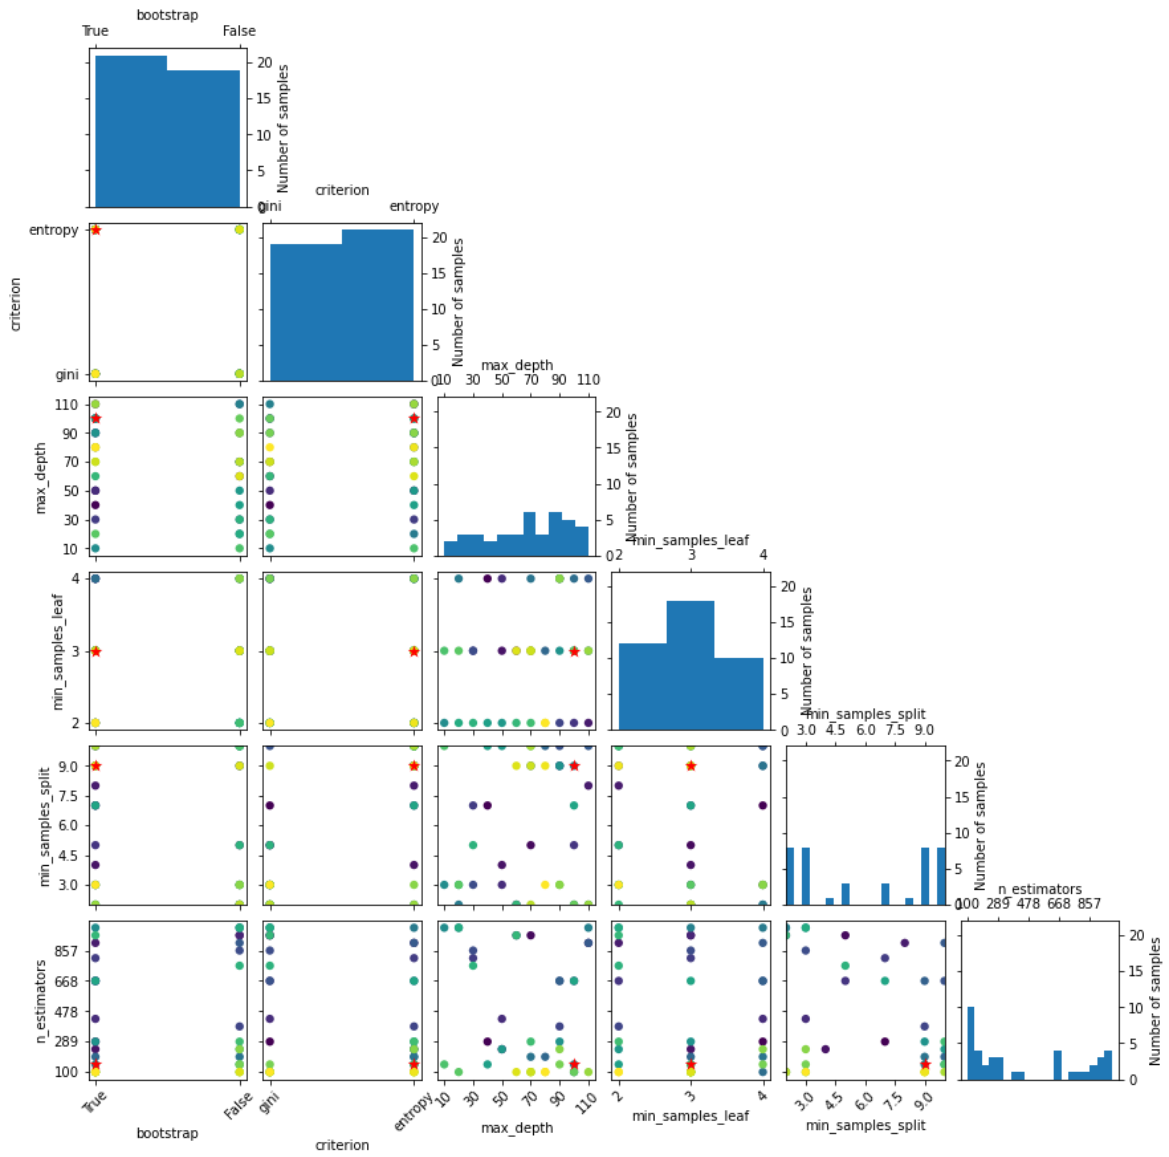


Figura E.46 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Res

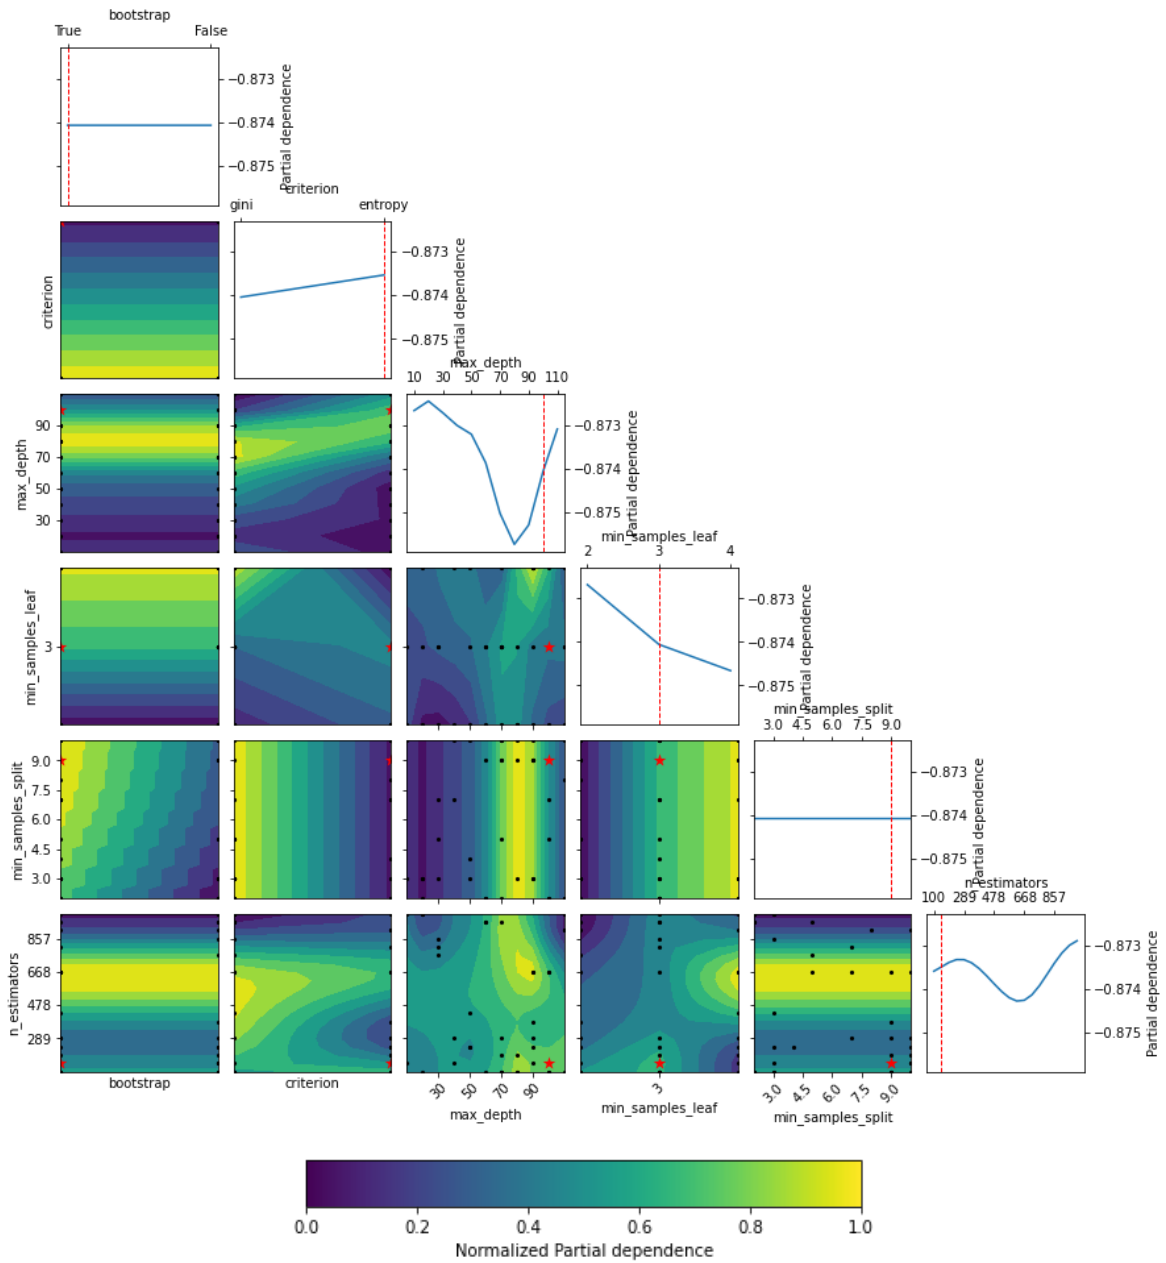


Figura E.47 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Res





Figura E.48 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Res


ANEXO F. MINERÍA DE DATOS DEL ÁNGULO DEL ROTOR – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM

En este anexo se presentan los resultados de la aplicación de técnicas de Minería de Datos sobre las series de tiempo del ángulo del rotor para el sistema de prueba IEEE 39-Bus System. Para este caso, se debe considerar que la ventana de tiempo de análisis abarca un número de 19 muestras del ángulo del rotor en su dinámica poscontingencia. Es decir, cuatro muestras más que las 15 muestras necesarias para la estimación del LLE correspondiente.


F.1. Funciones Empíricas Ortogonales




a) Generador G 04



b) Generador G 05



c) Generador G 06



d) Generador G 07


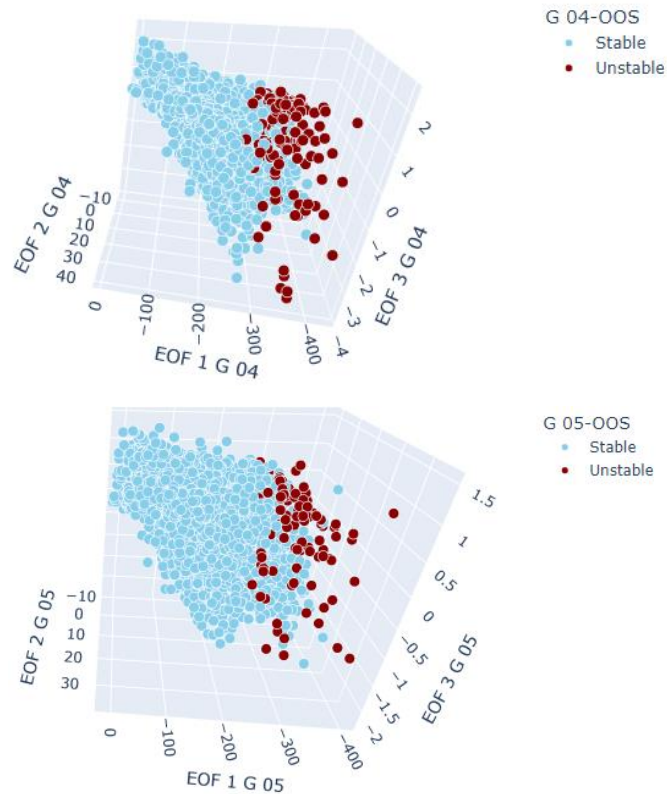


Figura F.1 Funciones Empíricas Ortogonales obtenidas para las series de tiempo del ángulo del rotor

En la Figura F.2 se exponen las DVR obtenidas con el espacio vectorial {EOF1, EOF2, EOF3} para el conjunto de generadores críticos. En este resultado se aprecia que los eventos inestables no ocupan una región altamente concentrada del espacio vectorial indicado. Además, se presenta solapamiento entre eventos estables e inestables.






Figura F.2 Representación tridimensional de las DVR formadas con el espacio vectorial {EOF1, EOF2, EOF3} del ángulo del rotor

F.2. Ingeniería de Características

En la Figura F.3 se ilustra la variabilidad explicada de las 19 EOF obtenidas. En el diagrama de codo (Elbow plot) mostrado, se identifica que el punto de inflexión del codo de la curva de valores singulares se forma a partir de 2 a 3 EOF. En este sentido, el análisis gráfico de extracción de características sugiere el uso de al menos 2 EOF. Se considerará, con la finalidad de mantener una mayor precisión en los resultados y una visualización

tridimensional de las DVR, el uso de las 3 primeras EOF. Se observa que las 3 primeras EOF permiten alcanzar una variabilidad explicada superior al 99.9%.




Figura F.3 Variabilidad Explicada de las EOF scores del ángulo del rotor

F.3. Visualización de Datos

F.3.1. Visualización de Coordenadas Paralelas

En la Figura F.4 se presenta el gráfico correspondiente al sistema IEEE 39-Bus System, en donde se trazan las coordenadas paralelas de las EOF scores obtenidas para el conjunto de generadores críticos.

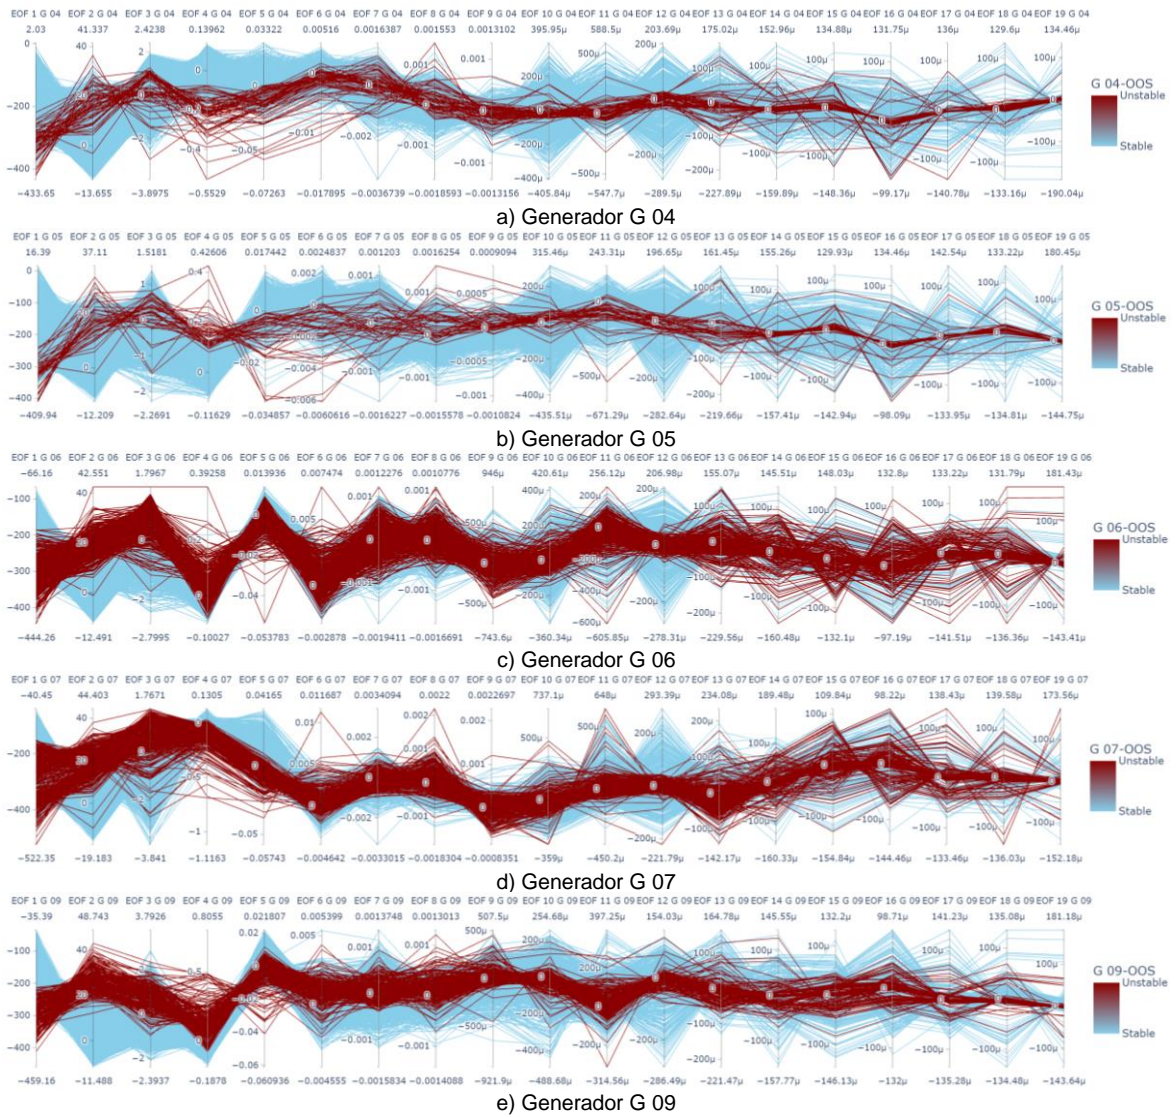


Figura F.4 Ilustración de Coordenadas Paralelas de las 19 EOF scores obtenidas para el conjunto de generadores críticos

Se observa que las EOF scores de eventos inestables no se concentran en una región reducida del espacio vectorial, como si ocurre con las EOF scores del LLE.

F.3.2. Visualización de las Curvas de Andrews

En la Figura F.5 se observan las Curvas de Andrews construidas a partir de 19 EOF scores, es decir, las curvas desarrolladas a partir de 19 términos.

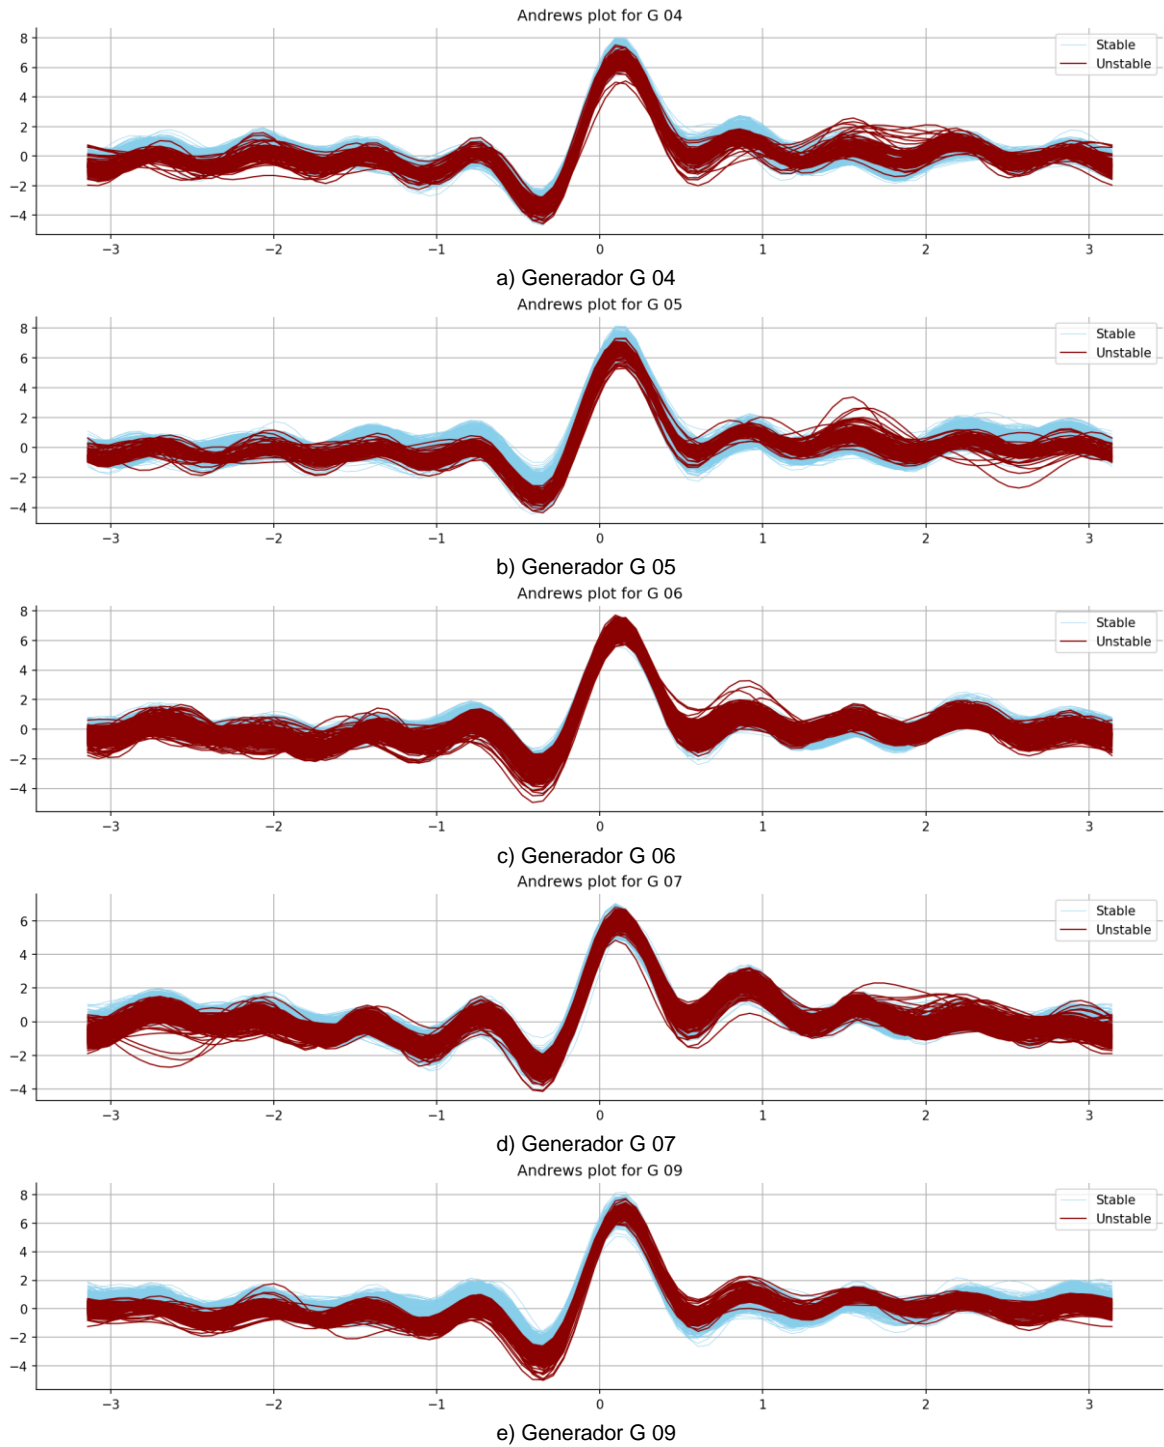


Figura F.5 Ilustración de las Curvas de Andrews formadas a partir de las 19 EOF scores obtenidas para generadores críticos (EOF scores normalizadas entre 0 y 1)

En estas curvas puede identificarse que no existe una concentración de los eventos inestables en una región espacial pequeña, como ocurre con las EOF scores del LLE.

F.3.3. Visualización Multidimensional del Algoritmo de RadViz

En la Figura F.6 se expone la representación de RadViz para la matriz de datos analizada. En esta visualización se identifica con más claridad que los eventos inestables no se localizan en una región altamente concentrada definida por el espacio vectorial de las 19 EOF scores, como si ocurre en el caso de las EOF scores del LLE. Además, se observa que existe solapamiento entre eventos estables e inestables.

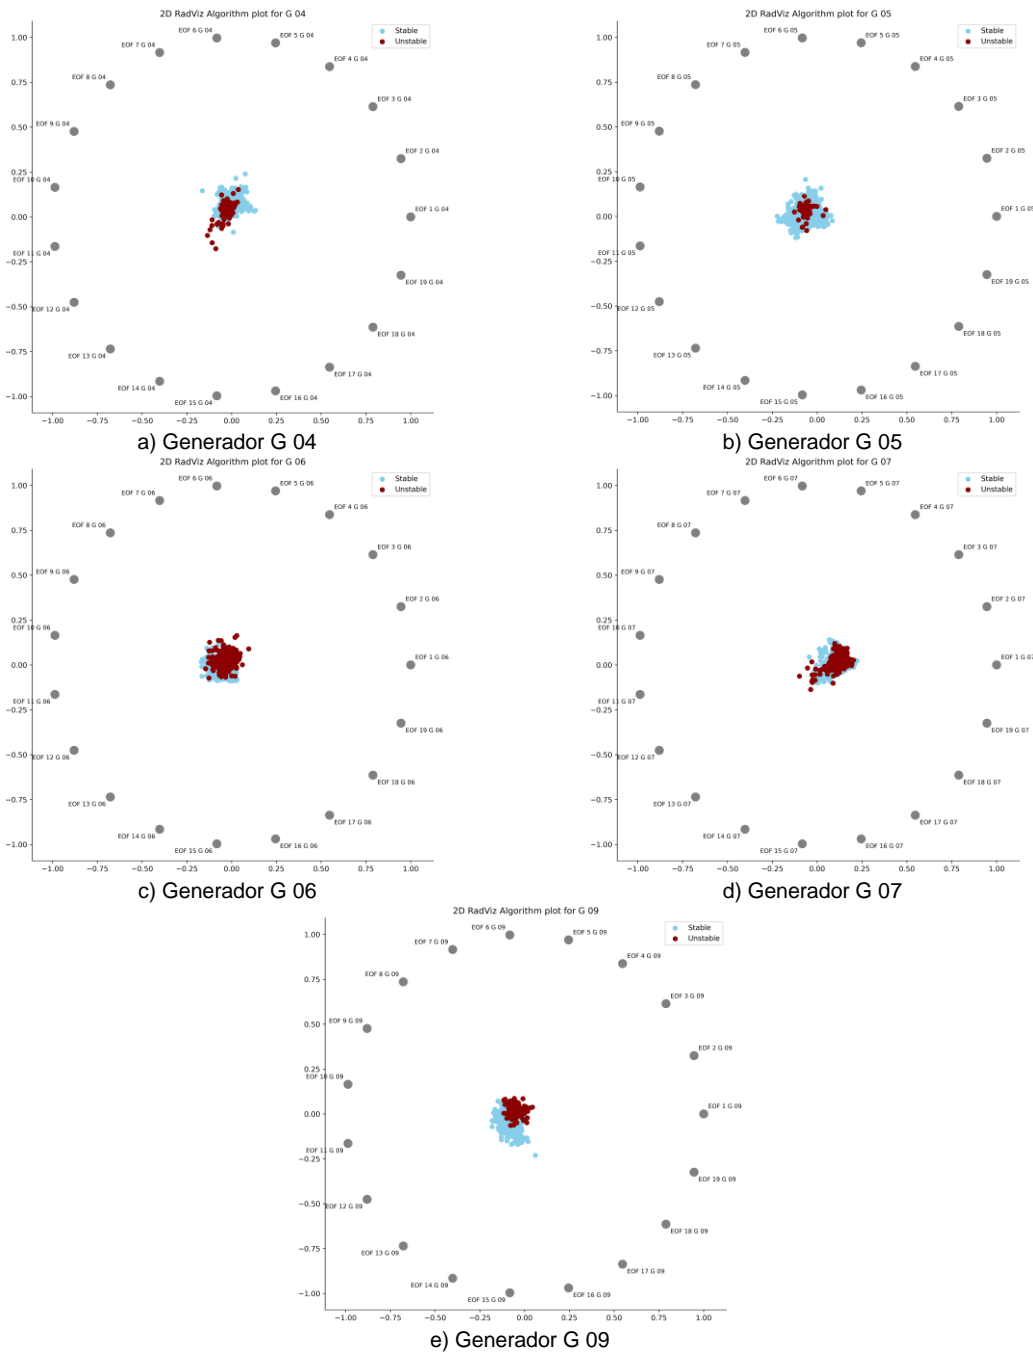


Figura F.6 Representación bidimensional del espacio vectorial compuesto por las 19 EOF scores del ángulo del rotor obtenidas para generadores críticos

F.3.4. Equilibrio de Clases

En la Figura F.7 se observa una comparativa del resultado obtenido con la aplicación del algoritmo de submuestreo en las EOF scores de cada generador.

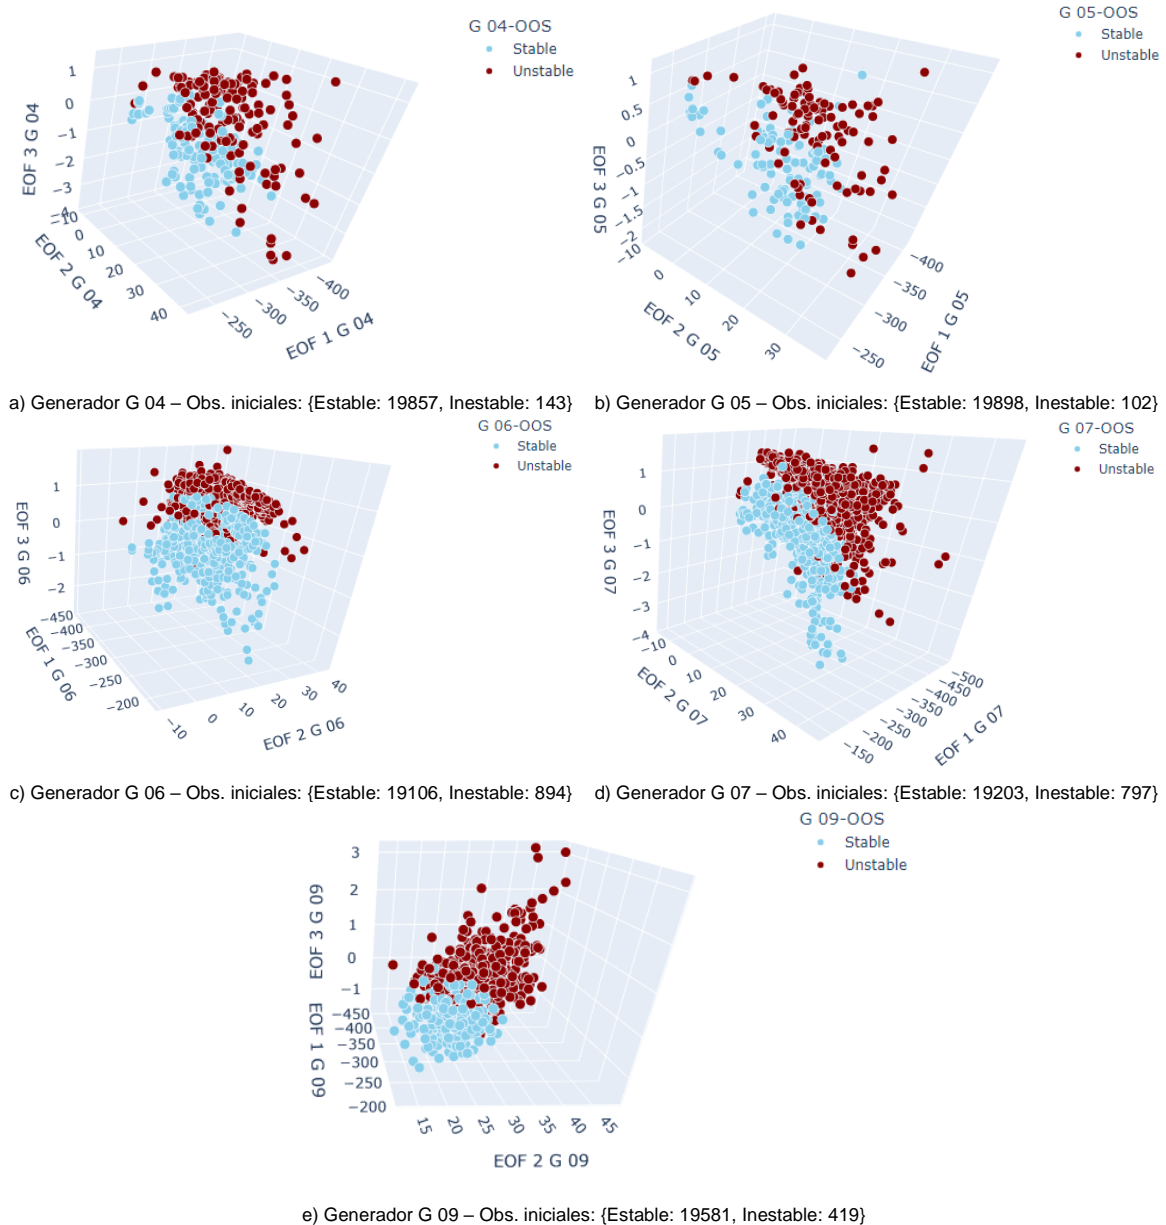


Figura F.7 Aplicación del algoritmo NearMiss version 3 en EOF scores de generadores críticos

Luego de aplicar la técnica de submuestreo se observa con mayor claridad el solapamiento entre las observaciones estables e inestables. Esta es una situación existente también para las EOF scores del LLE.

F.3.5. Correlación de Información

En la Figura F.8 se expone la matriz de correlación obtenida considerando como características las EOF scores obtenidas en el presente análisis. Como se observa que en general las correlaciones son relativamente bajas, no es posible considerar que existe una alta dependencia lineal entre las EOF scores. De este modo, no se tiene evidencia suficiente para omitir a alguna EOF del análisis.




Figura F.8 Matriz de correlación obtenida para el sistema de prueba IEEE 39-Bus System

ANEXO G. MÉTRICAS DE EVALUACIÓN PREDICTIVA – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM

En este apartado se incluyen los resultados de evaluación predictiva de Estabilidad Transitoria obtenidos del Sistema de Prueba IEEE 39-Bus System.

G.1. Métricas de desempeño en el generador G 04




Figura G.1 Resultado de la métrica *recall* – eventos estables




Figura G.2 Resultado de la métrica *recall* – eventos inestables




Figura G.3 Resultado de la métrica *balanced accuracy*

G.2. Métricas de desempeño en el generador G 05




Figura G.4 Resultado de la métrica *recall* – eventos estables




Figura G.5 Resultado de la métrica *recall* – eventos inestables




Figura G.6 Resultado de la métrica *balanced accuracy*

G.3. Métricas de desempeño en el generador G 06




Figura G.7 Resultado de la métrica *recall* – eventos estables




Figura G.8 Resultado de la métrica *recall* – eventos inestables




Figura G.9 Resultado de la métrica *balanced accuracy*

G.4. Métricas de desempeño en el generador G 07




Figura G.10 Resultado de la métrica *recall* – eventos estables




Figura G.11 Resultado de la métrica *recall* – eventos inestables




Figura G.12 Resultado de la métrica *balanced accuracy*

G.5. Métricas de desempeño en el generador G 09




Figura G.13 Resultado de la métrica *recall* – eventos estables




Figura G.14 Resultado de la métrica *recall* – eventos inestables




Figura G.15 Resultado de la métrica *balanced accuracy*

G.6. Métricas de desempeño globales




Figura G.16 Resultado de la métrica *recall* – eventos estables




Figura G.17 Resultado de la métrica *recall* – eventos inestables




Figura G.18 Resultado de la métrica *balanced accuracy*

ANEXO H. RESULTADOS DE APRENDIZAJE AUTOMÁTICO – SISTEMA DE PRUEBA IEEE 39-BUS SYSTEM

H.1. Resultados en el Generador G 04




Figura H.1 Resultado de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 04




Figura H.2 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLP-C-Sta generador G 04




Figura H.3 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 04




Figura H.4 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 04




Figura H.5 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G 04




Figura H.6 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 04

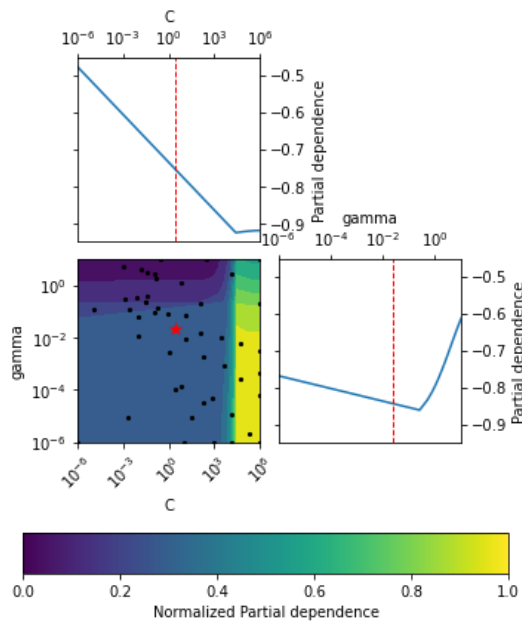


Figura H.7 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 04

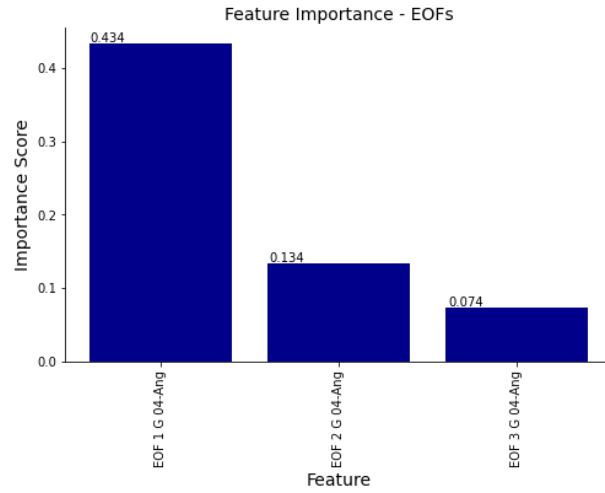


Figura H.8 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 04




Figura H.9 Resultado de Optimización Bayesiana en el algoritmo NSC-Sta generador G 04




Figura H.10 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 04




Figura H.11 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 04




Figura H.12 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 04




Figura H.13 Resultado de Optimización Bayesiana en el algoritmo RFC-Nor generador G 04

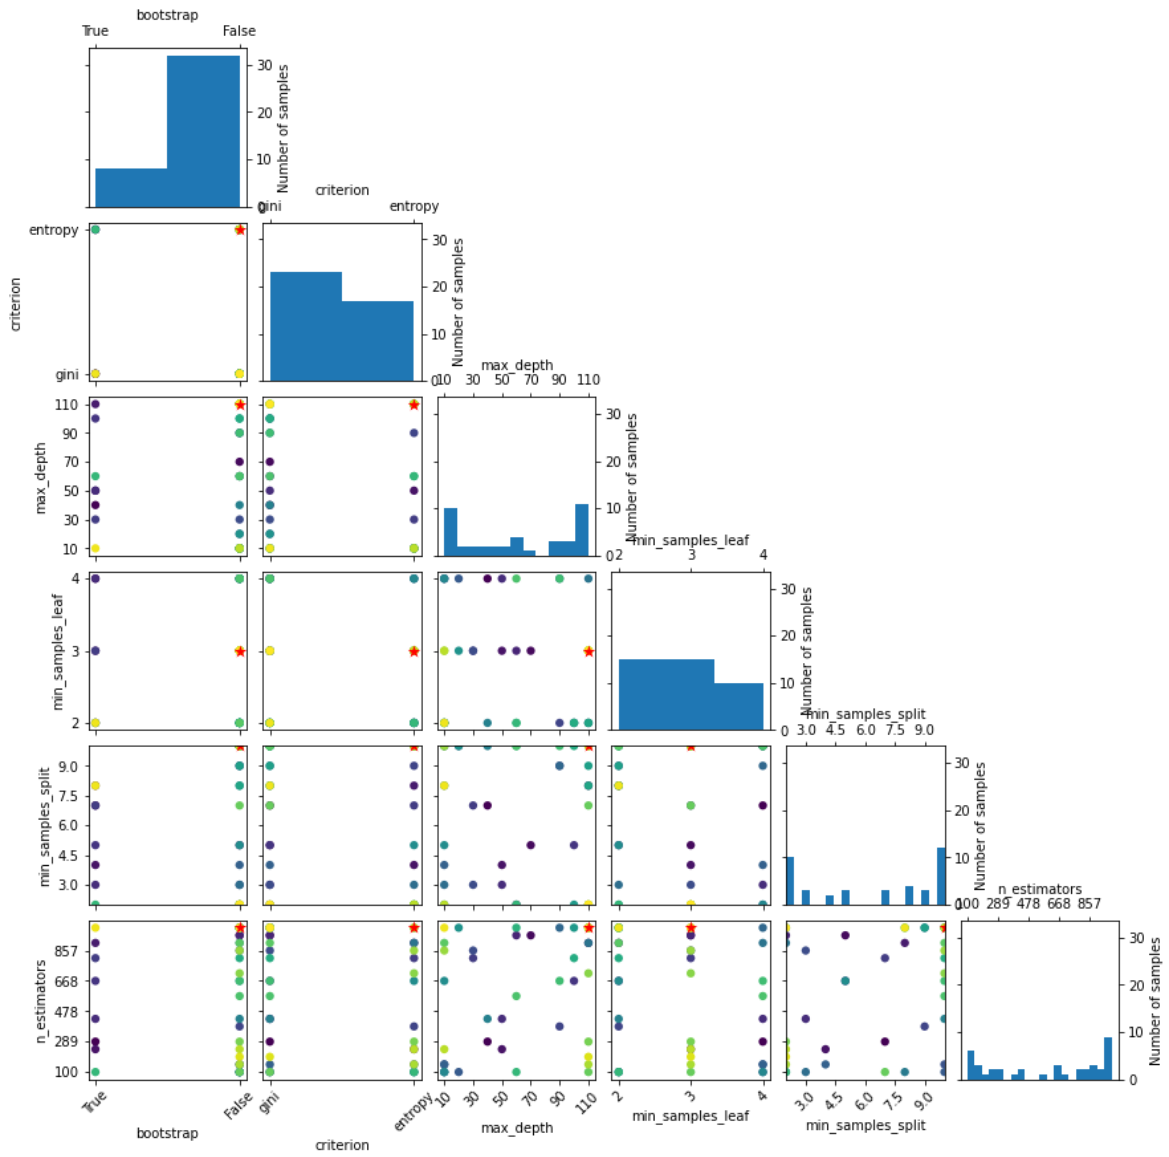


Figura H.14 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Nor generador G 04

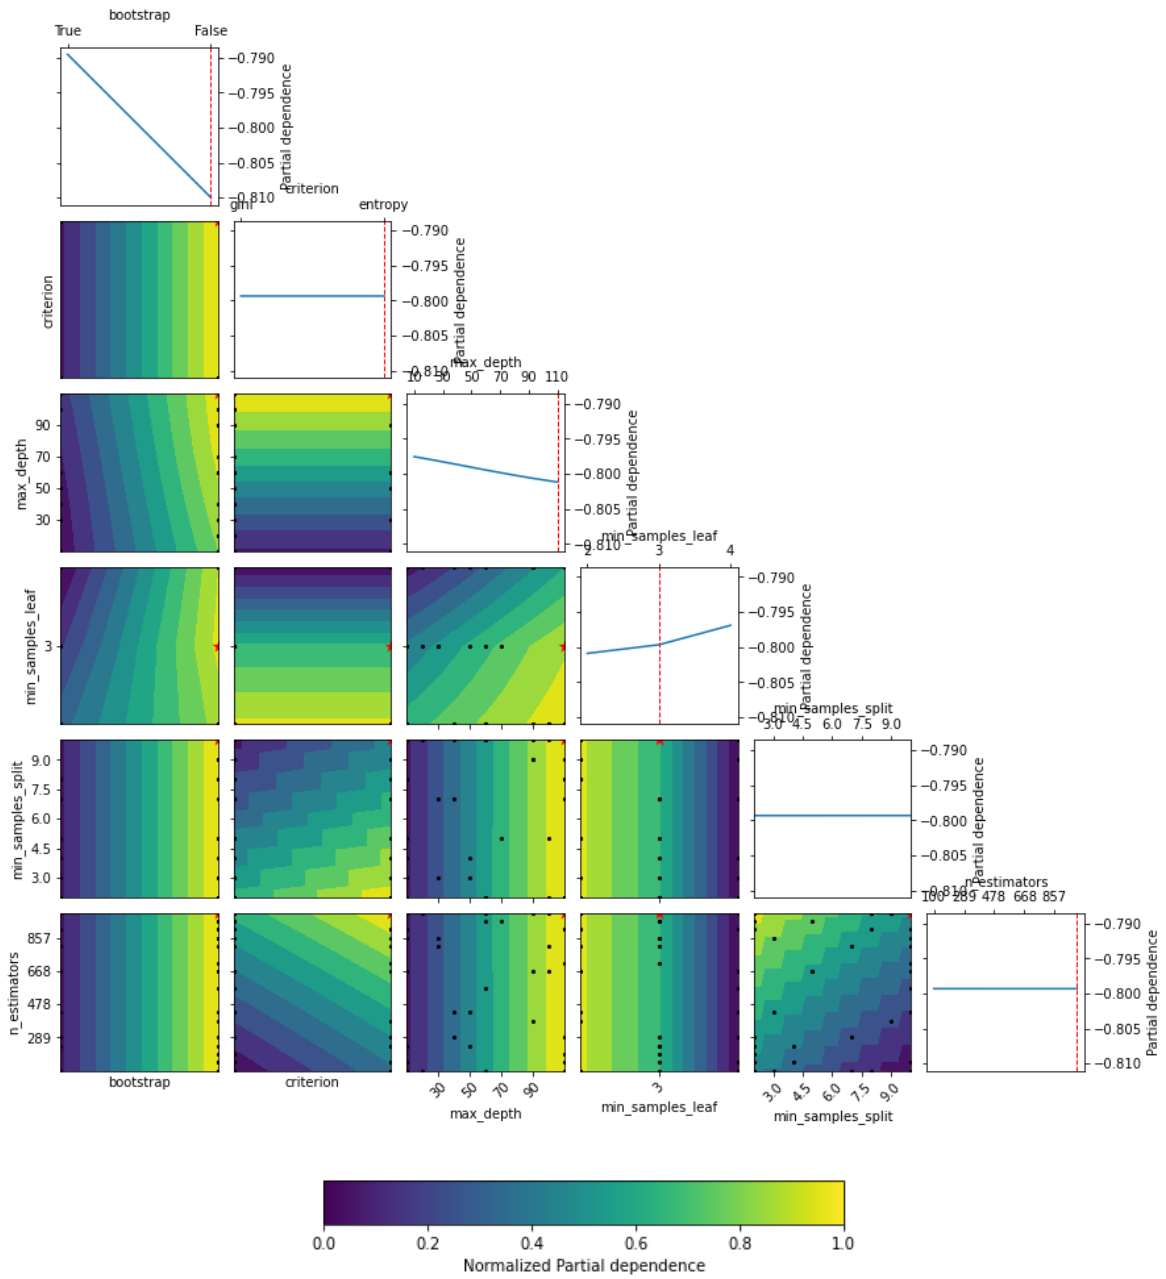


Figura H.15 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Nor generador G 04




Figura H.16 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Nor generador G 04

H.2. Resultados en el Generador G 05




Figura H.17 Resultado de Optimización Bayesiana en el algoritmo MLPC-Ori generador G 05




Figura H.18 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Ori generador G 05

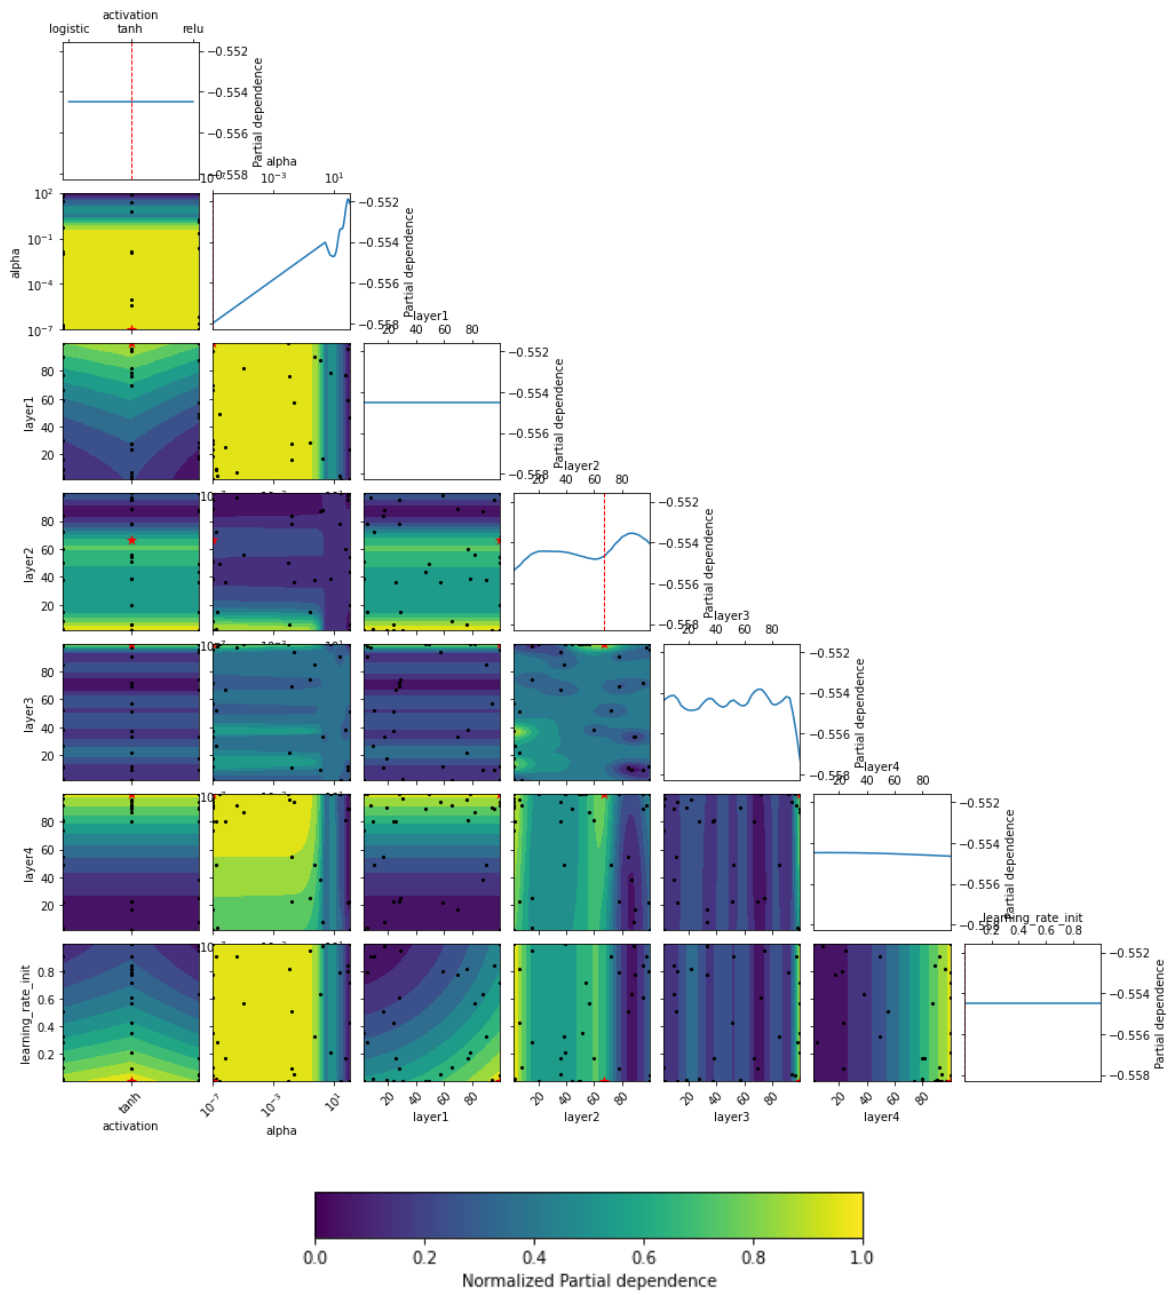


Figura H.19 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Ori generador G 05




Figura H.20 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Ori generador G 05




Figura H.21 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G 05




Figura H.22 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 05

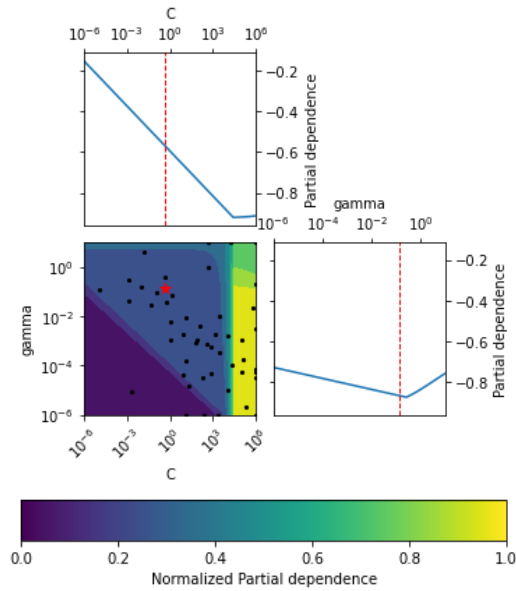


Figura H.23 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 05




Figura H.24 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 05




Figura H.25 Resultado de Optimización Bayesiana en el algoritmo NSC-Nor generador G 05




Figura H.26 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G 05




Figura H.27 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G 05




Figura H.28 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Nor generador G 05




Figura H.29 Resultado de Optimización Bayesiana en el algoritmo RFC-Sta generador G 05




Figura H.30 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 05

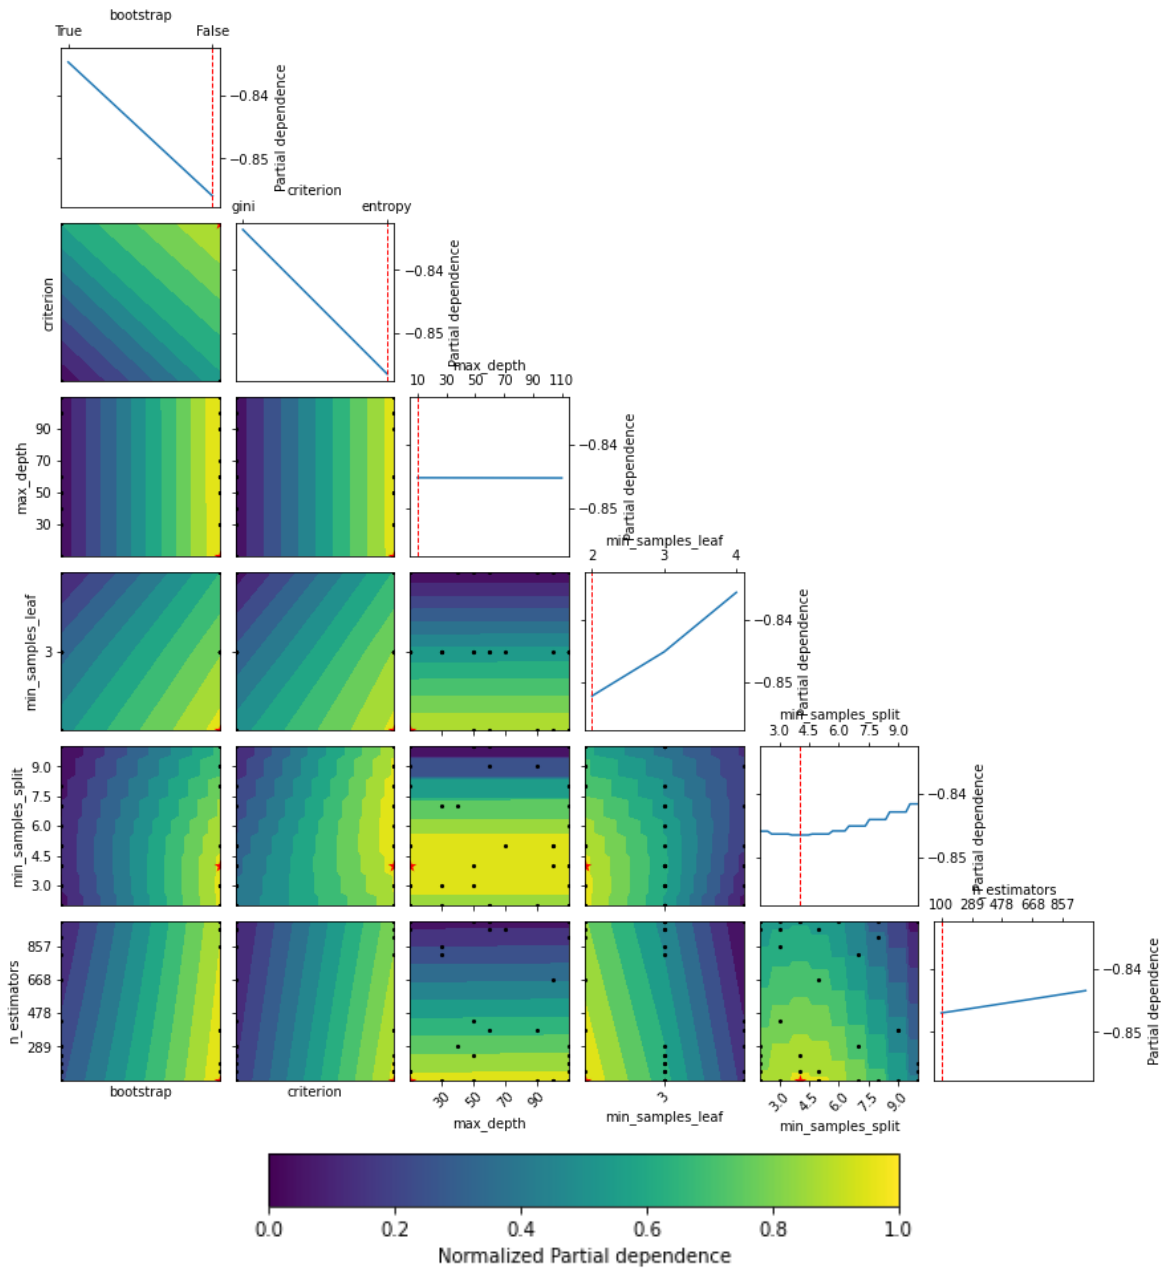


Figura H.31 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 05




Figura H.32 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 05

H.3. Resultados en el Generador G 06




Figura H.33 Resultado de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 06

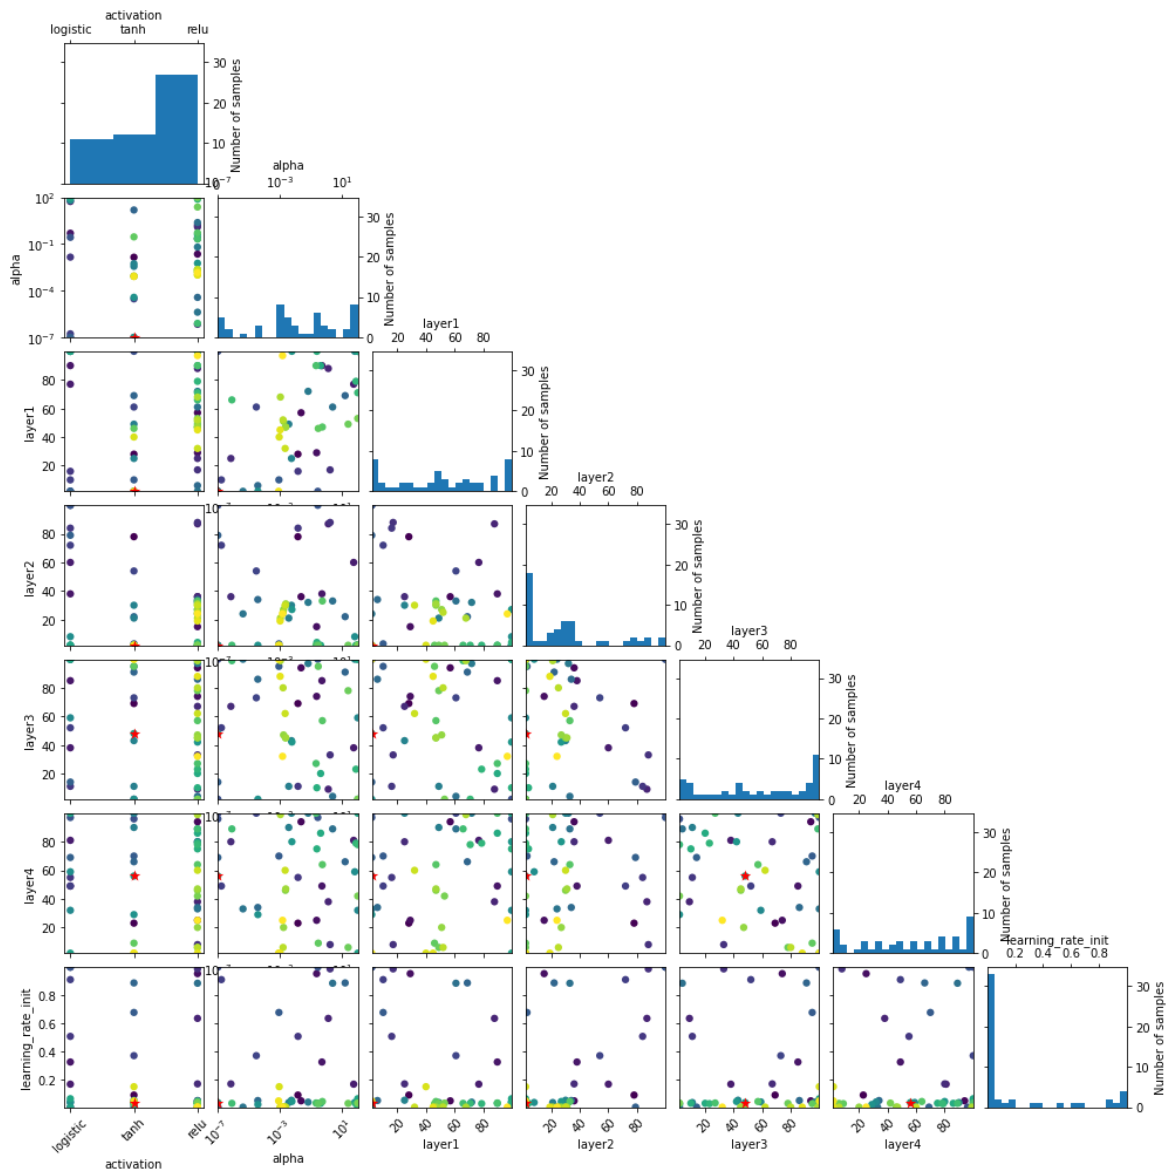


Figura H.34 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 06

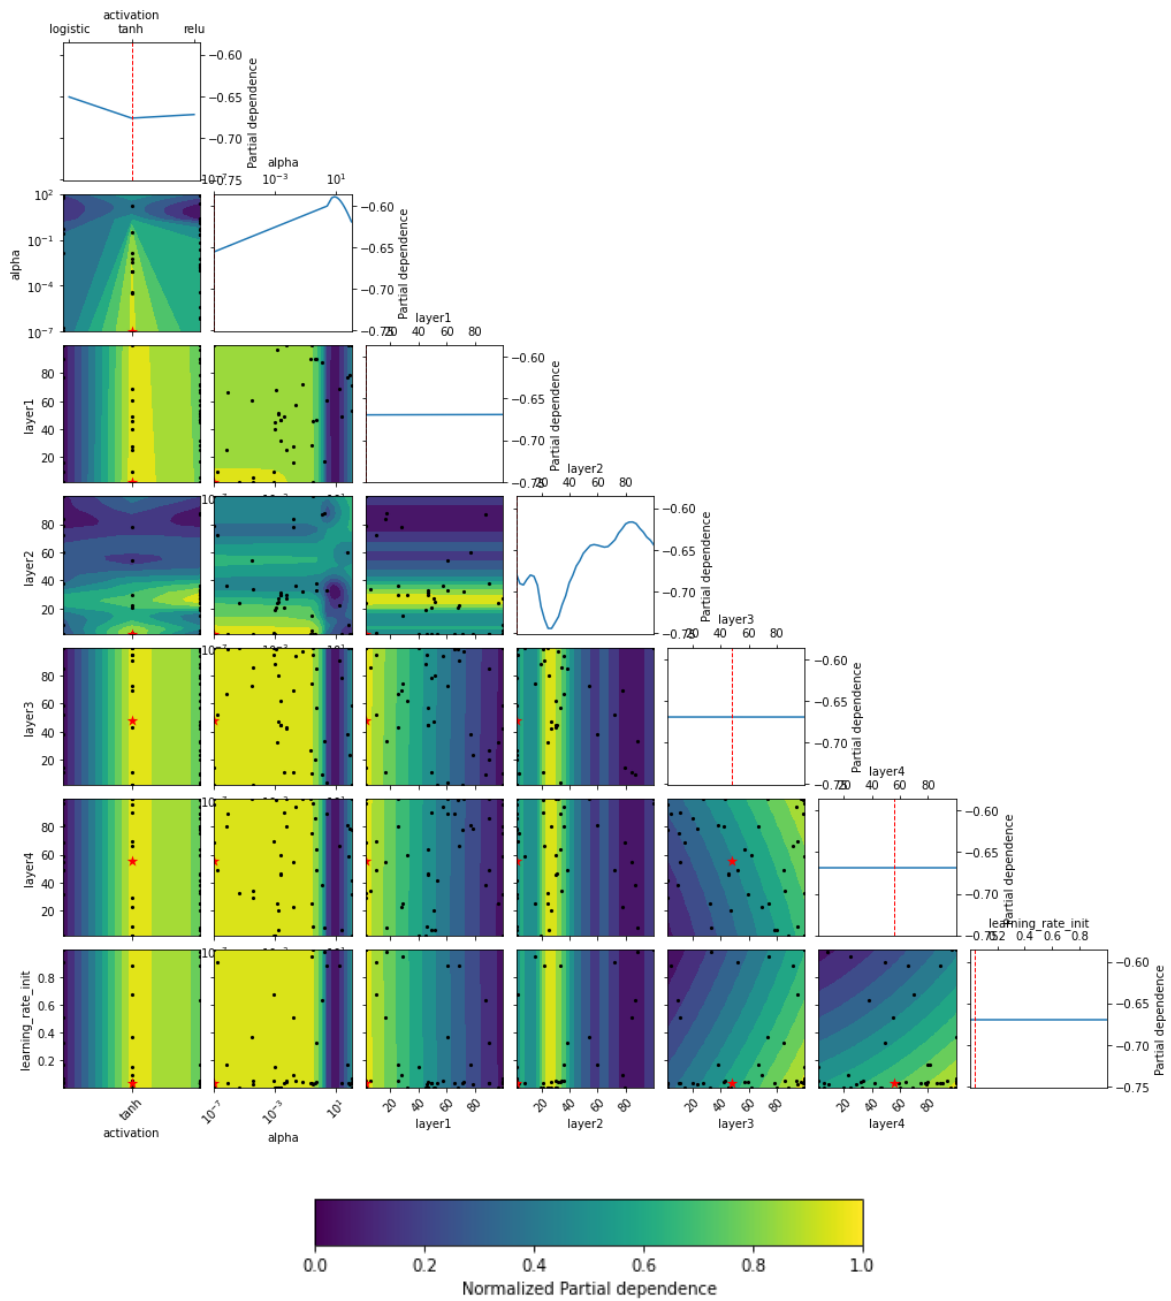


Figura H.35 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 06




Figura H.36 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 06




Figura H.37 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G 0




Figura H.38 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 06




Figura H.39 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 06




Figura H.40 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 06




Figura H.41 Resultado de Optimización Bayesiana en el algoritmo NSC-Sta generador G 0




Figura H.42 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 06




Figura H.43 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 06




Figura H.44 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 06




Figura H.45 Resultado de Optimización Bayesiana en el algoritmo RFC-Ori generador G 06

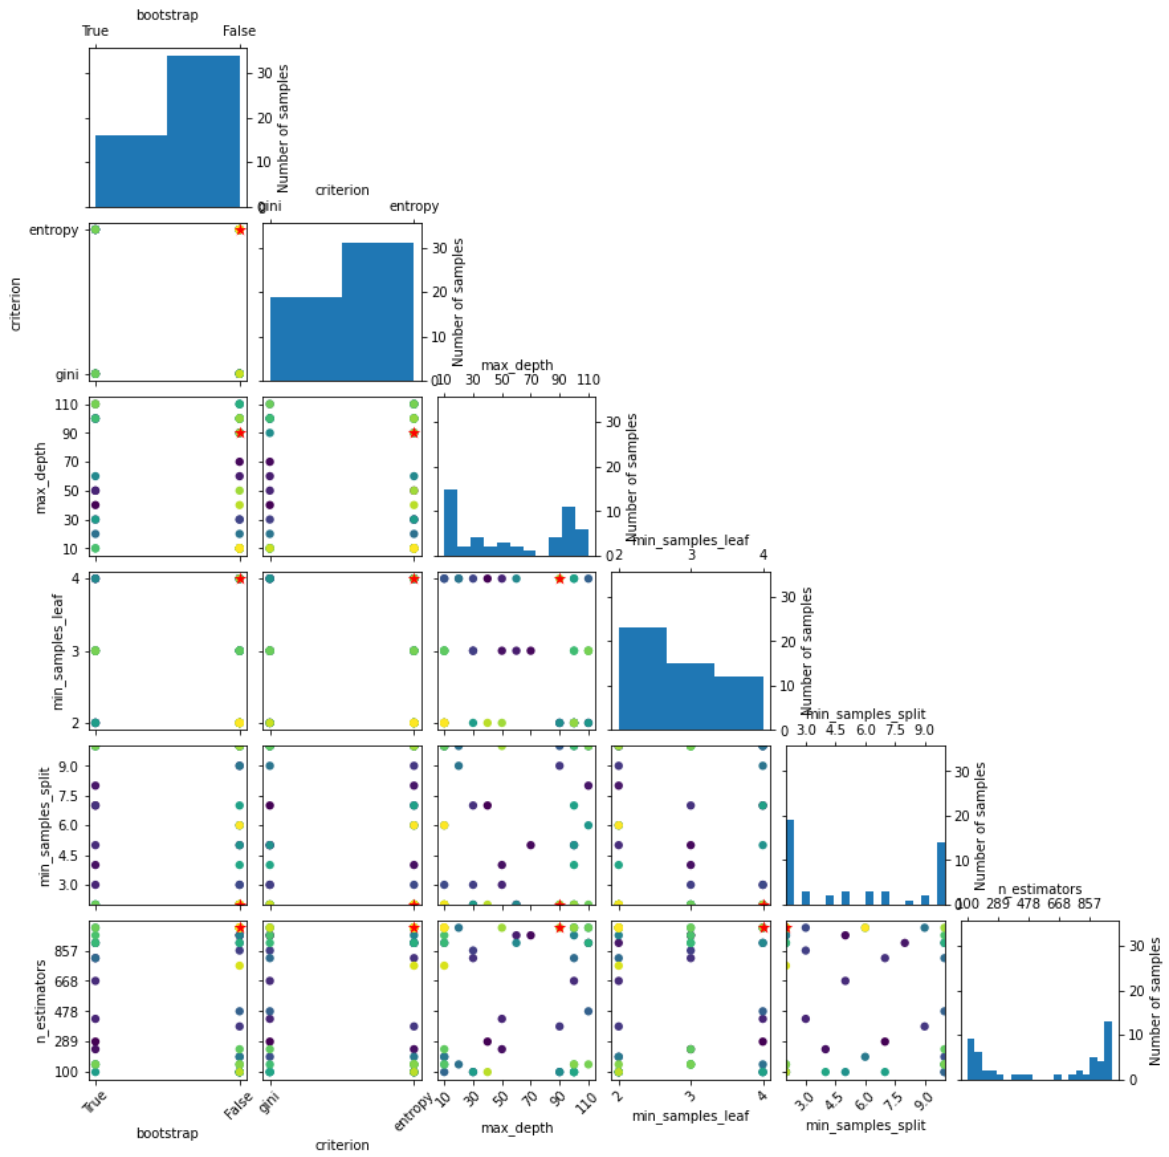


Figura H.46 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Ori generador G 06

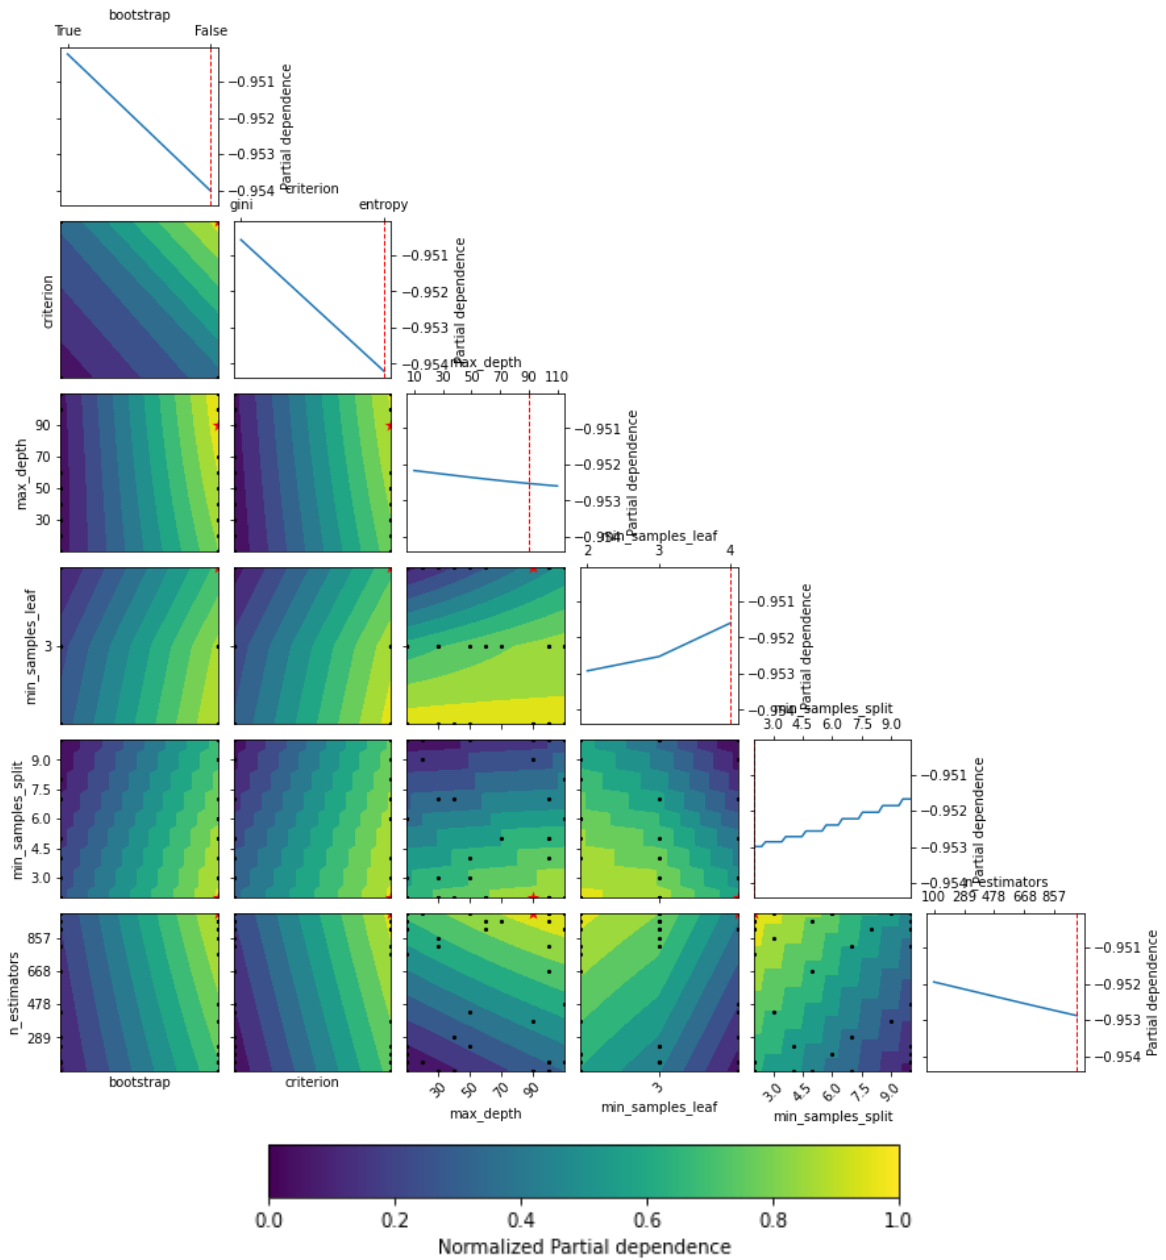


Figura H.47 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Ori generador G 06




Figura H.48 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Ori generador G 06

H.4. Resultados en el Generador G 07




Figura H.49 Resultado de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 07




Figura H.50 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 07




Figura H.51 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 07




Figura H.52 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor generador G 07

Optimización Bayesiana SVC-StWe

- Best balanced_accuracy (Training CV) = 0.9846
- balanced_accuracy (Testing) = 0.9841
- balanced_accuracy (CV) = 0.9837
- Best Parameters:
 - ('C', 0.49077)
 - ('gamma', 0.36386)




Figura H.53 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G 07




Figura H.54 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 07




Figura H.55 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 07




Figura H.56 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 07




Figura H.57 Resultado de Optimización Bayesiana en el algoritmo NSC-Sta generador G 07




Figura H.58 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 07




Figura H.59 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 07




Figura H.60 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 07




Figura H.61 Resultado de Optimización Bayesiana en el algoritmo RFC-Sta generador G 07




Figura H.62 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 07




Figura H.63 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 07




Figura H.64 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-Sta generador G 07

H.5. Resultados en el Generador G 09




Figura H.65 Resultado de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09




Figura H.66 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09




Figura H.67 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09




Figura H.68 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Sta generador G 09




Figura H.69 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe generador G 09




Figura H.70 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 09

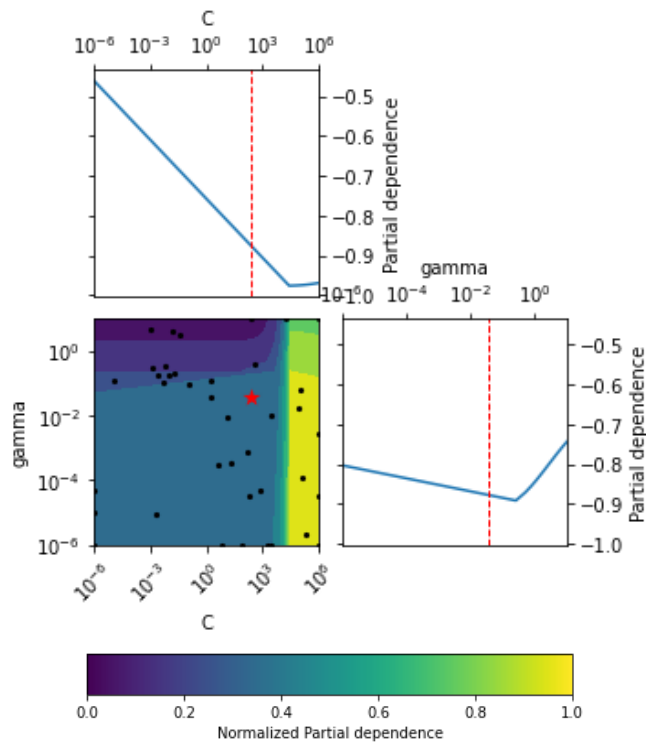


Figura H.71 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 09




Figura H.72 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe generador G 09

Optimización Bayesiana NSC-Sta

- Best balanced_accuracy (Training CV) = 0.9853
- balanced_accuracy (Testing) = 0.9838
- balanced_accuracy (CV) = 0.9851
- Best Parameters:
 - ('metric', euclidean)
 - ('shrink_threshold', 0.055)




Figura H.73 Resultado de Optimización Bayesiana en el algoritmo NSC-Sta generador G 09




Figura H.74 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 09




Figura H.75 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 09




Figura H.76 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Sta generador G 09

- Optimización Bayesiana RFC-StWe**
- Best balanced_accuracy (Training CV) = 0.9887
 - balanced_accuracy (Testing) = 0.9937
 - balanced_accuracy (CV) = 0.9850
 - Best Parameters:
 - ('bootstrap', True)
 - ('criterion', entropy)
 - ('max_depth', 90)
 - ('min_samples_leaf', 4)
 - ('min_samples_split', 5)
 - ('n_estimators', 100)




Figura H.77 Resultado de Optimización Bayesiana en el algoritmo RFC-StWe generador G 09

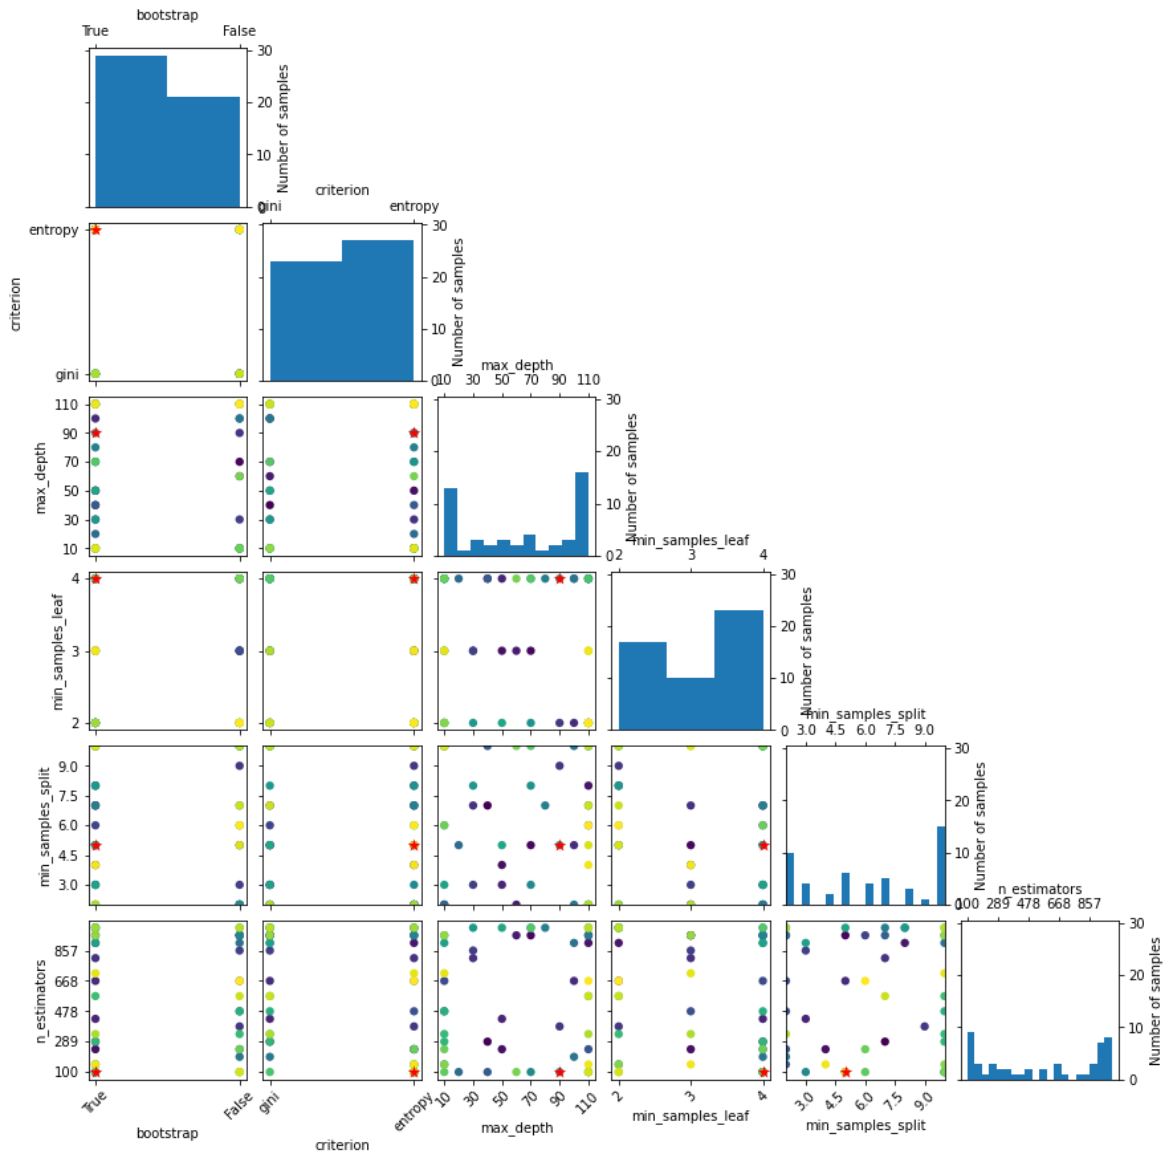


Figura H.78 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-StWe generador G 09

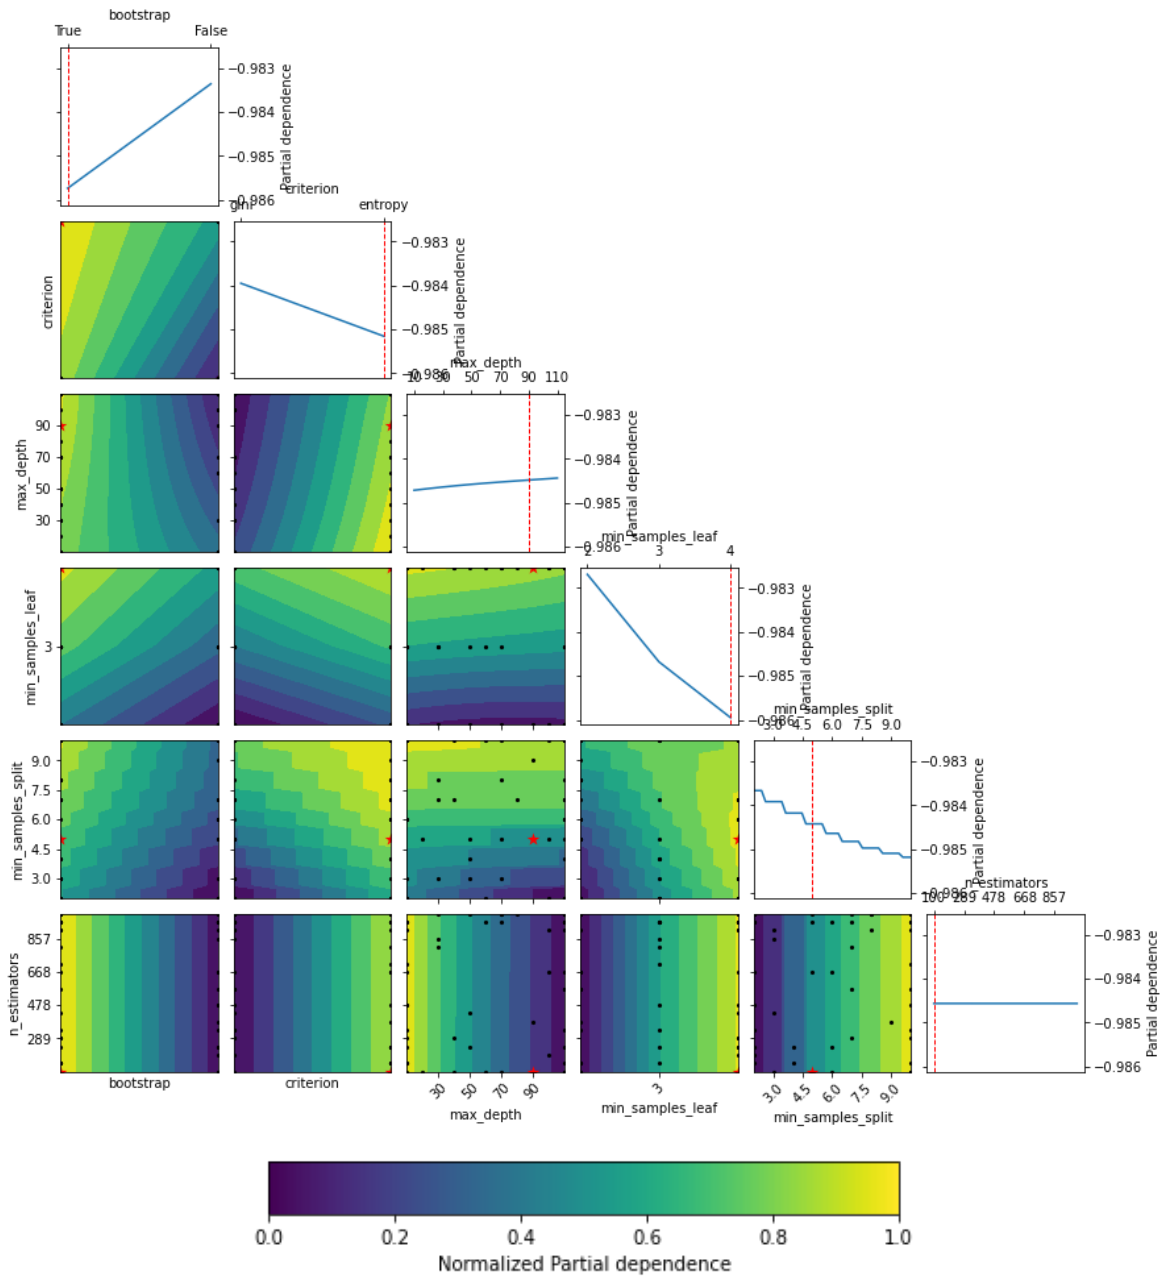


Figura H.79 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-StWe generador G 09




Figura H.80 Significancia de características del proceso de Optimización Bayesiana en el algoritmo RFC-StWe generador G 09

H.6. Resultados globales

Optimización Bayesiana MLPC-Nor

- Best balanced_accuracy (Training CV) = 0.9685
- balanced_accuracy (Testing) = 0.9886
- balanced_accuracy (CV) = 0.9703
- Best Parameters:
 - ('activation', 'relu')
 - ('alpha', 0.0085546)
 - ('layer1', 77)
 - ('layer2', 54)
 - ('layer3', 98)
 - ('layer4', 100)
 - ('learning_rate_init', 0.0001)




Figura H.81 Resultado de Optimización Bayesiana en el algoritmo MLPC-Nor




Figura H.82 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo MLPC-Nor




Figura H.83 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor




Figura H.84 Significancia de características del proceso de Optimización Bayesiana en el algoritmo MLPC-Nor




Figura H.85 Resultado de Optimización Bayesiana en el algoritmo SVC-StWe




Figura H.86 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo SVC-StWe




Figura H.87 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo SVC-StWe




Figura H.88 Significancia de características del proceso de Optimización Bayesiana en el algoritmo SVC-StWe




Figura H.89 Resultado de Optimización Bayesiana en el algoritmo NSC-Sta




Figura H.90 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo NSC-Sta




Figura H.91 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo NSC-Sta




Figura H.92 Significancia de características del proceso de Optimización Bayesiana en el algoritmo NSC-Sta




Figura H.93 Resultado de Optimización Bayesiana en el algoritmo RFC-Ori

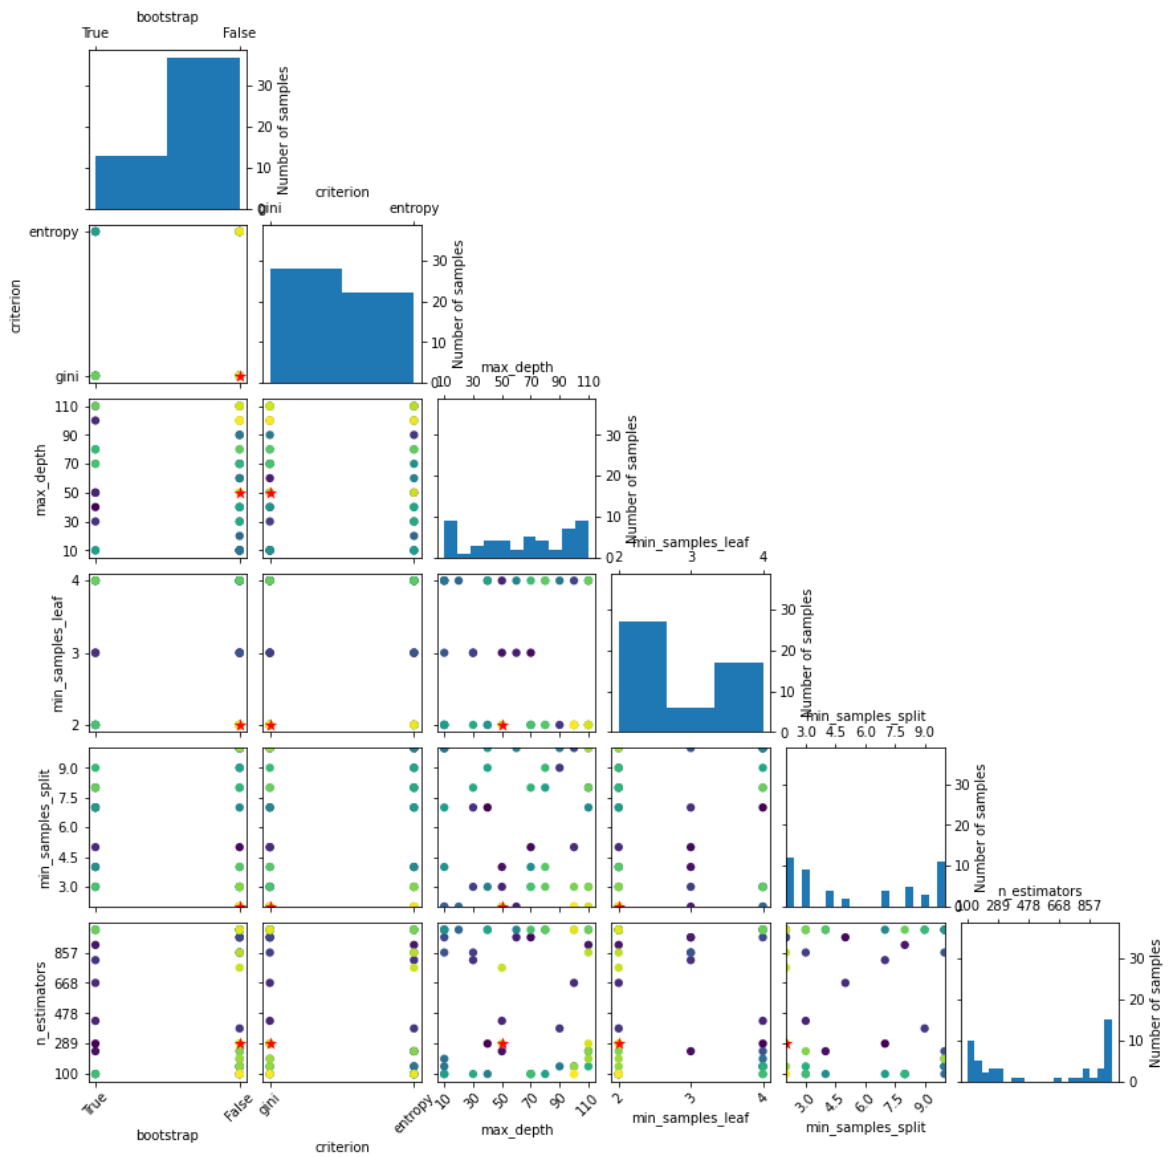


Figura H.94 Valores de los Hiperparámetros probados en el proceso de Optimización Bayesiana en el algoritmo RFC-Ori

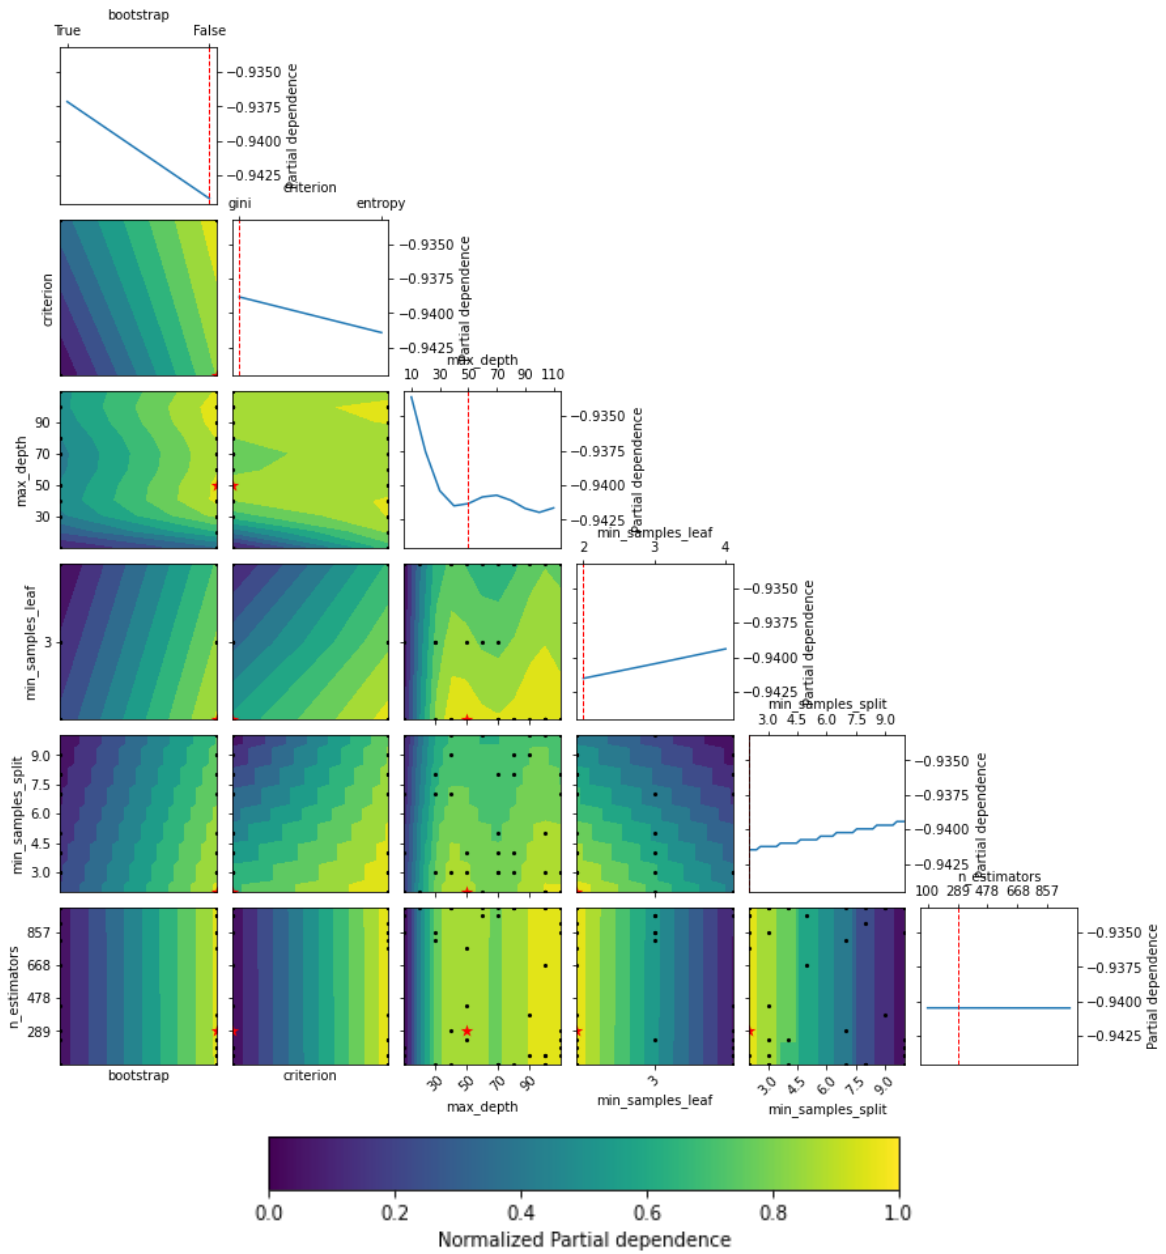


Figura H.95 Dependencia parcial del proceso de Optimización Bayesiana en el algoritmo RFC-Ori

ORDEN DE EMPASTADO

