



Evaluación de la Estabilidad de Tensión en Tiempo Real Usando Mediciones Sincronizadas de Fasores y Herramientas de Inteligencia Artificial

Walter Mauricio Villa Acevedo

Universidad de Antioquia
Facultad de Ingeniería
Departamento de Energía Eléctrica
Medellín, Colombia
2018

Evaluación de la Estabilidad de Tensión en Tiempo Real Usando Mediciones Sincronizadas de Fasores y Herramientas de Inteligencia Artificial

Walter Mauricio Villa Acevedo

Tesis de investigación presentada como requisito parcial para optar al título de:
Magister en Ingeniería - Ingeniería Eléctrica

Director:

Ph.D. Jesús M. López Lezama

Línea de Investigación:

Sistemas de Potencia

Grupo de Investigación:

Grupo en Manejo Eficiente de la Energía-
GIMEL

Universidad de Antioquia
Facultad de Ingeniería
Departamento de Energía Eléctrica
Medellín, Colombia
2018

Agradecimientos

El autor expresa sus agradecimientos a:

A la Universidad de Antioquia por brindar el recurso humano, invaluable e idóneo, para la contribución personal y profesional, durante el proceso de formación como estudiante de maestría en ingeniería.

Al grupo GIMEL (Grupo en Manejo Eficiente de la Energía), a su director por la disposición de sus instalaciones y personal profesional para la culminación de este trabajo de investigación.

Al Director de este proyecto de investigación por sus valoradas y pertinentes recomendaciones y sugerencias.

Resumen

En la actualidad, la característica competitiva de los mercados de energía eléctrica desregulados, los limitados planes de expansión del sistema, las restricciones ambientales y la inserción de generación renovable han provocado que los sistemas eléctricos de potencia sean operados habitualmente muy cerca de sus límites de estabilidad. Uno de estos límites es el de estabilidad de tensión, que resulta excedido cuando el sistema de potencia ya no tiene la capacidad de mantener estables las tensiones en todos o algunos de sus nodos después de un disturbio. En este trabajo de investigación se desarrolló un método para la evaluación de la estabilidad de tensión de largo alcance en tiempo real en sistemas de potencia.

Inicialmente, se dividió el sistema de potencia en sub-áreas que permitieran una mejor vigilancia del fenómeno de inestabilidad debida a nodos propensos a la inestabilidad y fuentes de generación que los pudieran controlar. La evaluación de la estabilidad de tensión se realizó mediante mediciones fasoriales sincronizadas y usando técnicas de inteligencia artificial. A través de las mediciones fasoriales sincronizadas se adquirió la información de la condición actual del sistema; y posteriormente, por medio de técnicas de inteligencia artificial e índices tradicionales, se desarrolló un esquema para la evaluación de la estabilidad de tensión. Este método permite vigilar la inestabilidad de tensión ocasionada por limitaciones en la transmisión de potencia reactiva en los corredores de las líneas, y también vigila cuando en un área del sistema se experimenta un déficit de potencia reactiva en las fuentes de suministro. Se realizó la validación del método propuesto en un sistema de prueba de 39 nodos para el cual se realizaron mediciones fasoriales sincronizadas simuladas. Estas pruebas corroboran que el método propuesto funciona correctamente ante diferentes escenarios y condiciones del sistema, siempre garantizando un monitoreo adecuado de la estabilidad de tensión independiente de la causa que lo produce.

Palabras clave: Áreas de Control de Tensión, Estabilidad de Tensión, Evaluación de Estabilidad, Índices de Estabilidad, Máquinas de Aprendizaje Extremo, Máquinas de Soporte Vectorial, Monitoreo en Tiempo Real, Mediciones Fasoriales Sincronizadas, Redes Neuronales Artificiales, Sistemas Inteligentes, Unidades de Medición Fasorial.

Abstract

Nowadays, the electric power systems have usually been operated very close to their stability limits due to the competitiveness of non-regulated markets of electric energy, the limited expansion system plans, the environmental restrictions, and the inclusion of renewable generation. One of these limits is the voltage stability that is exceeded when the power system does not have the capacity to keep the voltage stable in all its buses after any disturbance. In this research project it was proposed to develop a method for real-time long term voltage stability assessment in power systems.

Initially, the power system was divided into sub-areas that allowed a better supervision of the voltage instability caused by limitations in the reactive power transmission in the buses and the generation sources that could control them. The voltage stability assessment was made through synchronized phasor measurements along with artificial intelligence techniques. Information regarding the current system condition was acquired through synchronized phasor measurements; then, by using artificial intelligence and traditional indices, a method to voltage stability assessment was built. This method allows supervising the voltage instability caused by limitations in the reactive power transmission in the corridors lines, and it also monitors when a system area experiences a deficit of reactive power from the supply sources. The proposed method validation was performed in a 39-bus test system, for which simulated synchronized phasor measurements were completed. These tests confirm that the proposed method works properly under different scenarios and system conditions, always ensuring voltage stability monitoring in adequate manner independently of its cause.

Keywords: Voltage Control Areas, Voltage Stability, Stability Assessment, Stability Indexes, Extreme Learning Machines, Support Vector Machines, Real Time Monitoring, Synchronized Phasor Measurements, Artificial Neuronal Networks, Intelligent Systems, Phasor Measurement Units.

Tabla de contenido

Agradecimientos.....	5
Resumen.....	6
Abstract.....	7
Tabla de contenido.....	8
Lista de figuras.....	10
Lista de tablas.....	11
1. INTRODUCCIÓN.....	12
1.1 Planteamiento del Problema.....	13
1.2 Objetivo General.....	16
1.3 Objetivos Específicos.....	16
1.4 Alcance.....	16
1.5 Contenido Resumido.....	16
1.6 Bibliografía.....	17
2. EVALUACIÓN DE LA ESTABILIDAD DE TENSIÓN.....	19
2.1 Estabilidad de tensión.....	20
2.1.1 Clasificación de la estabilidad de tensión.....	20
2.1.2 Métodos para el análisis de estabilidad de tensión.....	21
2.1.3 Índices de estabilidad de tensión.....	22
2.1.4 Mecanismos de inestabilidad de tensión.....	23
2.2 Monitoreo de la estabilidad de tensión en tiempo real.....	24
2.2.1 Componentes del monitoreo de la estabilidad de tensión.....	24
2.2.2 Sistemas de medición sincronizada.....	26
2.3 Estado del arte del monitoreo de estabilidad de tensión.....	27
2.3.1 Monitoreo de la estabilidad de tensión basada en mediciones fasoriales sincronizadas.....	27
2.4 Conclusiones.....	38
2.5 Bibliografía.....	38
3. METODOLOGÍA PROPUESTA.....	42
3.1 Síntesis general de la metodología para la evaluación de la estabilidad.....	42
3.2 Construcción de la base datos usando el método Monte Carlo.....	44
3.2.1 Modelo probabilístico de la demanda nodal.....	44
3.2.2 Despacho económico en el corto plazo.....	45
3.2.3 Modelo probabilístico de contingencias $N-1$	46
3.2.4 Estructura general del método de simulación Monte Carlo.....	46
3.3 Áreas de control de tensión.....	48
3.3.1 Definición de VCA.....	48

3.3.2	Método de identificación de VCAs.....	49
3.4	Entrenamiento de sistemas inteligentes.....	52
3.4.1	Identificación de parámetros del sistema inteligente	55
3.5	Monitoreo de líneas de interconexión entre VCAs	56
3.6	Conclusiones.....	57
3.7	Bibliografía.....	58
4.	IMPLEMENTACIÓN DE METODOLOGÍA	61
4.1	Sistema de potencia de prueba.....	61
4.2	Identificación de VCAs	62
4.3	Entrenamiento de sistemas inteligentes.....	64
4.3.1	Identificación de parámetros del sistema inteligente	64
4.3.2	Selección del sistema inteligente.....	65
4.4	Método de monitoreo de líneas de interconexión entre VCAs.....	66
4.5	Monitoreo de estabilidad de tensión en tiempo real	68
4.6	Bibliografía.....	71
5.	CONCLUSIONES Y RECOMENDACIONES	73
5.1	Conclusiones.....	73
5.2	Recomendaciones y Retos Futuros.....	74

Lista de figuras

	Pag
Figura 2.1. Clasificación estabilidad en los sistemas de potencia (Prabha Kundur et al., 2004).	19
Figura 2.2. Definición del margen de carga.	23
Figura 2.3. Secuencia cronológica de la evaluación de la estabilidad en tiempo real.	25
Figura 2.4. Esquema conceptual para la evaluación de la estabilidad en tiempo real (Nguegan, 2009).	26
Figura 2.5. Sincrofasores.	27
Figura 3.1. Metodología propuesta para la evaluación de estabilidad en tiempo real.	43
Figura 3.2. Curvas de demanda horaria diaria según el tipo de usuario (Cepeda, 2013a). ..	45
Figura 3.3. Flujograma del método Monte Carlo propuesto para la base de datos.	47
Figura 3.4. Variación del VSM debido a diferentes direcciones de incremento de carga y contingencia.	48
Figura 3.5. Estructura del método de identificación de VCAs implementado.	50
Figura 3.6. Metodología para identificación de parámetros de la IA basada en MVMO. ..	57
Figura 4.1. Diagrama unifilar del sistema New England de 39 nodos (Pai, 1989).	61
Figura 4.2. Histograma del número de VCAs posibles en el sistema.	63
Figura 4.3. Configuración más típica de VCAs encontrada.	63
Figura 4.4. Convergencia del MVMO en el proceso de identificación de parámetros óptimos de la IA.	65
Figura 4.5. Convergencia del MVMO en la identificación de parámetros óptimos para cada KMAE.	69
Figura 4.6. Comparación entre los valores reales y estimados de VSM para la VCA2.	70
Figura 4.7. Comparación entre los valores reales y estimados de la diferencia angular cutset normalizada [0-1] para AC4.	71

Lista de tablas

	Pag
Tabla 2.1. Resumen de la implementación de técnicas de IA para monitoreo de la estabilidad de tensión.	35
Tabla 4.1. Parámetros óptimos identificados para la IA.	65
Tabla 4.2. MSE obtenidos en la prueba de selección de la IA.	66
Tabla 4.3. Líneas de las áreas <i>cutset</i> obtenidas para el sistema de prueba.	68
Tabla 4.4. Parámetros óptimos identificados para cada área <i>cutset</i> (AC).	68
Tabla 4.5. MSE y RMSE obtenidos en la validación de KMAE para cada VCA.	69
Tabla 4.6. Parámetros óptimos identificados para cada AC o interconexiones.	69
Tabla 4.7. MSE y RMSE obtenidos en la validación de KMAE para cada AC.	70

1. INTRODUCCIÓN

Los sistemas de suministro de energía eléctrica juegan un papel de vital importancia en los procesos de industrialización y desarrollo económico de los países modernos. Estos sistemas traen consigo beneficios del uso de la energía eléctrica, y a la vez plantean nuevos problemas que se deben solucionar para proporcionar el servicio de suministro. Algunos de estos problemas son resueltos durante la operación diaria del sistema, y otros requieren de una evaluación previa.

Las redes de energía eléctrica son sistemas dinámicos constituidos por una gran cantidad de dispositivos y elementos; además, su constitución es a través de la suma de diferentes subsistemas, que están dinámicamente interconectados en el funcionamiento del sistema completo. Para estos sistemas se presenta un crecimiento constante en la complejidad de las restricciones de funcionamiento, por lo cual se necesitan nuevos métodos de vigilancia y control, esto es, un impulso para el desarrollo de herramientas robustas y sofisticadas para la representación adecuada del sistema y para la supervisión de la evolución de sus estados.

La vigilancia del comportamiento de los sistemas de potencia es primordial para garantizar el funcionamiento confiable y seguro. Para una mayor exactitud y eficiencia se debe dirigir dicha vigilancia a la operación en tiempo real más allá de la evaluación en línea (*on-line*) (Savulescu, 2009). Los requerimientos técnicos para la vigilancia del sistema en tiempo real son muy exigentes, en los siguientes aspectos: a) la representación del sistema a monitorear; b) sistemas de medición rápidos de variables relevantes a medir; c) la entrega de resultados que deben ser rápida; y d) los resultados deben ser de fácil interpretación para el operador.

En la vigilancia del sistema las funciones requeridas para el monitoreo del sistema y sus interacciones son principalmente determinadas por la meta final de la supervisión, es decir, que fenómeno se quiere vigilar y ante el cual se desea proteger. Por lo general, las condiciones del sistema son establecidas con base en algunas mediciones de variables del sistema que determinan su estado, las cuales son luego visualizadas e interpretadas. Para el monitoreo en tiempo real se deben tener sistemas de medición rápidos que suministra un flujo continuo de las variables relevantes del sistema, esto es, que la información recibida sea lo más cercana posible a la condición en tiempo real del sistema eléctrico.

Dado el reciente incremento de colapsos de tensión o de fenómenos de inestabilidad de tensión en sistemas de potencia en diferentes partes del mundo, como lo sucedido en Estados Unidos y Canadá (C. L. Y. S. and X. Chen, 2007; Corsi & Sabelli, 2004, p. 00; Liscouski & Elliot, 2004), con pérdidas económicas de millones de dólares, y además debido a la alta frecuencia de ocurrencia de estos eventos hay un gran interés en la evaluación de la estabilidad de tensión del sistema de potencia y en la aplicación de medidas paliativas. Una primera propuesta para enfrentar este fenómeno fue la evaluación de la seguridad dinámica del sistema en línea (*on-line DSA*, por sus siglas en inglés) es un

esfuerzo para mitigar eventos de inestabilidad en el sistema de potencia, pero previo a mitigar los eventos de inestabilidad es necesario evaluar en línea el estado de operación del sistema, (CIGRE Working Group, 2007). Para la evaluación en línea el tiempo de cálculo es de 5 a 15 minutos. La evaluación completa debe completarse dentro de este lapso de tiempo desde el momento que es capturado el estado actual del sistema, hasta el momento que los resultados están disponibles (Morison, Wang, & Kundur, 2004). En este lapso de tiempo se considera que el estado del sistema no cambia significativamente. Esta tarea de evaluación, en lo que refiere a la estabilidad de tensión, se conoce como la evaluación de la seguridad de tensión en línea del sistema (VSA, por sus siglas en inglés).

La evaluación de la seguridad de tensión en línea permite determinar si el sistema soporta un disturbio inminente sin que éste provoque la interrupción del servicio de energía (CIGRE Working Group, 2007; Prabha Kundur et al., 2004). Esta evaluación se realiza para un conjunto de disturbios seleccionados, por lo cual no se tiene certeza de que el sistema resista disturbios no seleccionados. Para los centros de supervisión y control el desafío que se presenta en el monitoreo en tiempo real, es desarrollar herramientas apropiadas que permitan extraer de las mediciones el conocimiento útil para establecer la condición del sistema, y que permita la evaluación rápida de la estabilidad de tensión de los sistemas eléctricos de potencia.

Con la aparición de tecnologías como la unidad de medición fasorial (PMU, por su sigla en inglés), se aumentó la capacidad de medición en los sistemas eléctricos de potencia tanto en rapidez como en la sincronización de los fasores medidos. Por otra parte, también se ha presentado el mejoramiento de las aplicaciones de bases de datos, la gestión de la información y la infraestructura de comunicación. Debido a lo anterior, en los últimos años se han desarrollado aplicaciones de monitoreo de área amplia (WMAs, por sus siglas en inglés), las cuales utilizan las medidas fasoriales sincronizadas entregadas por las PMUs, permitiendo el monitoreo casi en tiempo real del sistema (Kerin, Heyde, Krebs, & Lerch, 2014). Al mismo tiempo, con el aumento del número de PMUs instaladas y los usos de los datos de las PMUs, se habilitan alternativas potenciales para el monitoreo de la estabilidad del sistema. Dichas herramientas deben avanzar al ritmo que aparecen nuevas exigencias del sistema, y al tiempo que se introducen nuevas tecnologías que permitan el desarrollo de algoritmos que evalúen la estabilidad de tensión en tiempo real del sistema de potencia.

1.1 Planteamiento del Problema

En la actualidad, la característica competitiva de los mercados de energía eléctrica desregulados, los limitados planes de expansión del sistema y las restricciones ambientales han provocado que los sistemas eléctricos de potencia sean operados habitualmente muy cerca de sus límites de funcionamiento. Esto ha traído como consecuencia que los sistemas operen cerca de los límites de estabilidad. Uno de estos límites es el de estabilidad de tensión, que resulta violado cuando el sistema de potencia ya no tiene la capacidad de mantener estables las tensiones en todos o algunos de sus nodos después de un disturbio.

En la actualidad este tipo de inestabilidad ha sido reconocido como uno de los principales problemas en los sistemas de potencia alrededor del mundo (C. L. Y. S. and X. Chen, 2007; Corsi & Sabelli, 2004; Liscouski & Elliot, 2004).

El aumento de la integración de las energías renovables intermitentes y el desarrollo de redes inteligentes, ha provocado un aumento en la complejidad de la operación y planeamiento del sistema de potencia. Debido a los nuevos desafíos que deben encarar los sistemas modernos de potencia se hace necesario adoptar la evaluación de la estabilidad en tiempo real, ya que los métodos convencionales de evaluación de la estabilidad basado en estudios fuera de línea son inadecuados, y pueden elevar los costos de operación del sistema (Z Dong, Xu, Wong, & Wong, 2013). El operador del sistema se ve obligado a emplear nuevos métodos de supervisión y evaluación de la estabilidad de tensión en tiempo real. Esta necesidad ha motivado al desarrollo de herramientas robustas y sofisticadas para la supervisión y evaluación del sistema. La vigilancia de los sistemas de potencia es primordial para garantizar una operación segura, y para una mayor precisión se debe realizar esta vigilancia en tiempo real (CIGRE Working Group, 2007; Prabha Kundur et al., 2004; Savulescu, 2009).

Para realizar el monitoreo de la estabilidad y eliminar el riesgo de apagón en los sistemas de potencia, las empresas operadoras están trasladándose desde los métodos fuera de línea hacia la evaluación de la estabilidad en tiempo real. En la operación del sistema en una región inestable donde se deben tomar decisiones críticas en línea, la evaluación en tiempo real requiere herramientas de cálculo más eficientes (Z Dong et al., 2013). En las últimas décadas, ha surgido una solución a este problema en la evaluación de la estabilidad en, o cercano al tiempo real que son las herramientas de Inteligencia Artificial (IA). La evaluación de la estabilidad en tiempo real usando IA reduce drásticamente el tiempo de cálculo, eliminando la necesidad de cálculo de las ecuaciones no lineales en línea de los modelos del sistema. La IA usada en la evaluación captura las relaciones entre los diferentes estados del sistema y la información de estabilidad, extrayendo el conocimiento desde la información y determinando el correspondiente estatus de estabilidad (Z Dong et al., 2013).

Para los centros de supervisión y control, el desafío que se presenta en el monitoreo en tiempo real de la estabilidad es el desarrollo de herramientas apropiadas que permitan extraer, desde las mediciones recibidas, un conocimiento útil para la evaluación de la estabilidad de tensión. La necesidad identificada en la evaluación en tiempo real puede ser solucionada con el desarrollo de sistemas de IA, que permitan la evaluación precisa y confiable de la estabilidad de tensión; disminuyendo el error en la predicción ante diferentes escenarios de demanda y generación, y considerando contingencias en el sistema de potencia (Z Dong et al., 2013; Savulescu, 2009)

Para el monitoreo se requiere que los tiempos de estimación sean cortos y los esfuerzos de cálculo sean mínimos. Para esto se ha utilizado tradicionalmente indicadores de desempeño del sistema que permiten establecer la distancia entre el punto de operación actual y un punto en la frontera de inestabilidad de tensión. La característica primordial de estos índices es que puedan ser estimados cuando cambian las condiciones operativas. Además, estos índices deben ser predecibles y rápidamente calculables (Cañizares, 2002; Gómez-Expósito, Conejo, & Cañizares, 2008). El problema en la mayoría de los índices de estabilidad es que

sus valores varían en forma altamente no lineal y discreta, debido a las características no lineales del sistema y a sus límites de operación (Cañizares, 2002; Gómez-Expósito et al., 2008; Hatziargyriou & Van Cutsem, 1994; Torres, Peralta, & Castro, 2007). Otros índices requieren de un cálculo altamente intensivo para determinar su valor ante las condiciones cambiantes del sistema.

Los sistemas de adquisición, de supervisión y control (SCADA, por sus siglas en inglés) que se han implementado en los centros de control con el fin de monitorear el sistema, dan poca información sobre las dinámicas rápidas del sistema de potencia (Liscouski & Elliot, 2004). Por otra parte, con los sistemas WAMs constituidos por PMUs se pueden observar las dinámicas del sistema de potencia gracias a la alta tasa de muestreo. Además, cada PMU es capaz de calcular los fasores de tensión y corriente de las mediciones locales con respecto a un ángulo de referencia común para el sistema (Phadke, 1993; Phadke & Thorp, 2008). Esto se logra sincronizando cada PMU en el tiempo por medio de una señal del sistema de posicionamiento global (GPS, por sus siglas en inglés). Las WAMs dan la oportunidad de tener una mejor observación y comprensión de los fenómenos rápidos y pueden ser usadas para evitar la inestabilidad de tensión en el sistema.

Los fasores medidos son datos en bruto; es decir, la información relevante contenida en ellas es diferente según el tipo de inestabilidad que se quiera monitorear. Además, esta información debe ser extraída y presentada en forma clara para posibilitar una rápida toma de decisiones. Para esto se deben desarrollar métodos para extraer la información útil desde el conjunto de datos que entregan las PMUs. Un problema actual es saber cómo usar las medidas fasoriales sincronizadas para la evaluación en tiempo real de la estabilidad de tensión del sistema, teniendo en cuenta que esta estabilidad está particularmente influenciada por máxima potencia transferida y por las reservas de potencia reactiva del sistema. El objetivo del método de monitoreo es detectar, tan pronto como sea posible, cuándo el sistema de potencia está en el proceso de perder su estabilidad de tensión, o cercano a tiempo real se debe determinar el margen de estabilidad de tensión del estado de operación del sistema (Karki, 2009; Lof, Smed, Andersson, & Hill, 1992; Morison, Wang, Moshref, & Edris, 2008; Nguegan, 2009).

En (Avramovic & Fink, 1992; Karki, 2009; Lof et al., 1992; Morison et al., 2008; Nguegan, 2009) se han trabajado métodos de monitoreo para prever la estabilidad de tensión y las acciones óptimas de control con el fin de evitar el colapso de tensión. La mayoría de los inconvenientes encontrados son los comportamientos altamente no lineales y la necesidad de emplear métodos computacionalmente intensivos. En consecuencia, es necesario reducir el tiempo de cálculo computacional, para lo cual se propone usar las medidas sincronizadas de fasores, combinándolas con técnicas de IA para la evaluación de la estabilidad de tensión en tiempo real (Z Dong et al., 2013).

Para el monitoreo de la estabilidad de tensión en tiempo real lo apropiado y efectivo es construir un método de evaluación de la estabilidad de tensión que considere los diferentes mecanismos de inestabilidad de tensión en el sistema. Además, el método de evaluación deberá producir resultados con un tiempo reducido de cálculo y con una respuesta confiable frente a las variaciones de carga, contingencias y ante los efectos de los límites de operación de elementos del sistema.

1.2 Objetivo General

Desarrollar un método para monitoreo de la estabilidad de tensión de largo alcance en sistemas de potencia, mediante el uso de mediciones fasoriales sincronizadas y herramientas de inteligencia artificial.

1.3 Objetivos Específicos

- Realizar una revisión bibliográfica sobre monitoreo de estabilidad de tensión de largo alcance, mediciones fasoriales sincronizadas y herramientas de inteligencia artificial aplicadas a la estabilidad de tensión.
- Construir una base de datos de medidas fasoriales mediante simulación que permita evaluar los índices propuestos.
- Seleccionar una herramienta de inteligencia artificial que sea aplicable a la evaluación de la estabilidad de tensión de largo alcance, por medio del análisis de las diferentes herramientas.
- Proponer un índice para evaluación de la estabilidad de tensión de largo alcance por medio de herramientas de inteligencia artificial a partir de índices tradicionales reportados en la literatura técnica.
- Implementar una herramienta de monitoreo de estabilidad de tensión integrando el índice propuesto con las mediciones fasoriales obtenidas mediante simulación.

1.4 Alcance

En el trabajo de investigación se busca establecer e implementar un método adecuado para el monitoreo de la estabilidad de tensión de largo alcance en tiempo real, con el cual se obtenga información del sistema de cuándo está propenso a la inestabilidad de tensión para un escenario determinado. La evaluación de la estabilidad en tiempo real se realizará por medio de la estimación de un índice de estabilidad de tensión conocido como “margen de estabilidad”. Esta evaluación debe ser rápida y precisa con el fin de entregar señales para un control adecuado y efectivo. Para la estimación del índice de estabilidad se ha propuesto trabajar con herramientas de IA con el fin de mejorar el tiempo del cálculo en la evaluación.

El método de monitoreo estará fundamentado en el uso de medidas fasoriales sincronizadas (voltaje en nodos) obtenidas por medio de herramientas de simulación para un sistema de prueba de la IEEE. En este trabajo no se considera el problema ubicación óptima de las PMUs, se trabaja bajo el supuesto que dichos elementos de medición ya están disponibles en el sistema, en base a la ubicación de las mismas que permita una mejor observabilidad al sistema desde punto de vista de la estimación de estados.

1.5 Contenido Resumido

Capítulo I, Introducción: Se presentan aspectos como la motivación para realizar este

trabajo de investigación, se establece el planteamiento del problema en el área de la estabilidad de tensión y los objetivos planteados en la investigación.

Capítulo II, Evaluación de la estabilidad de tensión: En esta sección se desarrollan los conceptos básicos sobre la estabilidad de tensión, monitoreo de sistemas de potencia, medición fasorial sincronizada por medio de PMUs. Finalmente, se presenta una revisión bibliográfica sobre métodos de monitoreo en tiempo real de la estabilidad de tensión de largo alcance.

Capítulo III, Metodología propuesta: Se presenta la metodología propuesta para la evaluación de la estabilidad de tensión desarrollada en este trabajo de investigación, conformada por los siguientes pasos: Construcción de la base de datos, identificación de áreas de control de tensión, entrenamiento y selección de la herramienta de inteligencia artificial, diseño e implementación del método en tiempo real de estabilidad de tensión de largo alcance.

Capítulo IV, Implementación de la metodología: Se presentan los resultados obtenidos y los análisis realizados con el sistema de prueba IEEE de 39 nodos, con el objetivo de comprobar la aplicabilidad del método propuesto en un sistema de potencia.

Capítulo V, Conclusiones y recomendaciones: Se presentan las conclusiones establecidas en el desarrollo del trabajo de investigación, se presentan las recomendaciones y trabajos posteriores a desarrollar a partir de lo establecido en la investigación.

1.6 Bibliografía

- B. Avramovic and L. H. Fink. (1992). Real-time reactive security monitoring. *IEEE Trans. on Power Systems*, 7.
- Cañizares, C. A. (2002). *Voltage Stability Assessment: Concepts, Practices and Tools*, IEEE/PES Power System Stability Subcommittee. Tech. Rep. SP101PSS.
- Chen, C. L. Y. S. and X. (2007). Analysis of the Blackout in Europe on November 4, 2006. Presented at the International Power Engineering Conference, IPEC.
- CIGRE Working Group, C. 60. (2007). *CIGRE Technical Brochure on Review of On Line Dynamic Security Assessment Tools and Techniques*.
- Corsi, S., & Sabelli, C. (2004). General blackout in Italy sunday september 28, 2003, h. 03: 28: 00. In *Power Engineering Society General Meeting, 2004. IEEE* (pp. 1691–1702). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1373162
- Dong, Z. Y., Xu, Y., Zhang, P., & Wong, K. P. (2013). Using IS to Assess an Electric Power System's Real-Time Stability. *IEEE Intelligent Systems*, 28(4), 60–66. <https://doi.org/10.1109/MIS.2011.41>
- Gómez-Expósito, A., Conejo, A. J., & Cañizares, C. (2008). *Electric Energy Systems: Analysis and Operation* (1st ed.). New York: CRC Press.
- Hatzargyriou, N. D., & Van Cutsem, T. (1994). *Indices predicting voltage collapse including dynamic phenomena*. CIGRE.
- K. Morison; X. Wang; A. Moshref and A. Edris. (2008). Identification of Voltage Control Areas and Reactive Power Reserve; An Advancement in On line Voltage Security Assessment. Presented at the IEEE Power And energy Society General Meeting, Conversion and Delivery Electrical Energy in the 21st Century.

- Karki, M. J. (2009). *Methods for On Line Voltage Stability Monitoring*. Iowa State, Iowa.
- Kerin, U., Heyde, C., Krebs, R., & Lerch, E. (2014). Real-time dynamic security assessment of power grids. *The European Physical Journal Special Topics*, 223(12), 2503–2516. <https://doi.org/10.1140/epjst/e2014-02272-1>
- Kundur, P., Cañizares, C., Paserba, J., Ajarapu, V., Anderson, G., Bose, A., ... Vittal, V. (2004). Definition and Classification of Power System Stability. *IEEE Transactions on Power Systems*, 19(2), 1387–1401. <https://doi.org/10.1109/TPWRS.2004.825981>
- Liscouski, B., & Elliot, W. (2004). Final report on the august 14, 2003 blackout in the united states and canada: Causes and recommendations. *A Report to US Department of Energy*, 40.
- Lof, P.-A., Smed, T., Andersson, G., & Hill, D. J. (1992). Fast calculation of a voltage stability index. *Power Systems, IEEE Transactions On*, 7(1), 54–64.
- Morison, K., Wang, L., & Kundur, P. (2004). Power system security assessment. *Power and Energy Magazine, IEEE*, 2(5), 30–39.
- Nguegan, Y. (2009). *Real Time Identification and Monitoring of the Voltage Stability Margin using Synchronized Phasor Measurements*. Kassel.
- Phadke, A. (1993). Synchronized phasor measurements in power systems. *IEEE Computer Applications in Power*, 6(2), 10–15. <https://doi.org/10.1109/67.207465>
- Phadke, A., & Thorp, J. S. (2008). *Synchronized Phasor Measurements and Their Applications*. Springer Science & Business Media.
- Savulescu, S. C. (2009). *Real Time Stability Assessment in Modern Power Systems Control centers*. (S. C. Savulescu, Ed.). Piscataway, NJ 08855: John Wiley & Sons.
- Torres, S. P., Peralta, W. H., & Castro, C. A. (2007). Power system loading margin estimation using a neuro-fuzzy approach. *Power Systems, IEEE Transactions On*, 22(4), 1955–1964.

2. EVALUACIÓN DE LA ESTABILIDAD DE TENSIÓN

La definición de estabilidad en sistemas de potencia es “la capacidad de un sistema eléctrico para una condición de operación inicial, de recuperar un estado de equilibrio de operación aceptable después de estar sometido a un disturbio, con la mayoría de las variables acotadas por lo que prácticamente todo el sistema se mantiene intacto” (P. Kundur, 1994; Prabha Kundur et al., 2004). Dependiendo del conjunto de fuerzas en oposición que pueden experimentar un desbalance que conducen a diferentes formas de inestabilidad, la clasificación de la inestabilidad es realizada tomando en cuenta las siguientes consideraciones (CIGRE Working Group, 2007; Prabha Kundur et al., 2004):

- La naturaleza física del modo resultante de inestabilidad que es indicada por la variable principal del sistema en el cual la inestabilidad es observada (ángulos, voltajes y frecuencia).
- El tamaño del disturbio considerado, el cual influencia el método de cálculo y la predicción de la estabilidad (grandes disturbios y pequeños disturbios).
- Los dispositivos, procesos y la ventana de tiempo que deben ser tomados en consideración con el fin de evaluar la estabilidad.

En la Figura 2.1 se muestra la clasificación de la estabilidad en sistemas de potencia, donde se muestra la clasificación concertada para los diferentes tipos de estabildades que pueden ocurrir en un sistema de potencia:

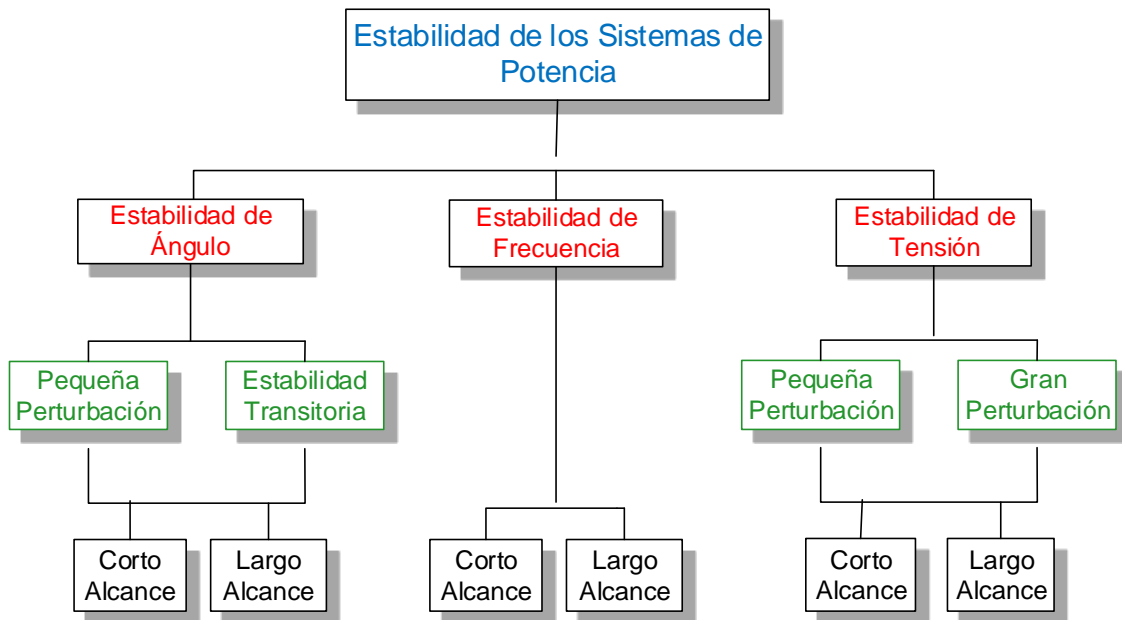


Figura 2.1. Clasificación estabilidad en los sistemas de potencia (Prabha Kundur et al., 2004).

2.1 Estabilidad de tensión

La estabilidad de tensión “se define para un condición de operación inicial como la capacidad del sistema para mantener las tensiones estables en todas los nodos del sistema después de ser sometido a una perturbación” (Ajjarapu, 2006a; Cutsem & Vournas, 1998; P. Kundur, 1994; Prabha Kundur et al., 2004; Taylor, 1994). El factor principal de la estabilidad de tensión de un sistema eléctrico es su capacidad para satisfacer la demanda de potencia reactiva requerida. Las fuerzas que impulsan a la inestabilidad de tensión son usualmente las cargas. En la operación normal del sistema la potencia generada sigue a la potencia demandada aportando suficiente potencia activa y reactiva a las cargas todo el tiempo. La inestabilidad de tensión se puede manifestar generalmente como una progresiva disminución o como un aumento de la tensión en algunos nodos del sistema de potencia.

En respuesta ante una perturbación, la potencia consumida por la carga tiende a ser restablecida por: la acción de ajuste del deslizamiento en los motores, los reguladores de tensión en la red de distribución, los cambiadores de tomas de los transformadores y los termostatos. Las cargas restablecidas incrementan la potencia sobre la red de alta tensión por el incremento del consumo de la potencia reactiva (disminución de los MVAr aportados por los capacitores de compensación en respuesta a la perturbación) causando la reducción en la tensión. La situación de aumento de carga causa la inestabilidad de tensión cuando las dinámicas de la carga intentan restaurar la potencia consumida más allá de la capacidad del sistema de transmisión y de la generación conectada (Ajjarapu, 2006a; Cutsem & Vournas, 1998; P. Kundur, 1994; Prabha Kundur et al., 2004; Taylor, 1994).

Cuando se habla de estabilidad de tensión, normalmente se usa el término de colapso de tensión que se define como el proceso por el cual la secuencia de eventos que acompaña la inestabilidad de tensión tienen a una apagón o tensiones anormalmente bajas en partes significativas en el sistema de suministro de energía eléctrica. El colapso de tensión significa entonces la imposibilidad de funcionamiento en determinada área o barras debido a los niveles inadecuados de tensión.

2.1.1 Clasificación de la estabilidad de tensión

La estabilidad de tensión se clasifica según el tipo de perturbación (Ajjarapu, 2006a; Cutsem & Vournas, 1998; P. Kundur, 1994; Prabha Kundur et al., 2004; Taylor, 1994) en:

- *Estabilidad de tensión de gran perturbación:* se refiere a la capacidad del sistema de mantener las tensiones estables después de una gran perturbación, tal como: un cortocircuito, una pérdida de generación, o contingencias. Esta capacidad está determinada por las características del sistema y de la carga, y por las interacciones entre los dispositivos de control continuo o discreto y las protecciones. El estudio del fenómeno de estabilidad de tensión de gran perturbación requiere la evaluación del sistema sobre un periodo de tiempo suficiente para capturar el comportamiento y las interacciones de los dispositivos, tales como: los motores, los transformadores y los limitadores de corriente de campo de los generadores.

- *La estabilidad de tensión de pequeña perturbación:* está asociada con la capacidad del sistema de mantener la tensión en las barras aceptables cuando se somete a pequeñas perturbaciones, tales como cambios incrementales en la carga del sistema. Esta forma de inestabilidad es influenciada por las características de la carga, los controles continuos y discretos en un instante determinado. Este concepto es útil en la determinación de como la tensión del sistema responderá ante pequeños cambios en el sistema.

En cuanto al intervalo de tiempo involucrado, la estabilidad de tensión se clasifica en:

- *Estabilidad de tensión de corto alcance:* involucra las dinámicas de rápida actuación (restauración) de las componentes de carga, tales como, motores de inducción, cargas controladas electrónicamente, y convertidores HVDC. Estos tienden a restablecer la potencia de consumo en una escala de tiempo muy rápida después de que ocurre una contingencia. El periodo de interés del orden de decenas de segundos.
- *Estabilidad de tensión de largo alcance:* involucra las actuaciones más lentas de los equipos, tales como: cambiadores de tomas de los transformadores, cargas controladas termostáticamente y limitadores de corriente de los generadores. El periodo de interés se extiende a varios o muchos minutos.

2.1.2 Métodos para el análisis de estabilidad de tensión

Análisis dinámico: los métodos de análisis dinámico adoptan que la estabilidad de tensión es un fenómeno dinámico entre los puntos de equilibrio o de operación. Para el modelo del sistema se tienen en cuenta las ecuaciones diferenciales de primer orden de las variables de estado y las ecuaciones algebraicas. Las simulaciones dinámicas (trayectoria en el dominio del tiempo) de los incidentes en el sistema de potencia que inducen la inestabilidad de tensión pueden ser representadas cronológicamente; por tanto, las dinámicas de los dispositivos de control del sistema, las operaciones de conexión, las acciones de compensación y los dispositivos de protección pueden ser considerados permitiendo la definición práctica y precisa de los límites reales de estabilidad.

Análisis estático: esta aproximación permite la evaluación de la estabilidad del estado del sistema con la ayuda de las ecuaciones de flujo de potencia. Este método captura una imagen del sistema en un punto en la trayectoria en el dominio del tiempo, las derivadas en función del tiempo de las variables de estado son iguales a cero. Consecuentemente las ecuaciones del sistema se reducen a ecuaciones algebraicas que permiten dar la indicación de la estabilidad del sistema en un punto de operación específico. Algunos de los métodos estáticos son:

- Curvas PV y QV (Taylor, 1994)
- Análisis de Sensibilidad VQ (P. Kundur, 1994)
- Análisis Modal (P. Kundur, 1994)
- Análisis de flujo de potencia continuado (Ajjarapu, 2006a; Cañizares, 2002)
- Método directo o método del punto de colapso (Cañizares, 2002)

2.1.3 Índices de estabilidad de tensión

Se han propuesto una gran variedad de índices (Cañizares, 2002; Gómez-Expósito et al., 2008; Hatziargyriou & Van Cutsem, 1994; Torres et al., 2007). La idea general del índice es definir una magnitud escalar para determinar la distancia desde punto de operación actual al límite de inestabilidad de tensión del sistema eléctrico. Es importante que el índice de estabilidad de tensión sea sensible a los cambios de carga y que presente un comportamiento predecible frente a los incrementos de la misma. Lo anterior permite extrapolar de manera sencilla qué potencia adicional puede ser suministrada por el sistema eléctrico antes de llegar al punto de inestabilidad de tensión. Es importante que los índices de estabilidad de tensión se puedan monitorear cuando los parámetros del sistema cambian, y que su cálculo sea rápido para las aplicaciones de vigilancia en línea del sistema. Los índices pueden ser clasificados en dos categorías:

a) Índices basados en el estado actual del sistema:

Estos índices consideran sólo el estado actual del sistema y se basan en el cálculo de algunas características o valores críticos que toman algunas variables cuando el sistema se acerca al punto de inestabilidad de tensión. Estos índices pueden ser obtenidos mediante mediciones simples del estado del sistema, o deducidos del jacobiano o de resultados del flujo de potencia. Los índices obtenidos por estos métodos presentan un comportamiento altamente no lineal, aunque el esfuerzo computacional para su cálculo es bajo. Algunos de los índices en esta categoría propuestos son (Cañizares, 2002; Hatziargyriou & Van Cutsem, 1994):

- Indicadores basados en diferentes mediciones simples: se realizan medición de las tensiones en barras del sistema, la medición de la reserva de la potencia reactiva en regiones del sistema.
- Indicadores que requieren la solución del flujo de carga o una salida del estimador de estados: se tiene el índice L, los factores de sensibilidad de las variables con respecto al cambio en las potencias activas y reactivas de las barras, los valores propios y valores singulares de la matriz jacobiana reducida de la potencia reactiva vs. tensión, y el índice de proximidad a la inestabilidad de tensión (VIPI, por sus siglas en inglés).

b) Índices de gran desviación:

Estos índices requieren incrementar la carga del sistema. Desde un estado actual se incrementa la carga siguiendo algún patrón predefinido de incremento, hasta llegar al punto de inestabilidad. Por lo general estos índices proveen una distancia al punto de inestabilidad en MW/MVAR. Un ejemplo, es el margen de cargabilidad que es el índice más básico y ampliamente aceptado para estimar la distancia a la frontera de inestabilidad. El margen de carga se define como la distancia en términos de potencia (parámetro de carga, λ) entre un punto de operación actual (caso base, λ_0) hasta el punto de inestabilidad de tensión (ver Figura 2.2). Este indicador toma en cuenta las no linealidades que ocurren entre el caso base y el punto de inestabilidad.

Las ventajas del margen de carga como índice de estabilidad de tensión son (Cañizares, 2002): i) Se requiere el modelo estático del sistema de potencia, puede ser usado con

modelos dinámicos, pero no depende de los detalles de la dinámica; ii) es un índice preciso que toma muy en cuenta las no linealidades del sistema y límites, tales como los límites de potencia reactiva que se encuentran cuando la carga se incrementa; iii) los límites no se reflejan directamente como cambios repentinos sobre el margen de carga y iv) el margen de carga toma en cuenta los patrones de incremento de carga (direcciones de incremento de carga en el espacio paramétrico de cargas).

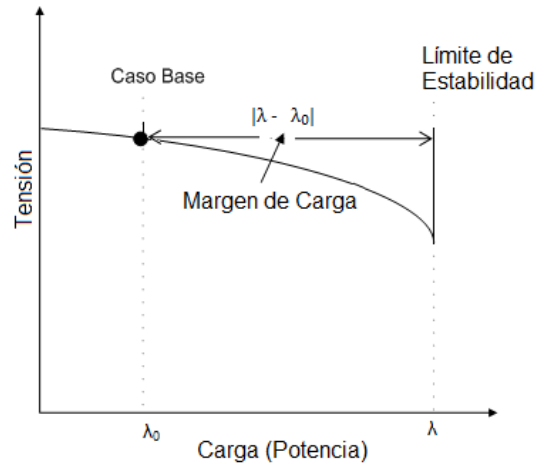


Figura 2.2. Definición del margen de carga.

Entre las desventajas del margen de carga como índice de estabilidad de tensión se tiene: i) se requieren cálculos en puntos alejados del punto de operación actual, es por esto que las exigencias computacionales son mayores que en el cálculo de los índices que se basan en usar solo información en el punto de operación actual. El costo computacional es la más seria desventaja del margen de carga. ii) se requiere asumir una dirección de incremento de carga. Esta información a menudo no se dispone fácilmente.

Se han elaborado algunos métodos específicos para incrementar la velocidad y la confiabilidad de los cálculos del límite de estabilidad de tensión. Estos son: el método de flujo de potencia continuado (Ajarapu, 2006a) y el método de punto de colapso (Cañizares, 2002).

2.1.4 Mecanismos de inestabilidad de tensión

Se han identificado dos causas de inestabilidad de tensión que se pueden detectar empleando el modelo de flujo de potencia (Cañizares, 2002; Schlueter, 1998):

- 1) *La inestabilidad de tensión causada por “La pérdida de control de tensión”:*

Esta inestabilidad es debida a que el incremento de carga del sistema produce un agotamiento en el suministro de la potencia reactiva. Esto ocurre cuando las fuentes de potencia reactiva alcanzan los límites máximos de suministro. Como resultado se tiene la pérdida del control de la tensión; es decir, las fuentes de potencia reactiva pierden la capacidad de mantener la tensión en sus bornes en el valor de referencia. Esta pérdida de control puede presentarse en un conjunto particular de generadores, o de condensadores sincrónicos o de compensadores estáticos de VAR (SVCs por sus siglas en inglés).

2) *Inestabilidad de tensión causada por “incapacidad de transmisión”:*

Al incrementarse la carga y la generación del sistema pueden producirse situaciones como:

- Aumento de las pérdidas de potencia reactiva serie (I^2X) de las líneas de transmisión motivado por excesivos flujos de potencia activa y reactiva a través de las reactancias de la red de transmisión.
- Los cambiadores de tomas de los transformadores regulables bajo carga alcanzan sus límites de operación.
- Los capacitores en conexión paralelo disminuyen su aporte de potencia reactiva debido a la reducción de tensión que experimentan sus bornes.

Estas situaciones limitan la capacidad de transmisión para transferir potencia y realizar soporte de tensión. Las pérdidas de potencia reactiva de la red que resultan de los sucesos anteriores pueden cortar completamente el flujo de potencia reactiva a una subregión que necesita suministro de potencia reactiva sin que se presente un agotamiento de las fuentes de potencia reactiva; esto es, sin que en algún generador, compensador sincrónico o dispositivo SVC se produzca la pérdida de control de tensión (Cañizares, 2002).

2.2 Monitoreo de la estabilidad de tensión en tiempo real

Para la evaluación en tiempo real se asume que los datos de entrada reflejan la imagen más reciente de las condiciones del sistema, y que el tiempo de cálculo debe ser muy corto (típicamente no debe exceder de uno o dos segundos) y que los resultados deben estar disponibles casi instantáneamente (Savulescu, 2009). Para el cálculo en línea el tiempo de cálculo es de 5 a 15 minutos, tiempo en el cual se considera que el estado del sistema no cambia significativamente. La evaluación en línea debe completarse dentro de este lapso de tiempo desde el momento de la captura del estado actual del sistema hasta que los resultados están disponibles (Morison et al., 2004).

La vigilancia de la estabilidad de tensión del sistema eléctrico debe ser entendida como un proceso continuo en tiempo real de monitoreo de la distancia a la frontera de inestabilidad. Además, es posible ejecutar la evaluación de la distancia a la frontera de inestabilidad en tiempo real usando métodos estáticos de análisis de estabilidad de tensión que son razonablemente precisos y muy rápidos (Savulescu, 2009).

2.2.1 Componentes del monitoreo de la estabilidad de tensión

En el monitoreo de la estabilidad de un sistema de potencia se siguen tres pasos principales (Nguegan, 2009):

- *Medición.* Se establece la condición del sistema a través de variables relevantes que reflejan la condición más reciente en cada instante de medición.
- *Análisis de la estabilidad de tensión.* Se determina si las condiciones operativas actuales son aceptables desde el punto de vista de la estabilidad de tensión.

- *Cálculo del margen de estabilidad de tensión.* Se evalúa la distancia del punto de operación actual a la frontera de estabilidad.

Para la evaluación de la estabilidad de tensión en tiempo real, la idea es ejecutar dicho análisis inmediatamente después que los datos de la medición estén disponibles, luego se continúa con chequeo rápido de la estabilidad usando un algoritmo rápido y confiable. Es posible ejecutar la evaluación de la estabilidad en tiempo real y monitorear la distancia a la inestabilidad usando algoritmos de estabilidad de estado estable especiales con tiempo de respuesta mucho más corta que el tiempo empleado en la estimación de estado (Savulescu, 2009).

La secuencia cronológica del proceso de la evaluación de la estabilidad en tiempo real se ilustra en la Figura 2.3. Se presenta la evaluación de la estabilidad alrededor de dos estados sucesivos de operación en los instantes T_0 y T_1 . Los datos de medición que caracterizan el comportamiento dinámico del sistema son usados como entrada en la evaluación de la estabilidad que son obtenidos en el instante T_0 por medio de los instrumentos de medición ubicados en algunas barras del sistema. Los pasos siguientes de análisis y cálculo están basados en las mediciones. La captura de un cambio en el estado del sistema sólo es posible hasta llegar al instante T_1 . El análisis de la estabilidad, el cálculo del margen y la presentación de los resultados son tareas complejas que deben ser realizadas en intervalos de tiempo apropiados para una evaluación de la estabilidad robusta en tiempo real.

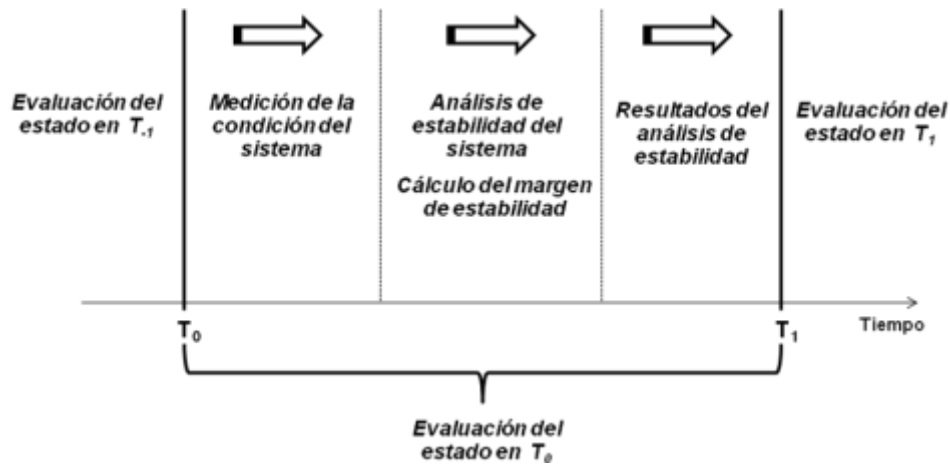


Figura 2.3. Secuencia cronológica de la evaluación de la estabilidad en tiempo real.

En la Figura 2.4, se muestran los componentes claves con el fin de cumplir con las condiciones para el monitoreo de la estabilidad de tensión. En general, la diferencia entre los distintos diseños conceptuales para la monitoreo de la estabilidad de tensión se refleja a través de las funciones que son requeridas en dicho proceso, a través de las interrelaciones entre ellas, y además a través de las diferentes variables de entrada usadas.

En la medición se obtiene una imagen de la condición del sistema provista periódicamente por un conjunto de mediciones relevantes del estado del sistema, constituyendo la fuente principal de datos para el monitoreo. La vigilancia tradicional del sistema de potencia es realizada por los SCADA, que son diseñados para capturar y entregar el comportamiento del sistema en intervalos de 5 a 20 segundos. Por esto, el sistema SCADA solo captura la

operación de estado estacionario y está limitado para el monitoreo de fenómenos dinámicos debido a que los dispositivos de medida del sistema SCADA tienen una baja densidad de muestreo y son de carácter asincrónico. Por el contrario, con las unidades PMU se pueden monitorear fenómenos dinámicos en el sistema debido a la alta densidad de muestro del dispositivo (hasta 50 ó 60 mediciones por segundo).

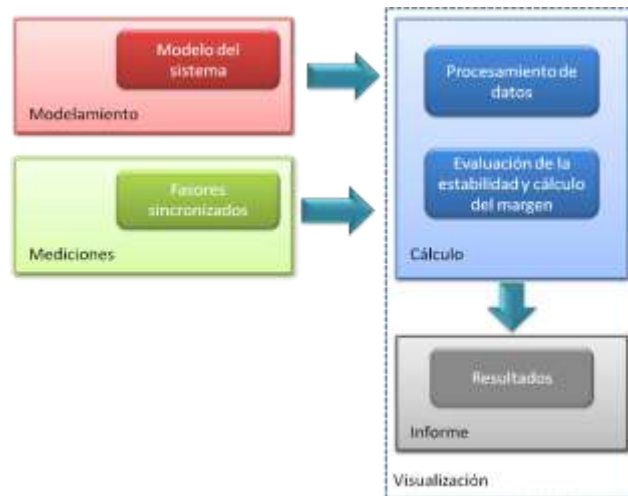


Figura 2.4. Esquema conceptual para la evaluación de la estabilidad en tiempo real (Nguegan, 2009).

Para estimar el margen de estabilidad de tensión del sistema de potencia desde los datos de medición se necesitan herramientas que extraigan esa información relevante. Las características que presentan los sistemas de IA los hacen especialmente adecuados para ser usados en ambientes de tiempo real (CIGRE Working Group, 2007; Morison et al., 2004).

Adicionalmente, existen procesos típicos para la extracción de información útil desde un conjunto de datos almacenados usando los métodos de Minería de Datos (MD) (Zhaoyang Dong et al., 2010; Nguegan, 2009).

2.2.2 Sistemas de medición sincronizada

La incorporación de las unidades de medición fasorial (PMUs) en los sistemas de potencia eléctrica ha mejorado considerablemente las posibilidades de monitoreo y análisis de las dinámicas en el sistema de potencia. Esto también ha impulsado la implementación a gran escala de los sistemas WAMs usando redes de PMUs, sistemas de comunicación y concentradores datos de fasoriales sincronizados (PDC, sigla del inglés) (Ree, Centeno, Thorp, & Phadke, 2010). Las PMUs miden fasores de tensión y de corriente sincronizados a una referencia común con una alta densidad de muestro (más de 50 ó 60 mediciones por segundo) (Ree et al., 2010). Las PMUs también miden la frecuencia local, la tasa de cambio de la frecuencia, las cantidades de las secuencias positiva, negativa y cero. Estos dispositivos brindan un gran potencial para el mejoramiento de la supervisión, la operación, la protección y el control de los sistemas de potencia modernos. La medición sincronizada de fasores permite monitorear dinámicas, identificar cambios en las condiciones del sistema, y aumentar la confiabilidad del sistema de potencia (Phadke, 1993; Phadke & Thorp, 2008; Ree et al., 2010).

La medición sincronizada de fasores (sincrofasor) corresponde a fasores que tienen como señal de referencia angular una onda coseno de frecuencia nominal (50 ó 60 Hz) sincronizada con el tiempo coordinado universal (UTC, por sus siglas en inglés); esto es, el valor máximo de la señal de referencia coincide con el cambio del segundo UTC. Se debe conocer el momento exacto del cambio del segundo UTC (máximo de la onda). Esto se hace a través de una señal de sincronización de un Pulso por Segundo (1PPS, tren de pulsos con el flanco de subida coincidente con el cambio del segundo). Por medio de la sincronización se asigna una etiqueta de tiempo al sincrofasor correspondiente a la hora UTC del instante de la medición. La fuente de sincronización más utilizada es el sistema GPS que entrega la señal de 1PPS con un error máximo de $1 \mu\text{s}$ (Phadke & Thorp, 2008).

Los sincrofasores son calculados en instalaciones geográficamente distantes con una señal de referencia común (ver Figura 2.5). Con el fin de obtener la medición simultánea de los fasores en un área amplia del sistema de potencia es necesario sincronizar estas etiquetas de tiempo, tal que todos los fasores pertenezcan al mismo instante de tiempo.




Figura 2.5. Sincrofasores.

Los sincrofasores son medidos por medio de las PMUs que son dispositivos que permiten medir el “ángulo de fase” y la amplitud de las ondas sinusoidales de tensión y de corriente AC con respecto a una referencia común. Para calcular un sincrofasor una PMU necesitará leer tanto la onda $x(t)$ como la señal de referencia sincronizada con la hora UTC (denominada onda coseno universal).

2.3 Estado del arte del monitoreo de estabilidad de tensión.

2.3.1 Monitoreo de la estabilidad de tensión basada en mediciones fasoriales sincronizadas.

Se han encontrado diferentes métodos de monitoreo de la estabilidad de tensión usando mediciones sincronizadas de fasores de tensión y corriente, y se propone la siguiente clasificación:

Monitoreo de la estabilidad de tensión de los corredores de transmisión usando WAMs.

Los corredores de transmisión se definen como conjuntos de líneas que pueden ser agrupadas, cuyos parámetros eléctricos del modelo equivalente del corredor de transmisión pueden ser calculados a partir de mediciones fasoriales sincronizadas en cada extremo del corredor. A partir de equivalentes de Thevenin de los generadores y del modelo equivalente del corredor de transmisión, se construye una red equivalente reducida para la evaluación de la estabilidad del sistema (S. Han et al., 2010; Larsson, Rehtanz, & Bertsch, 2003; Liu et al., 2008; Nguegan, Claudi, & Strunge, 2009; Zima, Larsson, Korba, Rehtanz, & Andersson, 2005).

Para esta evaluación se presenta como índice de estabilidad de tensión el margen de potencia con una frecuencia de actualización del cálculo menor de un segundo, evitando los tiempos de retardo en la estimación de mínimos cuadrados recursivos usado comúnmente en la determinación del equivalente Thevenin. Para propósito de monitoreo del sistema los resultados de los cálculos son presentados en forma de una actualización dinámica de la curva PV o de los márgenes de potencia activa.

La principal ventaja de esta metodología es que el algoritmo no requiere estimación de los parámetros del sistema de transmisión, de ahí la respuesta rápida. La desventaja es que se necesita una gran cantidad de PMUs para obtener resultados robustos del comportamiento del sistema. Además, se evalúa la estabilidad sólo para corredores de transmisión, y no se tienen en cuenta las reservas de potencia reactiva de los centros de generación.

Monitoreo de la estabilidad tensión usando la Impedancia Thevenin.

Esta metodología es una adaptación del cálculo de los parámetros del equivalente Thevenin del sistema de potencia vista desde un nodo, usando mediciones sincronizadas de fasores. Se desarrollan métodos nuevos de identificación para acelerar la estimación de los parámetros del equivalente Thevenin (tensión e impedancia), en comparación con los métodos de identificación de parámetros tradicionales. En esta aplicación de monitoreo de la estabilidad de tensión sólo requiere medidas consecutivas de los fasores de tensión y corriente; luego se calculan los parámetros del equivalente Thevenin y con esto se establece la potencia máxima transferida hacia el nodo, que se presenta cuando la impedancia Thevenin y a la impedancia de la carga son iguales en magnitud en el nodo observado (Julian et al., 2000; Vu, Begovic, Novosel, & Saha, 1999), (Corsi & Taranto, 2008; Fu, Pal, & Cory, 2008; Holen & Warland, 2002; Momoh, Xia, & Boswell, 2008; Smon, Verbic, & Gubina, 2006; Su & Wang, 2009).

Un extensión del método del equivalente Thevenin es presentado en (Holen & Warland, 2002), con el fin de mejorar la respuesta, este método incluye medidas tomadas de los nodos circundantes para asistir la estimación del equivalente Thevenin. Además, una variante del método del equivalente Thevenin (VIP++) fue introducida, la cual se basa en una predicción de la trayectoria al punto de inestabilidad de tensión, esto requiere la estimación de futuros cambios en las cargas de los nodos medidos por medio de PMUs.

El inconveniente de estas metodologías es que los índices de estabilidad propuestos poseen un comportamiento no lineal y presenta cambios bruscos por la operación de los cambiadores de toma de los transformadores y por el alcance de los límites de capacidad de potencia reactiva por parte de los generadores.

Monitoreo de la estabilidad tensión usando el equivalente Thevenin Multi-puerto.

Los generadores afectan significativamente la estabilidad de tensión, mientras que las múltiples cargas del sistema se deben tener en cuenta en la evaluación de estabilidad. Esto obliga a preservar los generadores y las cargas del sistema, al menos en una región de interés, en vez de concentrar todos los generadores y todas las cargas un circuito equivalente de un solo puerto. El resultado presentado es definido como un equivalente Thevenin multi-puerto (Gong, Schulz, & Guzman, 2006; Milosevic & Begovic, 2003).

En esta metodología se presenta un método para detectar la inestabilidad de tensión preservando la información de los generadores y las múltiples cargas del sistema de potencia. Basándose en que las PMUs están en todos los generadores y en todas las cargas, se usa una variante del equivalente Thevenin junto con la estimación de las reservas de potencia reactiva de los generadores para identificar la inestabilidad. Por otra parte, se propone un indicador para vigilar el agotamiento de las reservas de potencia reactiva de los generadores del sistema.

En este método no se presenta ninguna relación entre la disponibilidad de la potencia reactiva y el índice de estabilidad de tensión propuesto. Además, se producen cambios súbitos en el índice cuando los generadores alcanzan los límites de capacidad de potencia reactiva.

Monitoreo de la estabilidad basada en estimación o reconstrucción del estado del sistema.

Esta categoría es diferente de los otros métodos en el sentido en que la ubicación de las PMUs no es escogido para el propósito del monitoreo de la estabilidad de tensión, sino más bien, para estimar el vector de estado de las tensiones complejas en los nodos en una región entera que está sujeto a inestabilidad de tensión (Glavic & Van Cutsem, 2011). En (Genet & Maun, 2007) la caída de tensión en la impedancia Thevenin se aproxima por medio de la suma de los valores absolutos de las caídas de tensión complejas, en las ramas localizadas en los caminos más cortos desde los nodos de interés a los generadores que realizan el control de tensión. El criterio de la impedancia Thevenin es reemplazado por el criterio de adaptación de caída de tensión, un ajuste en el umbral de alarma es necesario para compensar la naturaleza heurística del método.

Un método preciso para la detección de la inestabilidad de tensión puede ser obtenido a partir de las condiciones de singularidad propiamente calculadas de la matriz Jacobina del sistema. Al respecto, en (Balamourougan, Sidhu, & Sachdev, 2004) se propone un método que requiere únicamente la información del fasor de voltaje en un nodo y la matriz de impedancia de la red para evaluar la estabilidad de tensión en un nodo, en forma de un índice de predicción del colapso de tensión. Este índice está basado en la singularidad de la matriz Jacobiana de las ecuaciones de flujo de potencia estándar, en el artículo sólo se consideraron escenarios de pequeños aumentos de carga.

En (Glavic & Van Cutsem, 2009a, 2009b) después de tener disponible el estado del sistema provisto por las mediciones fasoriales, se ajusta un conjunto de las ecuaciones algebraicas a los estados muestreados del sistema; luego, se ejecuta un cálculo eficiente de la sensibilidad con el fin de identificar cuando una combinación de potencias en las cargas han sobrepasado un máximo. Se tienen en cuenta efectos importante como son los límites de sobreexcitación de los generadores y los límites de los tomas de derivación de los transformadores de potencia.

La sensibilidad está definida como la inversa de la matriz jacobiana de las ecuaciones de flujo de potencia. Se considera propiamente la sensibilidad entre la potencia reactiva aportada por todos los generadores y la potencia reactiva individual de cada carga. Estas sensibilidades son usadas para identificar cuando la potencia en la carga pasa a través del máximo. En este punto, las sensibilidades cambian desde un gran valor positivo a un gran valor negativo. En teoría la sensibilidad debería tender a infinito, pero en la práctica las discontinuidades y la trayectoria de muestreo pueden evitar que se alcancen valores muy altos. Sin embargo, el cambio abrupto en el signo provee una indicación clara de inestabilidad de tensión. El modelo algebraico del cual es calculada la matriz Jacobiana asume que las dinámicas de corto plazo están en equilibrio.

Otra importante característica es la anticipación de la activación del limitador de sobreexcitación (OEL, por su sigla en inglés) de los generadores cuando se forma el Jacobiano del sistema. Para esto se realiza una estimación de la tensión E_q que es proporcional a la corriente de campo del generador, el valor de tensión es usado para identificar si el generador sincrónico opera bajo el control de su regulador automático de tensión (AVR, sigla en inglés) o tiene su corriente de campo limitada por el OEL. Esta aproximación provee una buena capacidad de anticipación de la activación del OEL en la evaluación de la estabilidad de tensión (Glavic & Van Cutsem, 2009b).

La estimación de la sensibilidad es bastante afectada en la precisión por el ruido en las mediciones de tensiones, por lo cual se proponen filtros para mejorar el desempeño. El inconveniente en esta metodología es la dependencia del número de PMUs instaladas en los nodos del sistema para monitorear la sensibilidad ante la variación de potencia reactiva del sistema.

Monitoreo usando sistemas de inteligencia artificial.

Este método se basa en la construcción de una base de datos de aprendizaje en modo fuera de línea. Dicha base está conformada por las variables eléctricas que permiten determinar el estado del sistema de potencia en tiempo real. Se realiza el entrenamiento de la herramienta de IA con la base de datos que contiene diversas condiciones de operación del sistema. Después, con las medidas disponibles en tiempo real se ingresan a la herramienta de IA y su salida provee un indicador de la estabilidad de tensión. Para estas herramientas, para un sistema de potencia dado, se generan fuera de línea y se usan luego eficientemente en tiempo real (Morison, 2006; Vittal, 2008; Diao et al., 2009; Jeyasurya, 2000; Chakrabarti & Jeyasurya, 2004; Nakawiro & Erlich, 2008; Zhou, Annakkage, & Rajapakse, 2010; Shaikh & Asghar, 2011; Bahmanyar & Karami, 2014; Goh et al., 2015; Zhukov, Tomin, Sidorov, Panasetsky, & Spirayev, 2015; Subramani, Jimoh, Kiran, & Dash, 2016). Se han encontrado algunas técnicas de IA para el monitoreo de la estabilidad de tensión, y se propone la siguiente división:

Redes neuronales artificiales (RNAs):

Se ha trabajado con RNAs en (Bahmanyar & Karami, 2014; Chakrabarti & Jeyasurya, 2004; Goh et al., 2015; Jeyasurya, 2000; Nakawiro & Erlich, 2008; Subramani et al., 2016; Zhou et al., 2010; Zhukov et al., 2015) para la estimación del margen de estabilidad de tensión en la estabilidad de tensión largo alcance. Se busca que para diferentes condiciones de operación del sistema, la RNA identifica las relaciones existentes entre un conjunto de entradas y la salida que es el margen de estabilidad. Se ha encontrado que las magnitudes de tensión en los nodos y sus ángulos son las variables de entradas a la RNA, que presentan menores errores en la estimación del margen de estabilidad de tensión.

En (Subramani et al., 2016) se presenta la estimación del índice de estabilidad para la evaluación de la estabilidad de tensión, usando las RNAs como herramienta de estimación. En este trabajo se utilizan la red neuronal multicapa de propagación hacia atrás y la red de función básica radial, las cuales fueron empleadas para estimar el índice de estabilidad propuesto. Se emplea un índice de estabilidad tipo línea, es decir, con este solo se vigila los límites de transferencia de las líneas que producen inestabilidad de tensión. Las técnicas de IA empleadas fueron usadas en un sistema pequeño, para el cual su comportamiento es bueno, no se validó la propuesta en un sistema con un número mayor de nodos o variables en los cuales se pueden presentar problemas de mala generalización de las RNAs. En (Goh et al., 2015) se considera el uso de RNA con propagación hacia atrás para el monitoreo de la estabilidad de tensión en sistemas de potencia, esto con fin de proveer una señal de alarma antes del que sistema colapse. Se usan índices de estabilidad de tensión tipo línea con el inconveniente ya mencionado, donde solo se predice la línea de transmisión más crítica debido a la cual el sistema puede experimentar inestabilidad. Un inconveniente del método presentado es debido a que la RNA demanda bastante tiempo tanto en la fase entrenamiento como la fase de actualización de la RNAs ante nuevas condiciones.

En (Bahmanyar & Karami, 2014) se propone una RNA con un conjunto reducido de variables de entrada para afrontar el problema del monitoreo de la estabilidad de tensión. El monitoreo se realiza por medio de la estimación del margen de estabilidad de tensión (VSM, del inglés); esto es, la distancia desde el punto actual del sistema a la frontera de estabilidad. La reducción del conjunto de variables de entrada se logra por medio de un proceso de ortogonalización de Gram – Schmidt junto con una técnica de análisis de sensibilidad basada en una RNA, resultando en una herramienta eficiente para la selección de características (reducción de datos), que permite identificar un conjunto reducido de entradas requeridas para aproximar el VSM con buena precisión y rapidez. En este trabajo solo se tienen en cuenta las contingencias más críticas del sistema, la criticidad es definida por el nivel de reducción del VSM; es decir, la contingencia más crítica corresponde al VSM. Esta forma de considerar las contingencias no cubre las contingencias que son menos críticas, pero que tienen mayor probabilidad de que ocurran en el sistema. Por otra parte, como variables de entrada solo se emplea la magnitud de las tensiones nodales y no se incluye la información que pueda entregar el ángulo de fase de los nodos.

En (Bulac, Triștiu, Mandiș, & Toma, 2015) se plantea una RNA tipo perceptron multicapa para el monitoreo en línea de la estabilidad de tensión. El índice de estabilidad empleado para el monitoreo es el valor singular de la matriz Jacobiana del modelo de flujo de potencia. Esta red es entrenada para aprender la correlación de entradas claves que caracterizan el fenómeno de estabilidad de tensión y el índice propuesto. Aunque el índice

de estabilidad basado en valor singular es un índice global tiene la desventaja principal de no entregar información precisa de que tan cerca se encuentra el sistema de la frontera de inestabilidad. Las entradas empleadas para entrenar la RNA no contemplan el uso de las tensiones y corrientes complejas tomadas desde las PMUs. Otro inconveniente es que la RNA consume bastante tiempo tanto en el entrenamiento como la actualización de la red ante nuevas condiciones del sistema que no fueron consideradas a priori.

Para mejorar el monitoreo de la seguridad de tensión del sistema de potencia se ha propuesto un esquema híbrido de RNAs en (Zhukov et al., 2015). El esquema híbrido combina habilidad de clasificación de la red Kohonen de los estados de operación del sistema, y la salida de esta red es usada como entrada en la red de propagación hacia atrás para la identificación de estados de alarma que resultan peligrosos para la seguridad del sistema, y para estimar el margen de voltaje en los nodos del sistema se emplea una red recurrente tipo Elman. Entre los inconvenientes que se presentan en este esquema se tiene que la RNA Kohonen presenta problemas en la clasificación de los estados. Esto sucede cuando no se cuenta con variables de entrada adecuadas, dificultando la labor de clasificación. Entre las variables de entrada se tiene la magnitud de las tensiones, potencias activas y reactivas, variables que dependen de los sistemas de estimación de estado y de los dispositivos de medición PMUs. Como es un esquema híbrido de RNAs los tiempos de la fase de entrenamiento son considerables debido a la gran cantidad de variables de entrada, esto se presenta para sistemas de potencia de mediano y gran tamaño.

En (Hashemi & Aghamohammadi, 2013) los autores proponen ejecutar la evaluación en tiempo real de la estabilidad de tensión usando la herramienta Wavelet, combinada con una red neural de función radial base. Se realiza la estimación del VSM aplicando un método de extracción de características con la técnica de Multiresolución Wavelet (MRWT, por su sigla en inglés), después se aplica el Análisis de Componentes Principales (ACP) para seleccionar las características más relevantes entregadas por MRWT. La RNA de función radial es aplicada para la estimación del VSM, usando las características más relevantes entregadas por las técnicas anteriores. Estas entradas están constituidas por el perfil de tensiones de los nodos tomados por las unidades de medición fasorial (PMU, del inglés). En el trabajo no se realiza una evaluación de cómo los cambios topológicos debido a las contingencias afectan el método propuesto para la evaluación de la estabilidad. Se menciona que las contingencias no afectan el método propuesto, pero no se presenta información que soporte esta afirmación. También se menciona que el método trabaja bien en condiciones dinámicas, para lo cual no se presenta información que lo soporte. Por lo cual este método propuesto no tiene una respuesta robusta ante las condiciones mencionadas anteriormente.

En (Rahi, Yadav, Malik, Azeem, & Kr, 2012) se propone un método para determinar la estabilidad de tensión de estado estable de los nodos de carga, donde se consideran diferentes condiciones de carga y se identifican los nodos que están propensos al colapso de tensión. Se propone una RNA de propagación hacia atrás para realizar la predicción del índice de estabilidad denominado “ L ”, calculado para cada nodo de carga del sistema. El nodo con índice L más alto es el nodo más vulnerable del sistema, lo que permite identificar áreas débiles en el sistema de potencia. En el método propuesto no se tienen en cuenta las contingencias y un gran número de diferentes condiciones de generación y demanda. El índice L está relacionado con la máxima capacidad de transferencia por las líneas del

sistema, pero no tienen en cuenta como las reservas de potencia reactiva afectan la estabilidad de tensión del sistema.

En (Innah & Hiyama, 2011) se propone una RNA de función radial para evaluar la estabilidad de tensión usando el índice L . Se construye la base de datos de estabilidad con los valores de las tensiones en los nodos y el correspondiente índice de estabilidad. Luego se entrena la RNA de función radial para que realice la predicción del índice L . Se realizó un análisis de sensibilidad sobre el número de unidades de medición fasorial usada en la predicción, se concluye que medidas con valores constantes de magnitud no entregan información relevante para la RNA. Por otra parte, el índice L está relacionado con la máxima capacidad de transferencia por las líneas del sistema, pero no tienen en cuenta como las reservas de potencia reactiva afectan la estabilidad de tensión del sistema.

En (Zhou et al., 2010) se propone la estimación del margen de estabilidad de tensión en la estabilidad de tensión largo alcance usando RNAs del tipo de propagación hacia atrás. Este trabajo se busca que, para diferentes condiciones de operación del sistema, la RNA identifique las relaciones existentes entre un conjunto de entradas y la salida que es el margen de estabilidad. Se ha encontrado que las magnitudes de tensión en los nodos y sus ángulos son las variables de entradas a la RNA, que presentan errores menores en la estimación del margen de estabilidad de tensión. La principal desventaja del método propuesto yace en que la precisión del sistema inteligente es directamente proporcional al número de PMUs instaladas en el sistema, para lo cual se propone una selección de la ubicación por medio de una técnica de optimización, o una reconstrucción del estado del sistema a partir de un número limitado de PMUs instaladas en el sistema.

En (Leonardi & Ajjarapu, 2010) se ha presentado una técnica para estimar el margen de estabilidad de tensión en tiempo real, basada en los modelos de regresión multi-lineal y una RNA con el fin de estimar la distancia a la frontera de estabilidad. Los modelos de regresión permiten relacionar la reserva de la potencia reactiva de los generadores con el margen de estabilidad de tensión, y la RNA permite la selección correcta de los modelos lineales de acuerdo con la condición operativa real existente en el sistema.

Arboles de decisión (AD):

También se han aplicado árboles de decisión en la estimación del margen de estabilidad, los atributos de decisión probados en varios de los nodos del árbol son los datos colectados de las PMUs en puntos de operación del sistema después de iniciarse el evento o disturbio. Diferentes atributos son usados como: las diferencias de los ángulos de voltaje entre los nodos, las magnitudes de voltaje en los nodos, las caídas de tensión en las líneas, el flujo de potencia reactiva en las líneas, las corrientes en las líneas y la potencia reactiva en los generadores (Diao et al., 2009; Karki, 2009; Vittal, 2008).

El mejor desempeño que se ha obtenido se logra con el uso combinado de las magnitudes de corriente en las ramas y la información de fallas. Los árboles son actualizados cada hora con el fin de tener en cuenta los cambios de estado del sistema.

El principal inconveniente práctico de este método es la capacidad de conformar un conjunto de aprendizaje representativo, en el contexto de la estabilidad de tensión, este debe involucrar una variedad de puntos de operación y disturbios incluyendo escenarios

estables e inestables, al igual que se debe considerar diferentes topologías debida a la consideración de contingencias N-1.

Máquinas de Soporte Vectorial (MSV):

En (Duraipandy & Devaraj, 2014) se propone una MSV para la evaluación de la estabilidad de tensión en línea, con un conjunto reducido de variables de entrada para el sistema inteligente. Para reducir el conjunto de entrada para las MSVs se plantea reducir la dimensión de las variables de entrada usando técnicas como ACP combinada con una técnica de selección de característica basada en Información Mutua (MI). Para realizar el monitoreo de la estabilidad de tensión se emplea el VSM. Se consideran únicamente las contingencias más severas que impactan de forma negativa el VSM del sistema. Las variables de entrada seleccionadas por el método propuesto son las potencias activas y reactivas de los nodos de carga del sistema, no se consideran tensiones fasoriales de los nodos del sistema. Para la estimación de VSM no se aclara si se consideran los límites de potencia reactivas de las fuentes generadoras del sistema.

En otra investigación se propone un esquema híbrido de inteligencia artificial compuesto por una máquina de soporte vectorial, MSV, y un sistema inmune artificial (SIA) para realizar la predicción de la estabilidad de tensión (AbAziz, Rahman, & Zakaria, 2014). Se presenta el índice de condición de estabilidad de tensión (VSCI, del inglés) como herramienta de evaluación de la estabilidad de los nodos de carga del sistema, la MSV se utiliza para estimar el VSCI y el SIA se utiliza para optimizar los parámetros del MSV. El índice de estabilidad VSCI propuesto es un índice de estabilidad tipo línea, que solo vigila la inestabilidad causada por los vínculos de transmisión. Para realizar la estimación del VSCI se necesita la potencia activa y reactiva no se tienen en cuenta las mediciones de los fasores de tensiones de los nodos del sistema.

Continuando con la MSV en la estimación del VSM del sistema de potencia, en (Suganyadevi & Babulal, 2014) se propone la regresión de soporte vectorial (RSV), la cual es la forma más común de aplicación de MSV. El método propuesto con RSV permite estimar el margen de cargabilidad del sistema en condiciones normales de operación y diferentes direcciones de crecimiento de la demanda. En este trabajo no se consideran como las contingencias afectan la estimación del margen de cargabilidad del sistema; es decir, no se consideran condiciones post falla del sistema. También no se tiene claridad sobre si la estimación del margen de cargabilidad se realiza considerando los límites de potencia reactivas de las fuentes del sistema. Además, dentro de las variables de entrada para la RSV no se consideran las tensiones fasoriales de los nodos del sistema entregadas por las PMUs.

Para el monitoreo en línea de la estabilidad de tensión de largo alcance también se ha propuesto el uso combinado de una máquina de soporte vectorial (MSV) y un algoritmo genético (Sajan, Kumar, & Tyagi, 2015). La máquina de soporte vectorial se emplea como herramienta de estimación y el algoritmo genético se utiliza para mejorar la precisión y tiempo de entrenamiento de la MSV. Se utilizan como entradas para la MSV las tensiones complejas de los nodos proporcionada por las PMUs y la salida es el margen de estabilidad de tensión, con lo cual se emula la herramienta del flujo continuado de potencia. En este artículo no se tiene en cuenta la ocurrencia de contingencias y el impacto de estas en el índice de estabilidad de tensión. Por otra parte, solo tienen en cuenta la distancia a la

frontera de estabilidad debida a la máxima cargabilidad del sistema de potencia (SNB) y no se considera la inestabilidad causada por la deficiencia de la potencia reactiva desde las fuentes.

Máquinas de Aprendizaje Extremo (MAE)

En (Velayati, Amjady, & Khajevandi, 2015) se desarrolla una nueva alternativa para determinar la categoría de estabilidad de tensión (clasificación de la estabilidad) basado en un proceso de pronóstico. La evaluación de la estabilidad de tensión se realiza por medio de herramientas de análisis de bifurcación de tipo Hof (HB, del inglés) y de límite inducido (LIB, del inglés). La estrategia de pronóstico se realiza usando técnicas de selección de características combinado con máquinas de aprendizaje extremo (MAE) y búsqueda en línea. En este trabajo se aborda como un problema de clasificación, lo que no permite obtener un margen de la estabilidad con el método propuesto; por otra parte, el método presentado solo tiene en cuenta la frontera de estabilidad de tipo HB y LIB, estas son importantes para el sistema. Pero es de vital importancia tener en cuenta la bifurcación tipo nodo silla (SNB, del inglés) o punto de máxima cargabilidad del sistema de potencia, que no se tienen en cuenta en el trabajo.

Para la predicción del VSM se propone una técnica de inteligencia artificial, tal como las máquinas de aprendizaje extremo (MAE); debido a la complejidad del problema que se quiere solucionar al usar las MAE se encontraron problemas de generalización, es decir, sobreestimación o subestimación que aumenta el error en la respuesta de la MAE (Zhang, Xu, Dong, Zhang, & Wong, 2013). Debido a los problemas de generalización de una MAE se propone construir un conjunto de MAEs para solucionar el problema. Con el método propuesto se mejora la respuesta en la predicción de VSM pero el inconveniente más importante es el aumento de los tiempos de entrenamiento de las MAE. En el trabajo se usa el VSM como índice para evaluar la estabilidad de tensión, no se menciona que en la predicción se tengan en cuenta los límites de potencia reactiva de los generadores y fuentes de reactiva. Estos límites afectan de forma negativa el índice VSM.

En la Tabla 2.1 se presenta una síntesis de los trabajos más relevantes de IA, se realiza un análisis donde se presenta la forma de monitorear el sistema, correspondiente al índice de estabilidad usado; la técnica de IA implementada y se identifican los principales inconvenientes o problemas no resueltos encontrados en el monitoreo de la estabilidad de tensión.

Tabla 2.1. Resumen de la implementación de técnicas de IA para monitoreo de la estabilidad de tensión.

Referencia	Implementación	IA	Problemas no resueltos
Subramani et al., 2016.	Monitoreo realizado a través de la estimación de índice de estabilidad global, usando una RNA de propagación hacia atrás.	RNAs	La implementación propuesta es afectada por la cantidad de PMUs, para un sistema de potencia mediano o grande se presenta problemas de generalización.
Goh et al., 2015	Monitoreo con un índice de estabilidad tipo línea usando una RNA de propagación hacia atrás, provee una señal de alarma.	RNAs	Sólo se identifica la línea más crítica que cause la inestabilidad, la RNA demanda bastante tiempo tanto en la fase de entrenamiento como en la actualización de la RNA ante nuevas condiciones.

Bahmanyar & Karami, 2014	Se realiza el monitoreo con el índice VSM y un perceptrón simple, se combina con una técnica para reducir de las entradas a la RNA.	RNAs	En las contingencias evaluadas no consideran las menos críticas, pero con mayor probabilidad ocurrencia.
Bulac, Triștiu, Mandiș, & Toma, 2015	El índice para el monitoreo es el valor singular de la matriz Jacobiana, se usa una RNA perceptron multicapa	RNAs	El índice usado no entrega información de la distancia a la frontera de inestabilidad. Las entradas de la RNA no son las tensiones y corrientes complejas.
Zhukov et al., 2015	Se propone un esquema híbrido de RNA (Kohonen, propagación hacia atrás y Elman) para estimar el índice de seguridad que vigila los flujo de potencia.	RNAs	La RNA Kohonen presenta problema en la clasificación de los estados, los tiempos de entrenamiento son considerables debido a la gran cantidad de variables de entrada.
Hashemi & Aghamohammadi, 2013	Se ejecuta el monitoreo usando la extracción de características y ACP, combinada con una RNA de función radial base para la estimación de VSM.	RNAs	No se realiza una evaluación de cómo las salidas de líneas afectan el método propuesto y solo se evaluó un sistema pequeño.
Rahi, Yadav, Malik, Azeem, & Kr, 2012	Se usa índice L para cada nodo de carga, identificando los nodos propensos a la inestabilidad, se usa la RNA con propagación hacia atrás	RNAs	El índice L vigila la máxima capacidad de transferencia en las líneas. No se tienen en cuenta las contingencias y consideran pocos escenarios de generación y demanda.
Innah & Hiyama, 2011	Proponer una RNA de función radial para evaluar la estabilidad de tensión usando el índice L .	RNAs	El índice L vigila la máxima capacidad de transferencia en las líneas, no tienen en cuenta las reservas de potencia reactiva afectan la estabilidad.
Zhou et al., 2010	Se estima el VSM usando RNAs de propagación hacia atrás.	RNAs	La precisión de la RNA es proporcional al número de PMUs instaladas en el sistema.
Leonardi, 2010	Se estima VSM basado en modelos de regresión multilineal y la reserva de potencia, la RNA selecciona el modelo lineal de acuerdo a la condición operativa.	RNAs	No se tiene en cuenta como los límites transferencia en las líneas afectan la estabilidad.
Diao et al., 2009	Se realiza el monitoreo usando el índice VSM, con los ADs se estima el índice para diversas condiciones de operación.	AD	No se conformó un conjunto representativo para el aprendizaje del AD, no se consideraron contingencias.
Duraipandy & Devaraj, 2014	Para el monitoreo se usa el VSM y una MSV de mínimo cuadrático, con un conjunto reducido de variables de entrada por medio del ACP y MI.	MSV	Se consideran contingencias más severas del sistema, en la estimación de VSM no se consideran los límites de reactiva de generadores.
AbAziz, Rahman, & Zakaria, 2014	Se realiza monitoreo por medio del VSCI, se estima con MSV combinada con SIA para optimizar los parámetros de la IA.	MSV	El VSCI es un índice que solo vigila la inestabilidad causada por los vínculos de transmisión. No se consideran las mediciones de los fasores de tensiones.
Suganyadevi &	Se vigila la estabilidad usando	MSV	No se consideran la influencia de las

Babulal, 2014	el índice VSM y el sistema inteligente RSV.		contingencias en el VSM, tampoco se consideran las tensiones fasoriales.
Sajan, Kumar, & Tyagi, 2015	Se propone el uso combinado de una MSV y un algoritmo genético para el monitoreo.	MSV	No se tiene en cuenta contingencias y el impacto en VSM. No se considera la inestabilidad causada por la deficiencia de la potencia reactiva desde las fuentes.
Velayati, Amjady, & Khajevandi, 2015	Se clasifica la estabilidad usando el análisis de bifurcación HB y LIB, combinada con una herramienta de selección de características y MAE.	MAE	Se aborda como un problema de clasificación, no se obtiene un margen de la estabilidad.
Zhang, et al., 2013	Se realiza el monitoreo usando el índice VSM, y se estima con una MAE.	MAE	Se presentan problemas de generalización en la IA, al combinar varias IAs se incrementa el tiempo de entrenamiento.

Monitoreo de la estabilidad de tensión basado en el monitoreo de la reserva de potencia reactiva.

Esta metodología propone vigilar las reservas de potencia reactiva disponibles para el control de tensión en diferentes áreas del sistema de potencia. La reserva de potencia reactiva disponible en algunos generadores claves, condensadores sincrónicos y compensadores estáticos son indicadores sensibles del estrés del sistema o de la vulnerabilidad ante una inestabilidad de tensión (Bao, Huang, & Xu, 2003; Corsi, 2009; B. Leonardi & Ajarapu, 2008; Bruno Leonardi & Ajarapu, 2011), (Corsi, 2010).

Se hace énfasis en la necesidad de la determinación efectiva de las reservas de potencia reactiva teniendo en cuenta que las fuentes de potencia reactiva deben estar cercanas al área afectada para ser efectivas. Por tanto, existe la necesidad de encontrar una relación entre la reserva de potencia reactiva y el margen de estabilidad de tensión (Bao et al., 2003; B. Leonardi & Ajarapu, 2008). También se han discutido y analizado diferentes definiciones de reserva de potencia reactiva. En (Bruno Leonardi & Ajarapu, 2011) se plantea la utilización de modelos de regresión multi lineal para transformar la variación de la reserva de potencia reactiva en información directa del margen de estabilidad de tensión.

La desventaja de este método es que no tiene en cuenta la inestabilidad de tensión causada por la incapacidad de transmisión en el sistema, esto sucede cuando la potencia transmitida es mayor a la capacidad de transmisión de potencia en las líneas y transformadores del sistema.

Monitoreo de la estabilidad de tensión basada en métodos libre de modelo (descomposición en valores singulares).

El método propuesto aplica la descomposición de valores singulares a una matriz de mediciones. Cada columna de esta matriz incluye los valores medidos entregados en un instante determinado por varios dispositivos PMUs, y varias columnas corresponden a varios instantes sucesivos de medición de los dispositivos PMUs. La matriz es actualizada en cada instante de muestreo con los nuevos datos de medida adquiridos (Overbye, Sauer, DeMarco, Lesieutre, & Venkatasubramanian, 2010).

La estabilidad de tensión es monitoreada por medio del cálculo y rastreo del valor singular más grande de esta matriz. Este método libre de modelo podría ser una manera interesante de tomar ventaja de un número limitado de PMUs instaladas. Son necesarios un soporte teórico adicional y la validación en un sistema real para demostrar este método como una solución práctica viable.

2.4 Conclusiones

Las técnicas de IA son una alternativa promisoría en el monitoreo de la estabilidad de tensión de largo alcance en sistemas de potencia, que permite cumplir con los requerimientos de valoración de la estabilidad en tiempo cercano al real. Entre las técnicas IAs para monitoreo de la estabilidad, se encontraron trabajos con: redes neuronales artificiales, máquinas de soporte vectorial y máquinas de aprendizaje extremo brindando robustez, adaptabilidad y flexibilidad. En la implementación de la IA se usan índices para la evaluación de la estabilidad de tensión, se debe tener especial cuidado en el índice usado debido a que dependiendo del tipo de índice se vigila un determinado mecanismo de inicio de la inestabilidad de tensión, esto es, inestabilidad por deficiencia de reserva de potencia reactiva o por superar la máxima transferencia de potencia en las líneas de transmisión.

2.5 Bibliografía

- AbAziz, N. F., Rahman, T. K. A., & Zakaria, Z. (2014). Voltage stability prediction by using Artificial Immune Least Square Support Vector Machines (AILSVM). In *Power Engineering and Optimization Conference (PEOCO), 2014 IEEE 8th International* (pp. 613–618). <https://doi.org/10.1109/PEOCO.2014.6814501>
- Ajjarapu, V. (2006). *Computational Techniques for Voltage Stability Assessment and Control*. Springer.
- Bahmanyar, A. R., & Karami, A. (2014). Power system voltage stability monitoring using artificial neural networks with a reduced set of inputs. *International Journal of Electrical Power & Energy Systems*, 58, 246–256. <https://doi.org/10.1016/j.ijepes.2014.01.019>
- Balamourougan, V., Sidhu, T. S., & Sachdev, M. S. (2004). Technique for online prediction of voltage collapse. *Generation, Transmission and Distribution, IEE Proceedings-*, 151(4), 453–460. <https://doi.org/10.1049/ip-gtd:20040612>
- Bao, L., Huang, Z., & Xu, W. (2003). Online voltage stability monitoring using var reserves. *Power Systems, IEEE Transactions On*, 18(4), 1461–1469.
- Bulac, C., Triștiu, I., Mandiș, A., & Toma, L. (2015). On-line power systems voltage stability monitoring using artificial neural networks. In *2015 9th International Symposium on Advanced Topics in Electrical Engineering (ATEE)* (pp. 622–625). <https://doi.org/10.1109/ATEE.2015.7133884>
- Cañizares, C. A. (2002). *Voltage Stability Assessment: Concepts, Practices and Tools, IEEE/PES Power System Stability Subcommittee*. Tech. Rep. SP101PSS.
- Chakrabarti, S., & Jeyasurya, B. (2004). On-line voltage stability monitoring using artificial neural network. In *2004 Large Engineering systems Conference on Power Engineering, 2004. LESCOPE-04* (pp. 71–75). <https://doi.org/10.1109/LESCPE.2004.1356271>
- CIGRE Working Group, C. 60. (2007). *CIGRE Technical Brochure on Review of On Line Dynamic Security Assessment Tools and Techniques*.
- Corsi, S. (2009). Wide Area Voltage Regulation and Protection. In *PowerTech, 2009 IEEE Bucharest* (pp. 1–7). <https://doi.org/10.1109/PTC.2009.5282180>
- Corsi, S. (2010). Wide area voltage protection. *IET Generation, Transmission Distribution*, 4(10), 1164–1179. <https://doi.org/10.1049/iet-gtd.2009.0496>
- Corsi, S., & Taranto, G. N. (2008). A Real-Time Voltage Instability Identification Algorithm Based on

- Local Phasor Measurements. *IEEE Transactions on Power Systems*, 23(3), 1271–1279. <https://doi.org/10.1109/TPWRS.2008.922586>
- Cutsem, T. van, & Vournas, C. (1998). *Voltage Stability of Electric Power Systems*. Springer.
- Diao, R., Sun, K., Vittal, V., O’Keefe, R. J., Richardson, M. R., Bhatt, N., ... Sarawgi, S. K. (2009). Decision tree-based online voltage security assessment using PMU measurements. *Power Systems, IEEE Transactions On*, 24(2), 832–839.
- Dong, Z., Zhang, P., Ma, J., Zhao, J., Ali, M., Meng, K., & Yin, X. (2010). *Emerging Techniques in Power System Analysis* (2010th ed.). Springer.
- Duraipandy, P., & Devaraj, D. (2014). On-line voltage stability assessment using least squares support vector machine with reduced input features. In *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT)* (pp. 1070–1074). <https://doi.org/10.1109/ICCICCT.2014.6993119>
- Fu, L., Pal, B. C., & Cory, B. J. (2008). Phasor measurement application for power system voltage stability monitoring. In *Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE* (pp. 1–8). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4596089
- Genet, B., & Maun, J.-C. (2007). Voltage-Stability Monitoring Using Wide-Area Measurement Systems. In *Power Tech, 2007 IEEE Lausanne* (pp. 1712–1717). <https://doi.org/10.1109/PCT.2007.4538573>
- Glavic, M., & Van Cutsem, T. (2009a). Wide-area detection of voltage instability from synchronized phasor measurements. Part I: Principle. *Power Systems, IEEE Transactions On*, 24(3), 1408–1416.
- Glavic, M., & Van Cutsem, T. (2009b). Wide-Area Detection of Voltage Instability From Synchronized Phasor Measurements. Part II: Simulation Results. *IEEE Transactions on Power Systems*, 24(3), 1417–1425. <https://doi.org/10.1109/TPWRS.2009.2023272>
- Glavic, M., & Van Cutsem, T. (2011). Investigating state reconstruction from scarce synchronized phasor measurements. In *PowerTech, 2011 IEEE Trondheim* (pp. 1–8). <https://doi.org/10.1109/PTC.2011.6019163>
- Goh, H. H., Chua, Q. S., Lee, S. W., Kok, B. C., Goh, K. C., & Teo, K. T. K. (2015). Evaluation for Voltage Stability Indices in Power System Using Artificial Neural Network. *Procedia Engineering*, 118, 1127–1136. <https://doi.org/10.1016/j.proeng.2015.08.454>
- Gómez-Expósito, A., Conejo, A. J., & Cañizares, C. (2008). *Electric Energy Systems: Analysis and Operation* (1st ed.). New York: CRC Press.
- Gong, Y., Schulz, N., & Guzman, A. (2006). Synchrophasor-based real-time voltage stability index. In *Power Systems Conference and Exposition, 2006. PSCE’06. 2006 IEEE PES* (pp. 1029–1036). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4075891
- Han, S., Lee, B., Kim, S., Moon, Y., Chang, B., & Shin, J. (2010). Voltage stability monitoring using PMU data in KEPCO system. In *Transmission and Distribution Conference and Exposition, 2010 IEEE PES* (pp. 1–5). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5484257
- Hashemi, S., & Aghamohammadi, M. R. (2013). Wavelet based feature extraction of voltage profile for online voltage stability assessment using RBF neural network. *International Journal of Electrical Power & Energy Systems*, 49, 86–94. <https://doi.org/10.1016/j.ijepes.2012.12.019>
- Hatziargyriou, N. D., & Van Cutsem, T. (1994). *Indices predicting voltage collapse including dynamic phenomena*. CIGRE.
- Holen, A., & Warland, L. (2002). Estimation of distance to voltage collapse: testing an algorithm based on local measurements. In *Proc. 14th Power System Computation Conference, Seville* (pp. 38–3).
- Innah, H., & Hiyama, T. (2011). A real time PMU data and neural network approach to analyze voltage stability (pp. 1263–1267). IEEE. <https://doi.org/10.1109/APAP.2011.6180572>
- Jeyasurya, B. (2000). Artificial neural networks for on-line voltage stability assessment. In *IEEE Power*

- Engineering Society Summer Meeting, 2000* (Vol. 4, pp. 2014–2018 vol. 4). <https://doi.org/10.1109/PSS.2000.866956>
- Julian, D. E., Schulz, R. P., Vu, K. T., Quaintance, W. H., Bhatt, N. B., & Novosel, D. (2000). Quantifying proximity to voltage collapse using the Voltage Instability Predictor (VIP). In *IEEE Power Engineering Society Summer Meeting, 2000* (Vol. 2, pp. 931–936 vol. 2). <https://doi.org/10.1109/PSS.2000.867496>
- Karki, M. J. (2009). *Methods for On Line Voltage Stability Monitoring*. Iowa State, Iowa.
- Kundur, P. (1994). *Power System Stability and Control*. McGraw-Hill.
- Kundur, P., Cañizares, C., Paserba, J., Ajarapu, V., Anderson, G., Bose, A., ... Vittal, V. (2004). Definition and Classification of Power System Stability. *IEEE Transactions on Power Systems, 19*(2), 1387–1401. <https://doi.org/10.1109/TPWRS.2004.825981>
- Larsson, M., Rehtanz, C., & Bertsch, J. (2003). Monitoring and operation of transmission corridors. In *Power Tech Conference Proceedings, 2003 IEEE Bologna* (Vol. 3, p. 8–pp). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1304467
- Leonardi, B., & Ajarapu, V. (2008). Investigation of various generator reactive power reserve (GRPR) definitions for online voltage stability/security assessment. In *Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century, 2008 IEEE* (pp. 1–7). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4596235
- Leonardi, B., & Ajarapu, V. (2010). *Real-Time Security Assessment of Angle Stability and Voltage Stability Using Synchrophasors* (Final Project Report, Part II). PSERC.
- Leonardi, B., & Ajarapu, V. (2011). Development of Multilinear Regression Models for Online Voltage Stability Margin Estimation. *Power Systems, IEEE Transactions On, 26*(1), 374–383.
- Liu, M., Zhang, B., Yao, L., Han, M., Sun, H., & Wu, W. (2008). PMU based voltage stability analysis for transmission corridors. In *Electric Utility Deregulation and Restructuring and Power Technologies, 2008. DRPT 2008. Third International Conference on* (pp. 1815–1820). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4523701
- Milosevic, B., & Begovic, M. (2003). Voltage-stability protection and control using a wide-area network of phasor measurements. *Power Systems, IEEE Transactions On, 18*(1), 121–127.
- Momoh, J. A., Xia, Y., & Boswell, G. (2008). Voltage stability enhancement using Phasor Measurement Unit (PMU) technology. In *Power Symposium, 2008. NAPS'08. 40th North American* (pp. 1–6). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=5307295
- Morison, K. (2006). On-line dynamic security assessment using intelligent systems. In *IEEE Power Engineering Society General Meeting, 2006* (p. 5 pp.-). <https://doi.org/10.1109/PES.2006.1709501>
- Morison, K., Wang, L., & Kundur, P. (2004). Power system security assessment. *Power and Energy Magazine, IEEE, 2*(5), 30–39.
- Nakawiro, W., & Erlich, I. (2008). Online voltage stability monitoring using Artificial Neural Network. In *Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2008. DRPT 2008* (pp. 941–947). <https://doi.org/10.1109/DRPT.2008.4523542>
- Nguegan, Y. (2009). *Real Time Identification and Monitoring of the Voltage Stability Margin using Synchronized Phasor Measurements*. Kassel.
- Nguegan, Y., Claudi, A., & Strunge, C. (2009). Online Monitoring of the Electrical Power Transfer Stability and Voltage Profile Stability Margins in Electric Power Transmission Systems Using Phasor Measurement Units Data Sets. In *Power and Energy Engineering Conference, 2009. APPEEC 2009. Asia-Pacific* (pp. 1–9). <https://doi.org/10.1109/APPEEC.2009.4918561>
- Overbye, T., Sauer, P., DeMarco, C., Lesieutre, B., & Venkatasubramanian, M. (2010). *Using PMU Data to Increase Situational Awareness* (Final Project Report). PSERC.
- Phadke, A. (1993). Synchronized phasor measurements in power systems. *IEEE Computer Applications in Power, 6*(2), 10–15. <https://doi.org/10.1109/67.207465>
- Phadke, A., & Thorp, J. S. (2008). *Synchronized Phasor Measurements and Their Applications*. Springer

Science & Business Media.

- Rahi, O. P., Yadav, A. K., Malik, H., Azeem, A., & Kr, B. (2012). Power System Voltage Stability Assessment through Artificial Neural Network. *Procedia Engineering*, 30, 53–60. <https://doi.org/10.1016/j.proeng.2012.01.833>
- Ree, J. D. L., Centeno, V., Thorp, J. S., & Phadke, A. G. (2010). Synchronized Phasor Measurement Applications in Power Systems. *IEEE Transactions on Smart Grid*, 1(1), 20–27. <https://doi.org/10.1109/TSG.2010.2044815>
- Sajan, K. S., Kumar, V., & Tyagi, B. (2015). Genetic algorithm based support vector machine for on-line voltage stability monitoring. *International Journal of Electrical Power & Energy Systems*, 73, 200–208. <https://doi.org/10.1016/j.ijepes.2015.05.002>
- Savulescu, S. C. (2009). *Real Time Stability Assessment in Modern Power Systems Control centers*. (S. C. Savulescu, Ed.). Piscataway, NJ 08855: John Wiley & Sons.
- Schlueter, R. A. (1998). A voltage stability security assessment method. *IEEE Transactions on Power Systems*, 13, 15.
- Shaikh, F. A., & Asghar, J. (2011). Computational Intelligence and Voltage Stability Analysis for Mitigation of Blackout. *International Journal of Computer Applications*, 16(2).
- Smon, I., Verbic, G., & Gubina, F. (2006). Local voltage-stability index using tellegen's Theorem. *IEEE Transactions on Power Systems*, 21(3), 1267–1275. <https://doi.org/10.1109/TPWRS.2006.876702>
- Su, Y., & Wang, X. (2009). A method for voltage stability assessment based on wide area measurement system. In *Power and Energy Engineering Conference, 2009. APPEEC 2009. Asia-Pacific* (pp. 1–4). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4918055
- Subramani, C., Jimoh, A. A., Kiran, S. H., & Dash, S. S. (2016). Artificial neural network based voltage stability analysis in power system. In *2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT)* (pp. 1–4). <https://doi.org/10.1109/ICCPCT.2016.7530255>
- Suganyadevi, M. V., & Babulal, C. K. (2014). Support Vector Regression Model for the prediction of Loadability Margin of a Power System. *Applied Soft Computing*, 24, 304–315. <https://doi.org/10.1016/j.asoc.2014.07.015>
- Taylor, C. W. (1994). *Power System Voltage Stability*. California: McGraw-Hill.
- Torres, S. P., Peralta, W. H., & Castro, C. A. (2007). Power system loading margin estimation using a neuro-fuzzy approach. *Power Systems, IEEE Transactions On*, 22(4), 1955–1964.
- Velayati, M. H., Amjady, N., & Khajevandi, I. (2015). Prediction of dynamic voltage stability status based on Hopf and limit induced bifurcations using extreme learning machine. *International Journal of Electrical Power & Energy Systems*, 69, 150–159. <https://doi.org/10.1016/j.ijepes.2015.01.005>
- Vittal, V. (2008). *Decision Tree Based Online Voltage Security Assessment Using PMU measurements* (No. científico) (p. 52). PSERC Report 08-26.
- Vu, K., Begovic, M. M., Novosel, D., & Saha, M. M. (1999). Use of local measurements to estimate voltage-stability margin. *Power Systems, IEEE Transactions On*, 14(3), 1029–1035.
- Zhang, R., Xu, Y., Dong, Z. Y., Zhang, P., & Wong, K. P. (2013). Voltage stability margin prediction by ensemble based extreme learning machine. In *2013 IEEE Power Energy Society General Meeting* (pp. 1–5). <https://doi.org/10.1109/PESMG.2013.6672489>
- Zhou, D. Q., Annakkage, U. D., & Rajapakse, A. D. (2010). Online Monitoring of Voltage Stability Margin Using an Artificial Neural Network. *IEEE Transactions on Power Systems*, 25(3), 1566–1574. <https://doi.org/10.1109/TPWRS.2009.2038059>
- Zhukov, A., Tomin, N., Sidorov, D., Panasetsky, D., & Spirayev, V. (2015). A hybrid artificial neural network for voltage security evaluation in a power system. In *2015 5th International Youth Conference on Energy (IYCE)* (pp. 1–8). <https://doi.org/10.1109/IYCE.2015.7180828>
- Zima, M., Larsson, M., Korba, P., Rehtanz, C., & Andersson, G. (2005). Design aspects for wide-area monitoring and control systems. *Proceedings of the IEEE*, 93(5), 980–996.

3. METODOLOGÍA PROPUESTA

En este capítulo se presenta la metodología propuesta para el monitoreo de la estabilidad de tensión de largo alcance, donde se consideran los mecanismos de inestabilidad de tensión en sistemas de potencia, estos son: i) inestabilidad de tensión causada por la pérdida de control de tensión, e ii) inestabilidad de tensión causada por incapacidad de transmisión. La primera parte del esquema planteado en la metodología, comprende la estructura de aprendizaje en modo fuera de línea. Este consiste en la construcción de la base de datos de aprendizaje, la división del sistema de potencia en áreas de control de tensión (VCAs, de sus siglas en inglés), y el entrenamiento para la técnica de inteligencia artificial (IA). La segunda parte, corresponde a la ejecución en tiempo real del método para la evaluación de la estabilidad de tensión. A continuación, se presenta una descripción general de la metodología desarrollada.

3.1 Síntesis general de la metodología para la evaluación de la estabilidad

En el presente trabajo de investigación se propone una metodología para el monitoreo de la estabilidad de tensión de largo alcance, en tiempo real usando mediciones fasoriales como datos de entrada. En la actualidad, los métodos de monitoreo de la estabilidad de tensión solo se centran en un mecanismo de inestabilidad de tensión a la vez, presentando el riesgo de inestabilidad de tensión debido al mecanismo no vigilado. Ante un cambio en la demanda y la ocurrencia de una contingencia, las variables eléctricas del sistema de potencia, como fasores de voltaje y de corriente, cambian, y estas variables pueden ser medidas en tiempo real por las PMUs. Usando estas medidas como datos de entrada, y con la metodología propuesta para la evaluación de la estabilidad es posible entregar una valoración de la inestabilidad de tensión del sistema por medio de un índice de estabilidad de tensión. En la Figura 3.1 se presentan el esquema general de la metodología propuesta para la evaluación de la estabilidad de tensión de largo alcance.

El esquema en la Figura 3.1, presenta el paso a paso que se sigue para realizar la evaluación de la estabilidad en tiempo real. Inicialmente se identifican las VCAs en el sistema de potencia, esto se realiza en línea y se puede actualizar con la información de tiempo real. En primera instancia, se adquieren las medidas de las variables eléctricas desde las PMUs en cada período de actualización; los datos son recibidos y pre-procesados en el centro de control con fin de filtrar ruido (se asume que la etapa de pre procesamiento se ha realizado).

Luego, se ejecuta la evaluación de la estabilidad de tensión en cada VCA identificada, con el fin de identificar el área más débil, en la cual se desarrolla la inestabilidad de tensión. Igualmente, se realiza una supervisión de los vínculos de transmisión entre VCAs para garantizar la estabilidad de tensión. Para cada VCA se evalúa o predice el índice VSM, que cuantifica el margen de cargabilidad del sistema.

En la delimitación de las VCAs del sistema se propone usar la información desde el sistema SCADA y las PMUs que maneja el operador del sistema; luego, con herramientas

matemáticas apropiadas se identifican los nodos propensos a inestabilidad de tensión con los respectivos generadores que los controlan. El índice de estabilidad de tensión para cada VCA refleja la distancia a la frontera de inestabilidad o al colapso de tensión en los nodos de dicha área.

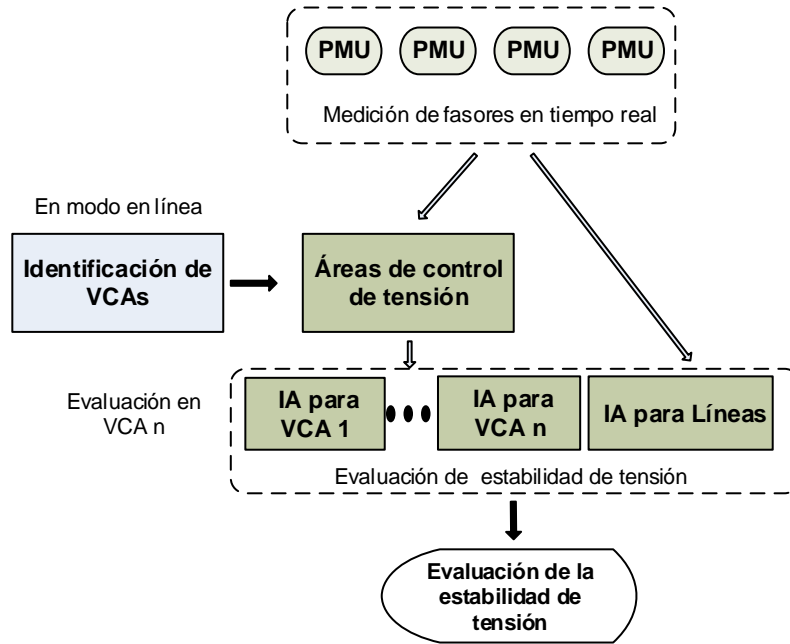


Figura 3.1. Metodología propuesta para la evaluación de estabilidad en tiempo real.

Para la evaluación o predicción de la estabilidad se propone el uso de técnicas de IA. Estas se consideran una alternativa promisoría para la evaluación en tiempo real de la estabilidad de tensión. Una de las ventajas primordiales que hacen a las técnicas IA atractivas es que reducen el tiempo requerido para la evaluación de la estabilidad, debido a que no se necesita el cálculo de ecuaciones diferenciales no lineales que rigen el comportamiento dinámico de los sistemas de potencia para realizar la evaluación de la estabilidad (Z Dong et al., 2013).

Para ejecutar cada una de las tareas propuestas en la evaluación de la estabilidad de tensión, en la metodología se considera la fase del aprendizaje en modo fuera de línea que está compuesto por varias etapas, como: i) Construcción de la base de datos usando el método Monte Carlo para generar múltiples condiciones para el sistema. ii) Identificación de las VCAs considerando diferentes escenarios de generación-demanda y contingencias *N-1* en el sistema; iii) Entrenamiento de la herramienta de IA.

Para la metodología se requiere de datos confiables que representen las diferentes condiciones del sistema, la simulación Monte Carlo se ejecuta iterativamente para evaluar diferentes escenarios de generación-demanda, se considera la selección de manera probabilística de contingencias *N-1* y se determina el margen de estabilidad de tensión. Esta información es usada para el entrenamiento de sistemas inteligentes los cuales son usados en la evaluación en tiempo real.

3.2 Construcción de la base datos usando el método Monte Carlo

Uno de los principales desafíos en la implementación de técnicas de IA es la necesidad de una gran cantidad de información confiable que permita caracterizar el comportamiento del sistema. Esto se realiza construyendo una base de datos; luego de obtenida la información se entrena en modo fuera de línea la herramienta de IA, con la herramienta entrenada se ingresa nueva información para evaluar el sistema.

La base de datos está conformada por datos de entrada y datos de salida. La base se divide en tres tipos de conjuntos de datos, que son: los datos de entrenamiento (fase de entrenamiento del sistema de IA); los datos de validación para evaluar la capacidad de generalización o aprendizaje en el entrenamiento (fase de validación); y los datos de prueba para examinar desempeño de la técnica de IA. Para el trabajo de investigación los datos de entrada de la base de datos estarán conformados por las medidas fasoriales sincronizadas de tensión de algunas barras del sistema, y los datos de salida están conformados por el margen de estabilidad de tensión del sistema (VSM por sus siglas en inglés), que corresponde a la distancia en potencia desde el punto de operación hasta la frontera de estabilidad.

Para usar el método de simulación Monte Carlo en la construcción de la base de datos se requieren varios datos de entrada, esto depende generalmente del objetivo de la simulación. Estos datos de entrada son usualmente representados por medio de funciones de distribución de probabilidad (PDF, de sus siglas en inglés) (Billinton & Li, 2013; Z. Dong et al., 2010; Li, 2011).

Se busca diseñar una metodología que se pueda actualizar diariamente por el operador del sistema. Para el análisis de la incertidumbre propuesta se considera únicamente el horizonte del planeamiento de corto plazo; por lo cual, se deben construir modelos probabilísticos de las variables aleatorias del sistema de potencia, como también los cambios de topología en la red que deben reflejar el comportamiento del sistema lo más cercano posible a la realidad (Li, 2011). La información inicial para construir la base de datos usando el método de simulación Monte Carlo es:

- i) Modelo probabilístico de la demanda nodal.
- ii) Despacho económico en el corto plazo.
- iii) Modelo probabilístico de contingencias $N-1$.

3.2.1 Modelo probabilístico de la demanda nodal

La demanda de potencia eléctrica y el consumo de energía en un sistema tienen un comportamiento altamente variable, y no lineal en función del tiempo, que presenta diferentes valores para cada nodo de carga en el sistema. La variabilidad en el comportamiento de la demanda se debe a la naturaleza y diversidad de los usuarios del sistema, esto es, usuarios residenciales, industriales y comerciales. El comportamiento cronológico horario de cada demanda se caracteriza por medio de curvas de carga horarias

las cuales representan el comportamiento tipo de cada usuario del sistema (Cepeda, 2013a; Hinojosa, 2007).

El horizonte de planeación para el pronóstico de la demanda es del corto plazo, que corresponde a un rango de tiempo de un día a varias semanas. El pronóstico de la demanda es una tarea común que realiza el operador de la red como un insumo para el despacho económico del sistema (Hinojosa, 2007). La demanda pronosticada generalmente difiere del comportamiento de la demanda real, por lo cual el pronóstico debe reflejar el comportamiento incierto de la demanda con el fin de adquirir la información lo más realista posible que permita la toma de decisiones operativas.

Con respecto al modelo probabilístico de la demanda nodal variable, este debe reflejar el comportamiento de la demanda en el corto plazo, modelando la incertidumbre asociada por medio de una adecuada PDF, la cual es usada como entrada en método de simulación Monte Carlo. En el trabajo de investigación para los nodos de carga (PQ) se han considerado tres curvas típicas de demanda diaria que corresponden a clientes residenciales, industriales y comerciales (ver Figura 3.2), y la incertidumbre en el pronóstico es incluida usando una función de distribución normal para la hora h (Cepeda, 2013a).




Figura 3.2. Curvas de demanda horaria diaria según el tipo de usuario (Cepeda, 2013a).

3.2.2 Despacho económico en el corto plazo

El despacho económico clásico (DE) consiste en la optimización de la producción de generación, la cual implica determinar la cantidad de energía que debe suministrar cada uno de los generadores de un sistema para atender la demanda a mínimo costo, despreciando el efecto de la red de transmisión (Wood & Wollenberg, 2012). Posteriormente, se propuso el flujo de potencia óptimo (OPF, de sus sigla en inglés) que consiste en encontrar el despacho de generación que cumpla con las restricciones de red, teniendo en cuenta una función objetivo (minimización de costos, maximización del beneficio social) y considerando un solo intervalo de tiempo (Dommel & Tinney, 1968). El despacho económico multiperíodo DEM (conocido en inglés como *unit commitment*) se puede ver como una extensión del OPF; en la función objetivo además del costo de generación, se considera la minimización del costo de arranque y parada de las unidades

térmicas. El DEM consiste en determinar para cada intervalo de tiempo, (típicamente 1 hora) de un horizonte dado (típicamente 24 horas) el despacho de cada unidad de generación teniendo en cuenta múltiples restricciones (C. L. Chen & Che, 1991). Estas restricciones normalmente incluyen el balance de potencia nodal, los límites operativos de red, restricciones inter-temporales como rampas de subida y bajada de unidades.

Hoy en día, cada operador de la red asume la solución del problema de optimización del DEM; en el trabajo de investigación se determina la potencia despachada entregada por cada unidad de generación para cada hora a la vez por medio del OPF usando el paquete computacional MATPOWER (Zimmerman, Murillo-Sanchez, & Thomas, 2011).

3.2.3 Modelo probabilístico de contingencias $N-1$

En este trabajo, el evento de salida de un elemento de conexión o de generación del sistema (contingencia $N-1$) se considera como un evento independiente y generado de forma aleatoria. La selección de las contingencias depende de la probabilidad de salida forzada de los componentes del sistema. La probabilidad de ocurrencia de un evento de contingencia puede ser estimado usando la distribución de Poisson con una tasa de ocurrencia constante (Billinton, 2013; Li, 2011). Usando la fórmula de la distribución de Poisson se tiene que la probabilidad de ocurrencia de una contingencia ($N-1$) en un periodo de tiempo t esta dada por la siguiente ecuación:

$$P_0 = 1 - e^{-\lambda_0 t} \quad (3.1)$$

Donde: λ_0 es tasa de ocurrencia promedio de una contingencia relacionada con un elemento del sistema, y t es el tiempo de duración considerado, en este caso es de una hora.

La ecuación (3.1) es aplicada a todos los componentes que se consideran en el conjunto elegible de contingencias $N-1$. En este trabajo, se consideran contingencias ocasionadas por la salida de líneas de transmisión, transformadores y unidades de generación.

Para la selección probabilística de contingencias usando el Método Monte Carlo, se asume que cada componente del sistema tiene dos estados de operación: estado de operación normal y estado de falla. En la simulación Monte Carlo, se genera un numero aleatorio uniformemente distribuido, R , para cada componente o grupo de componentes, el modelo Markoviano se maneja de la siguiente manera (Wang, Song, & Irving, 2008), así:

$$I_i = \begin{cases} 1 & R_i > P_0 \quad Normal \\ 0 & R_i \leq P_0 \quad Falla \end{cases} \quad (3.2)$$

Donde I_i es el estado de operación del i -ésimo componente del sistema, R_i es número aleatorio uniformemente distribuido para el i -ésimo componente.

Para los elementos en estado de falla se realiza el análisis de contingencias, que corresponde a ejecutar un flujo de potencia para determinar las condiciones post contingencia del sistema.

3.2.4 Estructura general del método de simulación Monte Carlo

En este trabajo de investigación, la simulación Monte Carlo se usa para obtener datos de pre y post contingencia de algunas variables eléctricas del sistema. Estos datos estarían

disponibles desde las PMUs en un sistema real (fasores de voltajes y corrientes), considerando diferentes condiciones operativas posibles y contingencias, incluyendo los eventos más severos que llevan al sistema a condiciones potencialmente inseguras. Se realiza la definición de los modelos probabilísticos de los parámetros de entrada (PDFs de las demandas nodales y de la ocurrencia de contingencias), la simulación de Monte Carlo se ejecuta iterativamente para evaluar la respuesta del sistema, la información generada se parecerá a las señales registradas por las PMUs en tiempo real, con el objetivo final de construir una base de datos de entrenamiento para la fase de entrenamiento de la metodología.

El método de Monte Carlo inicia con la generación de una muestra aleatoria desde las PDFs de las variables de entradas consideradas en el proceso, por ejemplo, la demanda en cada nodo, y la selección aleatoria de la contingencia en un elemento. Luego, se ejecuta el OPF para cada muestra de las variables de entrada con el fin de definir un escenario de estado estable pre-contingencia factible. Se continúa con el análisis estático de contingencia $N-1$ y el flujo de potencia continuado (CPF, por sus siglas en inglés) para determinar el VSM, usando el programa UWPFLOW (Cañizares & Alvarado, 1993). Al final, se obtienen resultados de flujo de potencia de pre y post contingencia y el VSM correspondiente a cada evaluación realizada en proceso Monte Carlo. En la Figura 3.3 se presenta el flujograma del proceso de Monte Carlo propuesto para construir la base de datos para la etapa de aprendizaje de la metodología propuesta.

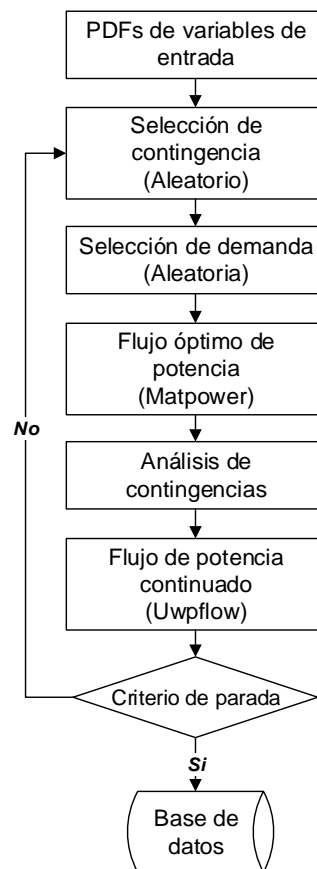


Figura 3.3. Flujograma del método Monte Carlo propuesto para la base de datos.

Con la herramienta de CPF se incrementa la demanda en el sistema de potencia con el objetivo de establecer la frontera de inestabilidad de tensión del sistema que corresponde al punto de máxima transferencia en la curva PV (Ajarapu, 2006b; Ajarapu & Christy, 1992; Dobson et al., 2002), la distancia desde el punto de operación hacia la frontera de inestabilidad de tensión depende de la trayectoria del incremento de la potencia en el sistema y del punto de operación inicial. Por otra parte, las contingencias, como la salida de líneas transmisión, tienen como consecuencia que la distancia a la frontera de inestabilidad se reduzca. Esto se ha comprobado por medio de análisis de estabilidad estática por lo cual es importante considerar el efecto de las contingencias sobre el VSM en condiciones de post contingencia (Cutsem & Vournas, 1998). En la Figura 3.4 se muestra de forma general como los diferentes puntos de operación en función de la potencia activa y reactiva demandada, direcciones de incremento y contingencias afectan la distancia a la frontera de inestabilidad de tensión.

En este trabajo de investigación se consideran diferentes direcciones de incremento de la demanda. Esto se logra variando los puntos de operación y manteniendo el factor de potencia constante para ese punto cuando se incrementa la demanda del sistema para determinar la frontera.

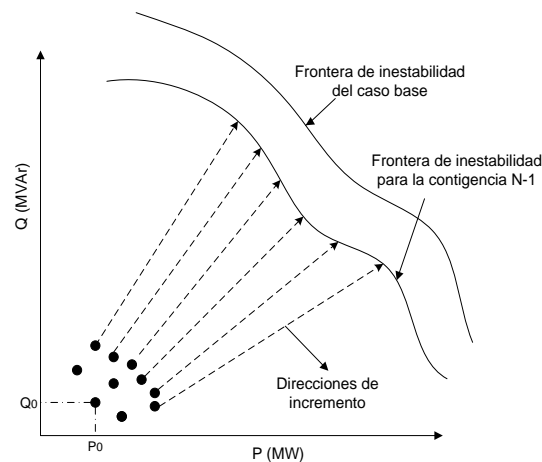


Figura 3.4. Variación del VSM debido a diferentes direcciones de incremento de carga y contingencia.

3.3 Áreas de control de tensión

En la delimitación de áreas de control de tensión, VCAs, se identifican a priori los nodos del sistema propensos a la inestabilidad de tensión para vigilarlos y controlarlos tan pronto como sea posible.

3.3.1 Definición de VCA

En la evaluación de la estabilidad de tensión en sistemas de potencia, es de particular interés determinar aquellas áreas críticas dentro del sistema que pueden ser propensas a sufrir deficiencias de potencia reactiva bajo alguna condición de operación estresada, así como también bajo la salida de elementos del sistema. Las deficiencias resultantes producen un desequilibrio de potencia reactiva que causa inestabilidad de tensión en

algunas áreas del sistema. Las áreas más propensas a los problemas de inestabilidad se denominan como VCAs. Cada VCA está constituida por un grupo de barras del sistema que presentan patrones de comportamiento de voltaje similares cuando el sistema está sometido a perturbaciones que podrían originar problemas de inestabilidad de tensión. Este conjunto que está formado por las barras de generación y carga con alta participación en los fenómenos de inestabilidad de tensión subyacente se ha denominado como grupo de barras coherentes. Las barras que alcanzan la capacidad límite para inyectar potencia reactiva en la red cuando se aumenta la demanda se considera como fuentes de generación, tales como: generadores síncronos, condensadores síncronos, dispositivos de compensación de potencia reactiva, entre otros (Lie, Schlueter, Rusche, & Rhoades, 1993; Schlueter, 1998; Schlueter, Hu, Chang, Lo, & Costi, 1991).

Las barras de generación incluidas en cada VCA forman la reserva base de potencia reactiva (RRB, por sus siglas en inglés) para esta área. La mayor parte de los incrementos de carga de potencia reactiva dentro de un VCA son suministrados por la RRB. Por lo que la RRB juega un papel muy importante al determinar el límite de demanda reactiva de cada barra de carga y reserva de potencia reactiva en cada VCA.

Con la determinación de las VCAs en el sistema, es posible identificar las barras de carga más propensas a la inestabilidad de tensión, como también las fuentes de potencia reactiva relacionadas con estas barras. Esto le permite al operador de red realizar el control coordinado apropiado y estrategias de supervisión para mejorar el comportamiento del voltaje en estas barras (Schlueter, 1998).

3.3.2 Método de identificación de VCAs

Uno de los principales desafíos que se deben afrontar en la identificación de las VCAs, es que la determinación de estas áreas se ve influenciada por el escenario de generación y los cambios topológicos en el sistema de potencia. En este trabajo, las VCAs se identifican siguiendo el método propuesto en (Echeverría, Flores, Villa, & Cepeda, 2017; Villa, Rueda, Torres, & Peralta, 2012). De igual modo se propone el uso del método Monte Carlo para generar diferentes condiciones operativas y cambios topológicos, contingencias $N-1$.

En primer lugar, se definen las PDFs de las variables de entrada al proceso, que son las demandas nodales y la generación aleatoria de contingencias $N-1$. Se generan de forma aleatoria la demanda nodal y la selección de contingencia, para el caso base se ejecuta el OPF, si hay un elemento en falla, se ejecuta el análisis de contingencia. Para esta condición operativa se calcula la distancia eléctrica entre todos los nodos del sistema (Lagonotte, Sabonnadiere, Leost, & Paul, 1989), se continúa con el cálculo de las coordenadas principales (Peña, 2002), y se ejecuta el análisis de clúster difuso, *Fuzzy C-means*, que identifica áreas y define los límites de cada VCA. Finalmente, se verifica la conectividad de las barras que conforman la VCA (Echeverría et al., 2017). En la Figura 3.5 se presenta el flujograma que describe el proceso desarrollado para la identificación de las VCAs que ha sido implementado en el trabajo.

Distancia eléctrica

El concepto de distancia eléctrica involucra la submatriz $[\partial Q/\partial V]$, que es parte de la matriz Jacobiana J , y su inversa $[\partial V/\partial Q]$, llamada como matriz de sensibilidad, ambas matrices

son reales y no simétricas (Lagonotte et al., 1989). Los elementos de $[\partial V/\partial Q]$ reflejan la propagación de la variación del voltaje después de la inyección de potencia reactiva en una barra, la magnitud del acoplamiento de voltaje entre dos barras puede ser cuantificada por la atenuación máxima de variación de voltaje entre estas dos barras. Estas atenuaciones se obtienen a partir de la matriz $[\partial V/\partial Q]$, mediante la división de los elementos de cada columna por el término diagonal de la matriz.

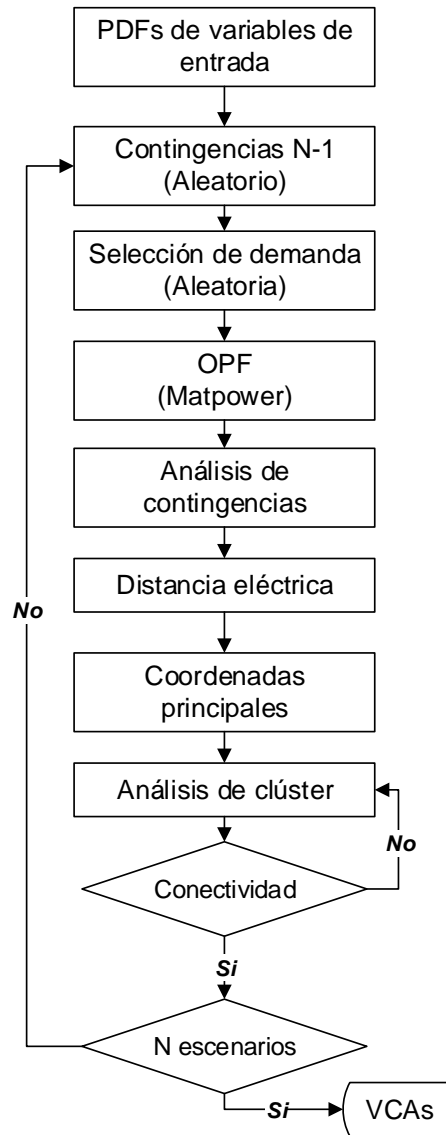


Figura 3.5. Estructura del método de identificación de VCAs implementado.

Con esta información se dispone de una matriz de atenuaciones entre todas las barras del sistema de potencia, cuyos términos son escritos como α_{ij} . Por lo tanto se tiene:

$$\Delta V_i = \alpha_{ij} \Delta V_j \quad (3.3)$$

Donde:

$$\alpha_{ij} = \left(\frac{\partial V_i}{\partial Q_j} \right) / \left(\frac{\partial V_j}{\partial Q_i} \right) \quad (3.4)$$

Generalmente, se da que $\alpha_{ij} \neq \alpha_{ji}$, con el fin de tener la propiedad de simetría en la distancia eléctrica, se utiliza la siguiente formulación para definir la distancia eléctrica entre dos nodos i y j (Lagonotte et al., 1989), así:

$$D_{ij} = D_{ji} = -\log(\alpha_{ij} \cdot \alpha_{ji}) \quad (3.5)$$

D_{ij} es la distancia eléctrica entre los nodos i y j , cuyas propiedades son: una matriz positiva y simétrica. Esta distancia eléctrica representa el grado de influencia derivado de los cambios de voltaje en otras barras.

Una vez definida la matriz de D_{ij} , se procede a determinar las VCAs a partir del uso de minería de datos, como sigue.

Coordenadas principales

Las coordenadas principales son una técnica de minería de datos que permite representar una matriz D cuadrada $n \times n$ de distancias entre n elementos de un conjunto, a un conjunto de variables ortogonales y_1, \dots, y_p , donde $p < n$, de manera que las distancias euclidianas entre las coordenadas de los elementos respecto a estas variables sean iguales a las distancias de la matriz original D , con estas coordenadas se construye una matriz X de $n \times p$, donde n es número de individuos y p es número de variables (Peña, 2002).

A partir de la matriz de distancia D_{ij} se construye la matriz de similitud \mathbf{Q} , esta matriz representa la variabilidad entre los elementos (matriz de covarianza), se obtiene así (Echeverría et al., 2017; Peña, 2002):

$$\mathbf{Q} = -\frac{1}{2} \left[\mathbf{I} - \frac{1}{n} \mathbf{1}\mathbf{1}' \right] D \left[\mathbf{I} - \frac{1}{n} \mathbf{1}\mathbf{1}' \right] \quad (3.6)$$

Donde \mathbf{I} es la matriz de identidad de dimensión $n \times n$ y $\mathbf{1}$ es un vector unitario de dimensión $n \times 1$.

Usando los valores propios (Λ_r) y la matriz de vectores propios (\mathbf{V}_r) de la matriz \mathbf{Q} , se obtiene la matriz de coordenadas principales \mathbf{Y}_r , de la siguiente manera (Cepeda, Rueda, Erlich, & Colomé, 2012; Peña, 2002):

$$\mathbf{Y}_r = \mathbf{V}_r \Lambda_r^{1/2} \quad (3.7)$$

Una vez obtenida las coordenadas principales, ecuación (3.7), de los datos multidimensionales se agrupan las barras del sistema en VCAs usando la herramienta de agrupamiento *Fuzzy C-means* (FCM).

Método de clúster de datos *Fuzzy C Means* (FCM)

El algoritmo de agrupamiento FCM, es un método que usa partición difusa, con el objetivo de encontrar grupos de datos (clúster), donde cada dato n dimensional u observación pertenece a un clúster con un cierto grado de pertenencia, por lo tanto, una observación dada puede pertenecer a varios grupos con cierto grado de pertenencia entre 0 y 1. La formulación detallada del FCM se puede encontrar en Hammouda & Karray, 2013. Dado

que el algoritmo de FCM es una herramienta de análisis de datos, está no considera la configuración real de la red eléctrica; de hecho, los grupos de barras que resultan de la aplicación de la FCM no corresponden necesariamente a las áreas eléctricas reales, es decir, a barras eléctricamente conectadas entre sí. Por lo que es necesario añadir un análisis adicional al algoritmo de agrupamiento que compruebe la conectividad eléctrica de las barras. Para esto se utiliza un algoritmo que emplea la teoría de Goderya (Goderya, Metwally, & Mansour, 1980). A continuación, se presenta un resumen del algoritmo.

Verificación de la conectividad de las barras en las VCAs

Sea A_r ($m \times n$) la matriz de incidencia (rama-nodo) de un área r del sistema, entonces la matriz de conectividad C_r ($n \times n$) puede ser definida como sigue (Cepeda, 2013a).

$$C_r = A_r^T \cdot A_r \quad (3.8)$$

Donde m es el número de ramas (líneas o transformadores), y n es el número de barras pertenecientes al área r .

Q_r ($n \times n$) y R_r ($n \times n$) representan la descomposición ortogonal-triangular de la matriz C_r , por lo tanto:

$$C_r = Q_r \cdot R_r \quad (3.9)$$

Basado en la matriz R_r , es posible definir el vector columna de verificación de conectividad C_v ($n \times 1$) como sigue:

$$C_{v_{i=1..n}}^i = \sum_{j=i+1}^n R_r^{(i,j)} \quad (3.10)$$

Donde i representa la fila y j representa la columna de la matriz R_r , y $R_r^{(i,j)}$ es el elemento (i, j) de R_r . El número de elementos nulos de C_v representa el número de sub-áreas formadas dentro del área r debido a la falta de conectividad (Cepeda, 2013a).

3.4 Entrenamiento de sistemas inteligentes

Entre las ventajas que hacen de la IA una alternativa promisoría para la evaluación en tiempo real de la estabilidad tenemos las descritas a continuación (Z Dong et al., 2013):

- a) Rapidez: Se debe obtener un estatus de la estabilidad del sistema en el punto actual de operación cercano al tiempo real. La IA determina la estabilidad en una fracción de segundo después de recibir los datos de entrada, lo cual permite una respuesta oportuna para prevenir la inestabilidad.
- b) Extracción de conocimiento: La IA puede extraer información de estabilidad del sistema, esto provee un entendimiento de la operación del sistema.
- c) Menor cantidad de datos: Para los métodos convencionales de evaluación de la estabilidad se requiere información precisa y una descripción completa del sistema. En tiempo real esta información es incierta o aún no disponible. En contraste, la IA evalúa la estabilidad con solo los parámetros significativos y disponibles.
- d) Capacidad de generalización: La IA maneja simultáneamente un amplio panorama de escenarios o condiciones del sistema en la evaluación de la estabilidad, estas condiciones pueden ser previamente asumidas y no previstas.

- e) Versatilidad: La IA se puede adaptar a las tres categorías de estabilidad y los operadores del sistema pueden diseñar herramientas para predecir el estado de estabilidad (clasificación), o para medir el margen de estabilidad (regresión).

Luego de construir la base de datos se continúa con el entrenamiento y validación de la técnica de IA. El entrenamiento permite que la IA adquiera conocimiento del problema de estabilidad. En este proceso se ingresan las mediciones fasoriales sincronizadas a la IA y la salida es el VSM correspondiente a los fasores de tensión ingresados. En la fase de ejecución de la IA ya entrenada y validada para un sistema de potencia determinado, tan pronto se reciba la información de entrada para la IA desde el sistema de potencia (mediciones fasoriales sincronizadas), la IA entregará los resultados de la evaluación de la estabilidad de tensión para la información de entrada respectiva.

Algunas de las técnicas de IA que pueden usarse en este trabajo están relacionadas con el reconocimiento de patrones y problemas de regresión (Ljung, 2010), tales como: las redes neuronales artificiales (RNAs), máquinas de soporte vectorial (MSV) y máquinas de aprendizaje extremo (MAE).

Redes Neuronales Artificiales

Las RNAs son una IA que están compuestas de un gran número de elementos de procesamiento altamente interconectados (neuronas artificiales) trabajando al mismo tiempo para la solución de un problema específico. La neurona artificial es una unidad de procesamiento de información que encuentra relaciones no lineales entre conjuntos de datos. Se denominan RNAs porque están basadas en el funcionamiento de la neurona biológica cuando procesa información. Las RNAs “aprenden de la experiencia”, está se suministra con el entrenamiento del sistema con datos experimentales para que la red adquiera el conocimiento relacionado con el problema bajo estudio.

Las RNAs están compuestas de muchos elementos sencillos que operan en paralelo, el diseño de la red está determinado en su mayoría por las conexiones entre sus elementos. (Lee, 1999). Un sistema neuronal imita al cerebro en dos aspectos: a) el conocimiento es adquirido por el sistema a través del proceso de aprendizaje; b) conexiones entre las neuronas, conocidas como pesos sinápticos son usadas para almacenar el conocimiento.

En el trabajo de investigación se usan las RNAs multicapa de conexión hacia adelante o “*feedforward*”, con el algoritmo de aprendizaje supervisado denominado propagación hacia atrás o “*backpropagation*” (Bishop, 1996; Haykin, 1994).

Máquinas de soporte vectorial

Las MSVs son una tipo de técnica de aprendizaje de máquina que han sido usadas en la solución de problemas de clasificación, regresión y reconocimiento de patrones (Bishop, 2006). Las MSVs son un nuevo método promisorio para problemas de clasificación de datos lineales y no lineales. Una MSV es un algoritmo que utiliza un mapeo no lineal para transformar los datos de entrenamiento originales a una dimensión superior, dentro de esta nueva dimensión, busca el hiperplano de separación óptima lineal (límite de decisión) separando una clase de otra). Con un mapeo no lineal apropiado a una dimensión suficientemente alta, los datos de dos clases siempre se pueden separar por un hiperplano. La MSV encuentra este hiperplano usando vectores de soporte y márgenes (definidos por

los vectores de soporte), esto se logra por medio de la solución de un problema de optimización (J. Han, Kamber, & Pei, 2011). Esta IA pertenece al conjunto de algoritmos denominados métodos basados en Kernel y se emplea la minimización de riesgo estructural como el principio de optimización (Cepeda, 2013a), la MSV tiene una robustez estadística y la habilidad de superar problemas de sobreajuste, lo que hacen esta herramienta promisoría para solución de problemas en ingeniería (Z. Dong et al., 2010).

El regresor de soporte vectorial (RSV) es una extensión de la MSV con una buena capacidad de generalización creada para solucionar problemas de predicción de series de tiempo y aproximación de funciones (regresión). La aproximación de funciones consiste en la determinación de la relación entre las entradas y salidas usando pares de datos correspondientes a entradas y salidas (x_i, z_i) donde $i = 1, \dots, l$; x_i es el i ésimo vector de entrada de dimensión n , z_i es el i ésimo escalar de salida, y l es el número de datos de entrenamiento (Abe, 2006; Hsu, Chang, & Lin, 2010). Una RSV asigna el espacio de entrada a un espacio de características multidimensional para determinar un hiperplano óptimo definido como:

$$f(x) = w^T \phi(x) + b \quad (3.11)$$

Donde w es un vector ponderado n -dimensional, $\phi(x)$ es la función de mapeo desde el espacio de x al espacio característico, b es el termino de umbral (Hsu et al., 2010).

En este trabajo se usa la máquina de soporte vectorial para problemas de regresión llamada ε -RSV con una función de base radial (RBF, por sus siglas en inglés) como kernel. Dado un conjunto de puntos de entrenamiento (x_i, z_i) donde $x_i \in R^n$ es un vector de características y $z_i \in R^1$ es un vector de salidas objetivos, con parámetros dados $C > 0$ y $\varepsilon > 0$ la forma estándar de la ε -RSV es (Chang & Lin, 2011):

$$\begin{aligned} \min: & \quad \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^* \\ \text{sujeto a:} & \quad w^T \phi(x_i) + b - z_i \leq \varepsilon + \xi_i, \\ & \quad z_i - \phi(x_i) - b \leq \varepsilon + \xi_i^*, \\ & \quad \xi_i, \xi_i^* \geq 0, i = 1, \dots, l. \end{aligned} \quad (3.12)$$

Donde C es el parámetro de margen que determina la compensación entre la magnitud del margen y el error de estimación de los datos de entrenamiento, ξ_i y ξ_i^* son variables de holgura asociadas con x_i (Abe, 2006). La función de mapeo $\phi(x)$ se le llama función kernel, para la RSV se emplea el RBF como kernel que se define como:

$$K(x_i, x_j) = \phi(x_i)^T \phi(x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (3.13)$$

Por otra parte, el parámetro positivo pequeño ε se utiliza para reducir los errores residuales en la regresión, por lo cual se propone una función lineal a intervalos en vez de una función de error cuadrática (Abe, 2006). El parámetro $\varepsilon > 0$ corresponde al radio de una zona que se denomina zona de insensibilidad- ε o tubo, la estimación ideal se logra cuando los datos de entrenamiento están en esta zona. Para permitir la existencia de datos por fuera del tubo se utilizan las variables de holgura no negativas ξ_i y ξ_i^* . Para más detalles sobre el ε -RSV

revisar la referencia (Abe, 2006).

Los parámetros C y ε de (3.12) y γ de (3.13) deben ser definidos antes del entrenamiento del RSV, los demás parámetros se determinan en el proceso de optimización definido en la ecuación (3.12).

Máquinas de aprendizaje extremo

Uno de los inconvenientes de la RNA es que la velocidad de entrenamiento de la RNA es mucho más lenta de lo requerido, y ha sido un gran obstáculo en sus aplicaciones durante la última década. Esto se debe a que los algoritmos de entrenamiento son basados en métodos de gradiente descendiente y además todos los parámetros de la red son sintonizados iterativamente en el entrenamiento.

Se propuso un nuevo algoritmo de aprendizaje denominado “máquina de aprendizaje extremo” (MAE) se usan tanto en problemas de clasificación como de regresión. La principal ventaja de las MAEs es la ausencia del ajuste iterativo en la capa oculta de la red por lo que su tiempo de entrenamiento es mucho menor que un RNA tradicional (Huang, Zhu, & Siew, 2006).

Para las MAEs se demuestra que los pesos entrada y los umbrales de la capa oculta de una red *feedforward* de una sola capa (SLFNs, por sus siglas del inglés) pueden ser aleatoriamente asignados, si las funciones de activación en la capa oculta son infinitamente diferenciables. Después de que los pesos de entrada y los umbrales de la capa oculta se eligen aleatoriamente, el SLFNs puede ser simplemente considerado como un sistema lineal y los pesos de salida (conexiones de la capa oculta a la capa de salida) del SLFNs puede ser determinados analíticamente a través de una simple operación inversa generalizada de las matrices de salida de la capa oculta (Huang, Zhou, Ding, & Zhang, 2012).

Una variante de las MAEs, es una versión desarrolla con kernel del tipo RBF, ecuación (3.13), que mejora la habilidad de generalización de la IA (Ding, Guo, & Hou, 2017). En este trabajo se usa el KMAE que corresponde a la MAE con kernel del tipo RBF (Huang, 2014).

3.4.1 Identificación de parámetros del sistema inteligente

La etapa de aprendizaje de la IA es realizado en modo fuera de línea, en cual la estrategia común para el entrenamiento es separar con un conjunto de datos de entrenamiento y datos de prueba (datos desconocidos). Estos datos desconocidos se utilizan para evaluar la exactitud de la predicción. El objetivo de la etapa de aprendizaje es construir un modelo de la IA (por ejemplo del MSV y MAE) basado en la información inmersa en el conjunto de entrenamiento (J. Han et al., 2011). Antes de ejecutar el entrenamiento de las técnicas de máquinas de aprendizaje del tipo kernel, se debe realizar una determinación de los parámetros óptimos de la IA para mejorar la adaptación a los datos de entrenamiento y la exactitud en la respuesta de la IA ante datos desconocidos (Hsu et al., 2010).

Generalmente, el kernel tipo RBF para la MSV tiene dos parámetros a optimizar C y γ . Para la selección de estos parámetros de la MSV se ha propuesto usar la validación cruzada basada en k repeticiones (J. Han et al., 2011; Hsu et al., 2010), que permite prevenir el problema de sobreajuste, y el método “*grid search*” para obtener los valores óptimos de C

y γ . En la validación cruzada se dividen de forma aleatoria los datos en k subconjuntos mutuamente excluyentes y de igual tamaño. El entrenamiento y la prueba se realizan k veces, donde se mantiene un subconjunto de prueba y los demás $k - 1$ subconjuntos restantes son los datos de entrenamiento. La recomendación es utilizar el algoritmo “grid search” en C y γ usando validación cruzada, donde se prueban varias parejas (C, γ) y se seleccionan aquellos en los que se genera el menor error de predicción en la validación cruzada. Se ha determinado que para identificar buenos parámetros se utiliza una escala exponencial de la siguiente manera: $C = 2^{-5} \cdot 2^{-3} \dots 2^{15}$ y $\gamma = 2^{-15} \cdot 2^{-13} \dots 2^3$ (J. Han et al., 2011; Hsu et al., 2010).

El algoritmo de “grid search” es un procedimiento de alto consumo computacional que según el número de parejas consideradas depende el tiempo de cálculo, este procedimiento no garantiza la obtención de los parámetros óptimos de la IA. Como una solución al problema anterior se ha propuesto la utilización de técnicas de optimización metaheurísticas como optimización por enjambre de partículas (Sundaram & Swarup, 2011), algoritmos genéticos (Sajan et al., 2015) y optimización de mapeo de media-varianza (MVMO, por sus siglas en inglés), donde se minimiza una función objetivo (FO) que corresponde al error cuadrático medio (Cepeda, 2013a). En este trabajo se usa la herramienta MVMO (Erlich, 2018; Rueda, Cepeda, & Erlich, 2012; Rueda & Erlich, 2013) y la función objetivo definida así:

Minimizar:

$$FO = \sum_{i=1}^k \left(\frac{|t - y|^2}{n} \right)_i \quad (3.14)$$

Sujeto a:

$$x_{min} \leq x \leq x_{max} \quad (3.15)$$

Donde: t es el vector de salidas deseadas, y es el vector de predicción por la IA, $|\cdot|$ corresponde a la distancia euclidiana, n corresponde a la dimensión del vector y . El subíndice i se refiere a la i ésima iteración del proceso de validación cruzada de k repeticiones, y el vector x comprende los parámetros de IA que dan solución al problema.

El flujograma de la metodología propuesta para la identificación de los parámetros de la IA usando MVMO se presenta en la Figura 3.6.

3.5 Monitoreo de líneas de interconexión entre VCAs

Se implementará un segundo conjunto de técnicas de IA para vigilar la potencia que fluye por los vínculos de transmisión con objetivo de garantizar que no se exceda los límites de las líneas. Se propone emplear como información de entrada a las IA las diferencias angulares entre los nodos límites de las VCAs, y se determina la potencia en la interconexión por medio de un nuevo concepto denominado “ángulos del conjunto de corte” o *cutset angles*. Este método permite monitorear el estrés de un conjunto de líneas (conjunto de corte) que unen diferentes áreas de control de tensión. Esta estimación del estrés se realiza por medio del cálculo de la diferencia angular de una línea equivalente construida a partir del conjunto de corte entre las áreas que separa (Dobson, 2010; Dobson,

Parashar, & Carter, 2010).

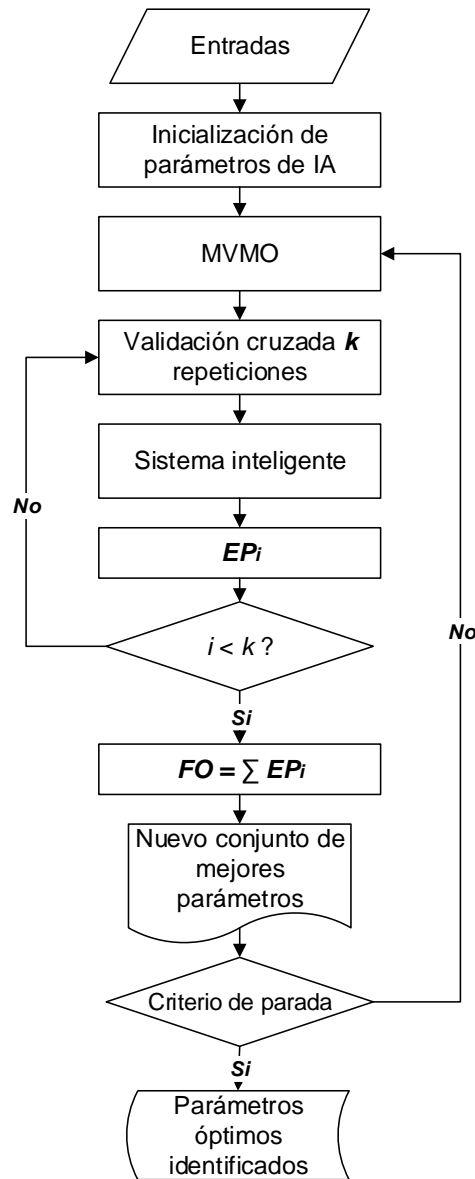


Figura 3.6. Metodología para identificación de parámetros de la IA basada en MVMO.

3.6 Conclusiones

La metodología propuesta para el monitoreo de la estabilidad está constituida por una fase de aprendizaje de fuera de línea y de ejecución en tiempo real, como herramienta central para la evaluación de la estabilidad de tensión se propone sistemas inteligentes.

La división del sistema de potencia en VCAs permite dividir las tareas de monitoreo de la estabilidad en cada área, asignándose a éstas una técnica de IA, esto con el fin de mejorar el desempeño del sistema inteligente.

3.7 Bibliografía

- Abe, S. (2006). *Support Vector Machines for Pattern Classification*. Springer Science & Business Media.
- Ajjarapu, V. (2006). *Computational Techniques for Voltage Stability Assessment and Control*. Springer.
- Ajjarapu, V., & Christy, C. (1992). The continuation power flow: a tool for steady state voltage stability analysis. *IEEE Transactions on Power Systems*, 7(1), 416–423. <https://doi.org/10.1109/59.141737>
- Billinton, & Li, W. (2013). *Reliability Assessment of Electric Power Systems Using Monte Carlo Methods*. Springer Science & Business Media.
- Billinton, R. (2013). *Reliability Evaluation of Power Systems*. Springer Science & Business Media.
- Bishop, C. M. (1996). *Neural Networks for Pattern Recognition* (1st ed.). Oxford University Press, USA.
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning. Pattern Recognition* (Vol. 4). <https://doi.org/10.1117/1.2819119>
- Cañizares, C. A., & Alvarado, F. L. (1993). Point of collapse and continuation methods for large AC/DC systems. *IEEE Transactions on Power Systems*, 8(1), 1–8. <https://doi.org/10.1109/59.221241>
- Cepeda, J. C. (2013). *Evaluación de la Vulnerabilidad del Sistema Eléctrico de Potencia en Tiempo Real usando Tecnología de Medición Sincrofasorial* (Tesis Doctoral). Universidad Nacional de San Juan, San Juan, Argentina.
- Cepeda, J. C., Rueda, J. L., Erlich, I., & Colomé, D. G. (2012). Probabilistic approach-based PMU placement for real-time power system vulnerability assessment. In *2012 3rd IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)* (pp. 1–8). <https://doi.org/10.1109/ISGTEurope.2012.6465671>
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Trans. Intell. Syst. Technol.*, 2(3), 27:1–27:27. <https://doi.org/10.1145/1961189.1961199>
- Chen, C. L., & Che, S. L. (1991). Short-term unit commitment with simplified economic dispatch. *Electric Power Systems Research*, 21(2), 115–120. [https://doi.org/10.1016/0378-7796\(91\)90025-I](https://doi.org/10.1016/0378-7796(91)90025-I)
- Cutsem, T. van, & Vournas, C. (1998). *Voltage Stability of Electric Power Systems*. Springer.
- Ding, S., Guo, L., & Hou, Y. (2017). Extreme learning machine with kernel model based on deep learning. *Neural Computing and Applications*, 28(8), 1975–1984. <https://doi.org/10.1007/s00521-015-2170-y>
- Dobson, I. (2010). New angles for monitoring areas. In *Bulk Power System Dynamics and Control (iREP) - VIII (iREP), 2010 iREP Symposium* (pp. 1–13). <https://doi.org/10.1109/IREP.2010.5563265>
- Dobson, I., Parashar, M., & Carter, C. (2010). Combining Phasor Measurements to Monitor Cutset Angles. In *2010 43rd Hawaii International Conference on System Sciences (HICSS)* (pp. 1–9). <https://doi.org/10.1109/HICSS.2010.110>
- Dobson, I., Van Cutsem, T., Vournas, C., DeMarco, C. L., Venkatasubramanian, M., Overbye, T., & Cañizares, C. A. (2002). Voltage stability assessment: Concepts, practices and tools. *IEEE Power Engineering Society, Power System Stability Subcommittee Special Publication*, 11, 21–22.

- Dommel, H. W., & Tinney, W. F. (1968). Optimal Power Flow Solutions. *IEEE Transactions on Power Apparatus and Systems*, PAS-87(10), 1866–1876. <https://doi.org/10.1109/TPAS.1968.292150>
- Dong, Z., Xu, Y., Wong, K., & Wong, K. P. (2013). Using IS to Assess an Electric Power System's Real-Time Stability. *IEEE Intelligent Systems*, 28(4), 60–66. <https://doi.org/10.1109/MIS.2011.41>
- Dong, Z., Zhang, P., Ma, J., Zhao, J., Ali, M., Meng, K., & Yin, X. (2010). *Emerging Techniques in Power System Analysis*. Springer Science & Business Media.
- Echeverría, D., Flores, V., Villa, W., & Cepeda, J. (2017). Identificación de Áreas de Control de Voltaje en el Sistema Nacional Interconectado de Ecuador utilizando Minería de Datos. *Revista Técnica Energía*, (13).
- Erlich, I. (2018, February 9). Mean-variance mapping optimization algorithm home page. Retrieved February 9, 2018, from <https://www.uni-due.de/mvmo/>
- Goderya, F., Metwally, A. A., & Mansour, O. (1980). Fast Detection and Identification of Islands in Power Networks. *IEEE Transactions on Power Apparatus and Systems*, PAS-99(1), 217–221. <https://doi.org/10.1109/TPAS.1980.319631>
- Hammouda, K., & Karray, F. (2013, June 19). A comparative Study of Data Clustering Techniques. University of Waterloo. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.126.3224&rep=rep1&type=pdf>
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques, Third Edition* (3rd ed.). Morgan Kaufmann.
- Haykin, S. S. (1994). *Neural Networks: A Comprehensive Foundation*. Macmillan.
- Hinojosa, V. . (2007). *Pronóstico de la demanda de corto plazo en sistemas de suministro de energía eléctrica utilizando inteligencia artificial* (Tesis Doctoral). Universidad Nacional de San Juan, San Juan, Argentina.
- Hsu, C., Chang, C., & Lin, C. (2010). *A practical guide to support vector classification*.
- Huang, G.-B., Zhu, Q.-Y., & Siew, C.-K. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*, 70(1–3), 489–501. <https://doi.org/10.1016/j.neucom.2005.12.126>
- Huang, Zhou, H., Ding, X., & Zhang, R. (2012). Extreme Learning Machine for Regression and Multiclass Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513–529. <https://doi.org/10.1109/TSMCB.2011.2168604>
- Lagonotte, P., Sabonnadiere, J. C., Leost, J.-Y., & Paul, J.-P. (1989). Structural analysis of the electrical system: application to secondary voltage control in France. *IEEE Transactions on Power Systems*, 4(2), 479–486. <https://doi.org/10.1109/59.193819>
- Lee, K. Y. (1999). Current Trend and the State of the Art in Intelligent System Applications to Power Systems (p. 80). Presented at the International Conference on Intelligent System Application to Power System, Rio de Janeiro, Brazil. Retrieved from https://sigarra.up.pt/faup/en/pub_geral.pub_view?pi_pub_base_id=8761
- Li, W. (2011). *Probabilistic Transmission System Planning*. John Wiley & Sons.
- Lie, T., Schlueter, R. A., Rusche, P. A. E., & Rhoades, R. H. (1993). Method of identifying weak transmission network stability boundaries. *IEEE Transactions on Power Systems*, 8(1), 293–301. <https://doi.org/10.1109/59.221228>
- Ljung, L. (2010). Perspectives on system identification. *Annual Reviews in Control*, 34(1), 1–12. <https://doi.org/10.1016/j.arcontrol.2009.12.001>
- Peña, D. (2002). *ANÁLISIS MULTIVARIANTE DE DATOS* (Edición: 1). Madrid: McGraw-Hill Interamericana de España S.L.
- Rueda, J. L., Cepeda, J. C., & Erlich, I. (2012). Estimation of location and coordinated tuning of PSS based on mean-variance mapping optimization. In *2012 IEEE Power and Energy Society General Meeting* (pp. 1–8). <https://doi.org/10.1109/PESGM.2012.6345025>

- Rueda, J. L., & Erlich, I. (2013). Optimal dispatch of reactive power sources by using MVMOs optimization. In *2013 IEEE Computational Intelligence Applications in Smart Grid (CIASG)* (pp. 29–36). <https://doi.org/10.1109/CIASG.2013.6611495>
- Sajan, K. S., Kumar, V., & Tyagi, B. (2015). Genetic algorithm based support vector machine for on-line voltage stability monitoring. *International Journal of Electrical Power & Energy Systems*, *73*, 200–208. <https://doi.org/10.1016/j.ijepes.2015.05.002>
- Schlueter, R. A. (1998). A voltage stability security assessment method. *IEEE Transactions on Power Systems*, *13*, 15.
- Schlueter, R. A., Hu, I.-P., Chang, M.-W., Lo, J. C., & Costi, A. (1991). Methods for determining proximity to voltage collapse. *IEEE Transactions on Power Systems*, *6*(1), 285–292. <https://doi.org/10.1109/59.131074>
- Sundaram, K., & Swarup, S. (2011). Classification and Assessment of Power System Security Using Multiclass SVM. *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions On*, *41*, 753–758. <https://doi.org/10.1109/TSMCC.2010.2091630>
- Villa, W. M., Rueda, J. L., Torres, S., & Peralta, W. H. (2012). Identification of voltage control areas in power systems with large scale wind power integration. In *Transmission and Distribution: Latin America Conference and Exposition (T D-LA), 2012 Sixth IEEE/PES* (pp. 1–7). <https://doi.org/10.1109/TDC-LA.2012.6319092>
- Wang, X.-F., Song, Y.-H., & Irving, M. (2008). *Modern Power Systems Analysis*. Springer.
- Wood, A. J., & Wollenberg, B. F. (2012). *Power Generation, Operation, and Control*. John Wiley & Sons.
- Zimmerman, R. D., Murillo-Sanchez, C. E., & Thomas, R. J. (2011). MATPOWER: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education. *IEEE Transactions on Power Systems*, *26*(1), 12–19. <https://doi.org/10.1109/TPWRS.2010.2051168>

4. IMPLEMENTACIÓN DE LA METODOLOGÍA

En este capítulo se realiza la prueba de viabilidad de la metodología propuesta usando el sistema de potencia de prueba “*New England*” de 39 nodos, adaptado para producir información de la respuesta de estado estable para realizar el análisis de estabilidad de tensión. Se presentan los resultados de los casos estudiados y el análisis de los resultados permite identificar las ventajas de la metodología propuesta para el monitoreo de la estabilidad de tensión en tiempo real usando técnicas de IA.

4.1 Sistema de potencia de prueba

Para validar la metodología propuesta se propone utilizar el sistema de prueba de la IEEE de 39 nodos (Pai, 1989). En la Figura 4.1 se presenta el diagrama unifilar del sistema IEEE 39 nodos o sistema “*New England*”. El sistema de prueba está conformado por 10 generadores con límites de potencia activa y reactiva, tiene 29 nodos de carga (nodos PQ), 12 transformadores y 34 líneas de transmisión; los datos de las líneas de transmisión, transformadores, demanda nodal, límites de potencia activa y reactiva fueron tomados de (Washington, 2018).




Figura 4.1. Diagrama unifilar del sistema *New England* de 39 nodos (Pai, 1989).

El proceso de simulación de Monte Carlo permite construir diferentes condiciones operativas cercanas a la realidad del sistema. Las condiciones operativas consisten de

diferentes escenarios o curvas de demanda horaria (con un horizonte de 24 horas) que se transfieren a las demandas nodales de los nodos PQ del sistema de 39 nodos. Los escenarios se construyen desde la demanda del caso base, tomada de la información original del sistema, y luego es modificada usando las curvas de demanda horaria según corresponda al tipo de usuario elegido para cada nodo (Cepeda, 2013b). En el trabajo de investigación se define la misma cantidad de nodos PQ que pertenecen a cada tipo de usuario residencial, comercial e industrial (ver Figura 3.2). La incertidumbre en la demanda se considera usando una PDF de una distribución normal con media igual a la demanda nodal en la hora h y desviación igual al 8% de la demanda nodal.

También se consideran en las condiciones operativas la ocurrencia de contingencias $N-1$, que afectan la estabilidad de tensión del sistema de prueba. Estas contingencias se generan en el proceso de Monte Carlo, asumiendo una tasa de ocurrencia promedio de salida igual a 0.04, tanto para líneas de transmisión como unidades de generación. Para el sistema con un elemento fallado se ejecuta el análisis de contingencias y luego se ejecuta el CPF, este se realiza para el sistema completo o fallado según sea el caso respectivo. Se determina el VSM para condiciones tanto de pre y pos contingencia en el sistema de prueba. Para el trabajo se construye matriz compuesta de 20.000 condiciones operativas, $X_{N \times n}$, donde N corresponde al número de condiciones operativas simuladas y n corresponde al número de fasores de tensión tomados para cada condición operativa; en este caso se toman los 39 fasores de tensión que corresponde a cada nodo del sistema. También, se construye una matriz $Y_{N \times 1}$ donde se almacena el VSM calculado para cada condición simulada.

4.2 Identificación de VCAs

La determinación de las VCAs para el sistema de potencia es un paso previo y necesario para la evaluación en tiempo real de la estabilidad de tensión, por lo cual se ejecuta la metodología planteada en la sección 3.3.2. Como paso inicial se definen las PDFs como una distribución normal para las demandas nodales del sistema de prueba, considerando los mismos parámetros indicados en la sección 4.1. Para la selección de contingencias se usa la PDF de distribución de Poisson, solo se consideran salidas de líneas de transmisión y transformadores del sistema de prueba, con una tasa de ocurrencia promedio de una contingencia igual a 0.04. Para la identificación de las VCAs en el sistema de prueba de 39 nodos se realizaron 30000 simulaciones de diferentes condiciones operativas.

Debido a que la delimitación de las VCAs es influenciada por las diferentes condiciones de demanda del sistema y en gran medida por los cambios topológicos causados por la salida de líneas de transmisión y transformadores, la metodología implementada permite identificar diferentes cantidades de VCAs o configuraciones de áreas según sea la condición operativa evaluada. Al final del proceso de identificación de las VCAs se realiza un análisis estadístico con el fin de identificar la configuración más típica de VCAs; es decir, la que más se repite para el sistema analizado. Esta configuración es seleccionada para el sistema de prueba de 39 nodos sobre la cual se continúa trabajando.

En la Figura 4.2 se muestra el histograma que presenta la frecuencia de las diferentes configuraciones de VCAs, en donde la evaluación de todos los escenarios propuestos revela la formación de 2 a 7 VCAs en el sistema. Note que la configuración con 5 áreas es la más

típica, seguida de la configuración de 4 áreas.

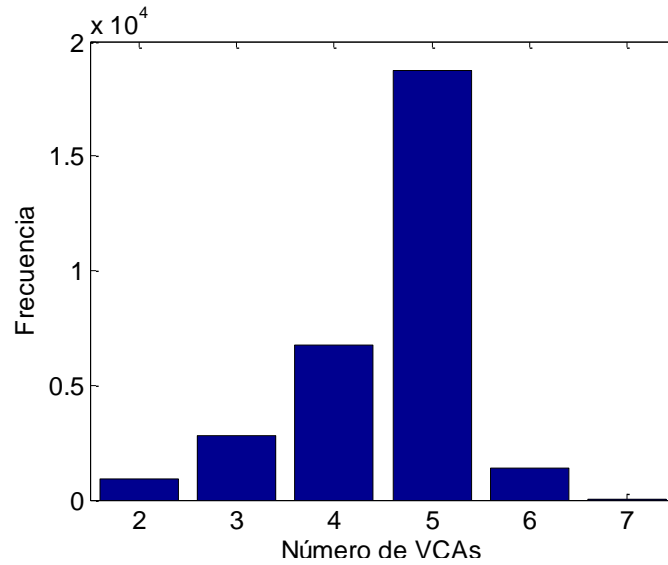


Figura 4.2. Histograma del número de VCAs posibles en el sistema.

En la Figura 4.3 se presentan la configuración de las VCAs que fueron identificadas en gran parte de las condiciones operativas generadas con la metodología basada en el método de Monte Carlo.

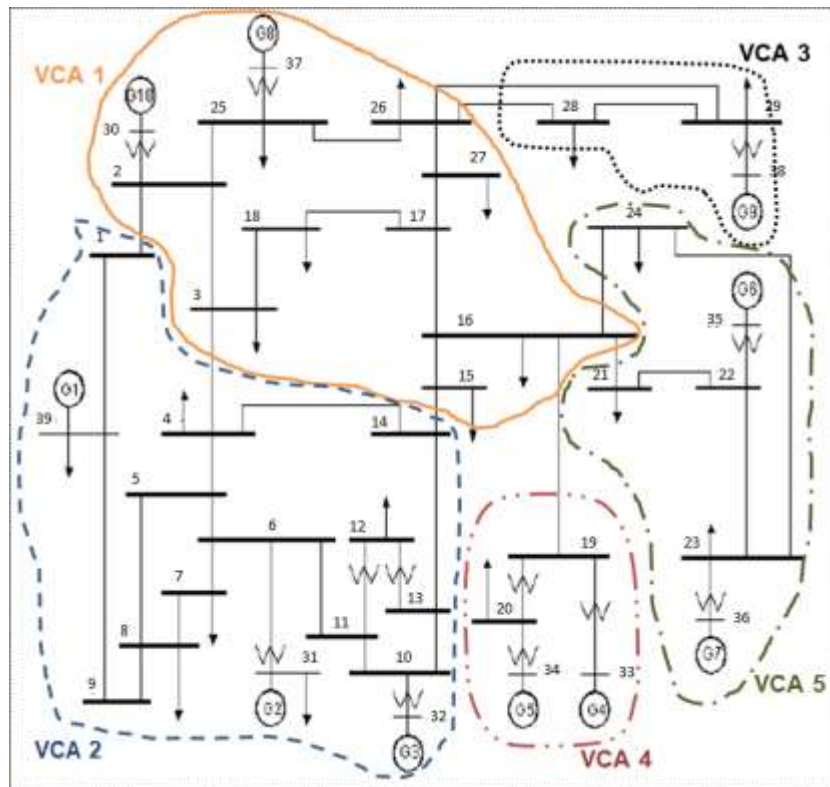


Figura 4.3. Configuración más típica de VCAs encontrada.

4.3 Entrenamiento de sistemas inteligentes

En esta etapa se realiza la valoración preliminar de los sistemas inteligentes que se proponen para trabajar en la evaluación de la estabilidad de tensión (RNA, RSV y KMAE), con la herramienta de IA que presente mejor resultado se ejecuta la implementación de monitoreo de la estabilidad de tensión propuesta. La evaluación de la estabilidad se clasifica como tarea de regresión que consiste en establecer una relación entre las entradas y salidas, usando pares conocidos de entrada y salida. Para la entrada se tienen varios atributos o “*features*” y para la salida un valor objetivo o “*target value*”. El objetivo del entrenamiento es construir un modelo de la IA basado en los datos de entrenamiento, el cual predice los valores objetivos de los datos de prueba solo con los atributos de los datos de prueba (Chang & Lin, 2011; Hsu et al., 2010).

La base de datos está conformada por las matrices $X_{N \times n}$ que está formada por los atributos y $Y_{N \times 1}$ los valores objetivos. En el entrenamiento de IAs es común dividir el conjunto de datos en un subconjunto de entrenamiento y uno de prueba. En este caso el 70% de los datos se usan en el entrenamiento y 30 % en la validación de la IA. Un aspecto importante previo al entrenamiento de los sistemas inteligentes, especialmente las IA con kernel, es la necesidad de identificar los parámetros óptimos del kernel que presentan mejores resultados para los datos manejados por cada IA (Hsu et al., 2010). El método de identificación de parámetros de la IA fue presentando en la subsección 3.4.1, tomado de Cepeda, 2013.

4.3.1 Identificación de parámetros del sistema inteligente

Antes del entrenamiento del RSV y KMAE se deben determinar los parámetros óptimos que permiten obtener una mejor exactitud en la respuesta de la IA (Hsu et al., 2010; Huang et al., 2012). Como se ha mencionado, se usa la validación cruzada de k repeticiones con el método “*grid search*” para prevenir problemas de sobreajuste. Este procedimiento es computacionalmente intensivo debido a que el número de combinación de los parámetros es grande; además, es un proceso de búsqueda local cuyo intervalo de la búsqueda es difícil de establecer (Chang & Lin, 2011). Como solución a los problemas anteriores se ha desarrollado una alternativa presentada en (Cepeda, 2013b), donde se usa un algoritmo de optimización heurística llamado MVMO para determinar los mejores parámetros de la IA con kernel. Los parámetros óptimos que se deben identificar para RSV son ε , C y γ según la ecuación (3.12), los parámetros óptimos a identificar para KMAE son C y γ . La metodología propuesta para la identificación de los parámetros de la IA, usando MVMO, se presenta en la subsección 3.4.1. En este caso se usan 10 repeticiones en la validación cruzada para garantizar una regresión robusta. Basado en (Cepeda, 2013b) se define el espacio de búsqueda de los parámetros de la IA de siguiente forma: $C \in [2^{-5}, 2^{15}]$, $\gamma \in [2^{-15}, 2^5]$, $\varepsilon \in [2^{-5}, 2^0]$.

Para ejecutar la RSV se utiliza la librería de máquinas de soporte vectorial (LIBSVM, por sus siglas en inglés) para el diseño, entrenamiento y prueba del modelo de RSV (Hsu et al., 2010). Para ejecutar la KMAE se utiliza el código computacional y adaptado para este trabajo que se encuentra en (Huang, 2018). Para la RNA tipo *backpropagation* se usa el paquete de redes neuronales del programa Matlab (Math Works, Inc., 2018).

La identificación de los parámetros se aplica a los datos generados de fasores de tensión y VSM con el sistema de prueba de 39 nodos. En la Figura 4.4 se presenta la convergencia del proceso de optimización del MVMO, que fue implementado para la identificación de los parámetros óptimos para el entrenamiento de RSV y KMAE.

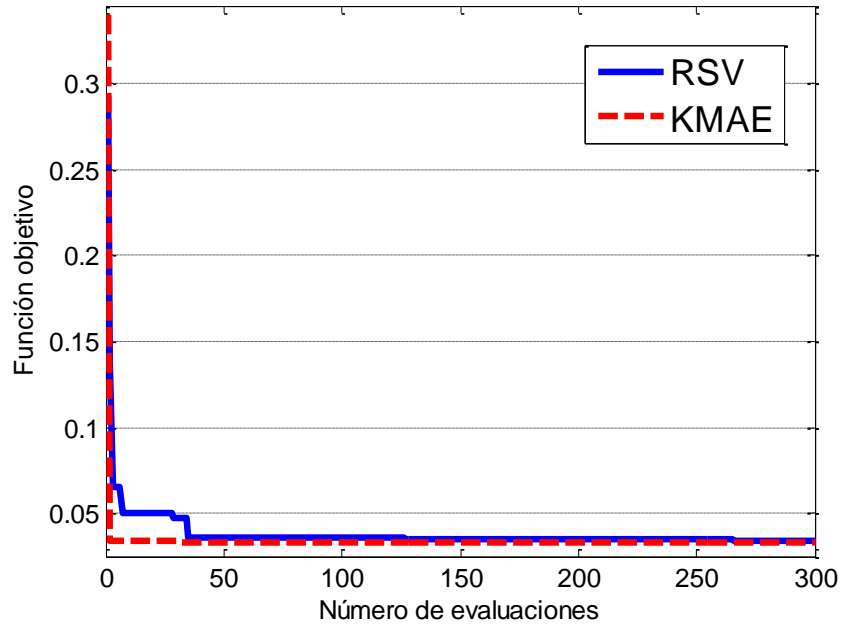


Figura 4.4. Convergencia del MVMO en el proceso de identificación de parámetros óptimos de la IA.

En la Tabla 4.1 se presentan los parámetros óptimos para cada IA usado en la aproximación de funciones (IA-regresor) obtenidos para 10000 muestras obtenidas por medio del proceso Monte Carlo para el sistema de 39 nodos.

Tabla 4.1. Parámetros óptimos identificados para la IA.

<i>IA-Regresor</i>	<i>Parámetros identificados</i>		
	<i>Log₂C</i>	<i>Log₂γ</i>	<i>Log₂ε</i>
<i>RSV</i>	12.888	0.675	-4.778
<i>KMAE</i>	7.840	-5.237	-----

4.3.2 Selección del sistema inteligente

De la revisión de la literatura técnica, se identificó que se ha trabajado en evaluación de estabilidad de tensión con sistemas inteligentes como la RNA, MSV y en menor medida con MAE, para el trabajo de investigación se propone realizar una prueba preliminar para determinar las capacidades de generalización de las IA en relación a la estimación del margen de estabilidad de tensión para el sistema de 39 nodos. La prueba de selección consiste en que para cada condición simulada se genera la información de los fasores de tensión de todos los nodos y el respectivo VSM. Se entrena el sistema con los parámetros óptimos obtenidos en la sección anterior, Para la prueba de desempeño de la IA se consideran las siguientes condiciones (Glavic & Van Cutsem, 2009b):

- ✓ Caso 1: Medidas de fasores de tensión sin ruido en la magnitud de los fasores.

- ✓ Caso 2: En las medidas de los fasores se agrega ruido de forma aleatoria con una distribución normal de media cero y desviación igual 0.01 p.u.
- ✓ Caso 3: En las medidas de los fasores se agrega ruido de forma aleatoria con una distribución normal de media cero y desviación igual 0.04 p.u.

En la Tabla 4.2 se muestran los resultados de la prueba preliminar de desempeño de la IA. En este caso se define como índice de desempeño el error medio cuadrático (MSE, por sus siglas en inglés) para las estimaciones realizadas por los IA-regresor. Se consideran 5000 muestras seleccionadas aleatoriamente de la base de datos. Se calcula el MSE considerando todas las muestras de prueba, el tiempo de entrenamiento corresponde al entrenamiento con 10.000 muestras diferentes a las de la etapa de la prueba, y el tiempo de prueba corresponde a la ejecución de las 5000 muestras. Para la RNA se identificó el número óptimo de neuronas en la capa oculta igual a veinte, y los parámetros óptimos de RSV y KMAE se muestran en la Tabla 4.1.

Tabla 4.2. MSE obtenidos en la prueba de selección de la IA.

<i>IA- Regresor</i>	<i>MSE</i>			<i>Tiempo de entrenamiento (s)</i>	<i>Tiempo de prueba (s)</i>
	<i>Caso 1</i>	<i>Caso 2</i>	<i>Caso 3</i>	<i>Caso 1</i>	<i>Caso 1</i>
<i>RNA</i>	0.0029	0.1005	0.8872	390.25	0.145
<i>RSV</i>	0.0543	0.4264	2.2049	28.7470	0.2831
<i>KMAE</i>	0.0534	0.3470	0.4364	5.4758	0.8446

Se observa en la Tabla 4.2, que KMAE tiene una predicción más exacta en condiciones de gran cantidad de ruido donde los datos de entrada son diferentes a los datos de entrenamiento, situación que se presenta en caso 3. La segunda más exacta es RNA, seguida de RSV. En relación al tiempo de entrenamiento, KMAE tiene el menor tiempo comparada con las otras IAs. El tiempo de ejecución para KMAE es igual 0.844 segundos siendo el mayor valor, pero adecuado para el problema a resolver.

Para el presente trabajo de investigación se selecciona KMAE para realizar la evaluación de la estabilidad de tensión en largo alcance debido al buen desempeño en las predicciones realizadas, y un tiempo aceptable en obtenerlas, esto corresponde al tiempo de entrenamiento y de ejecución o prueba.

4.4 Método de monitoreo de líneas de interconexión entre VCAs

Para vigilar los vínculos de transmisión entre las VCAs se implementa el método llamado “ángulos del conjunto de corte” o *cutset angles*. Antes de ejecutar el método se deben identificar las áreas en las cuales el sistema de potencia se puede dividir. En este trabajo se asume como criterio principal de división la variación de la tensión eléctrica en función de la potencia reactiva, como se presenta en la sección 3.3. Se define como área *cutset* el área conformada por las líneas de interconexión que unen a las diferentes áreas operativas. Estas líneas están conectadas a los nodos frontera de cada área (Dobson, 2010, 2012; Dobson et al., 2010). El área *cutset* no debe contener generación o demanda, es decir, solo se deben incluir los nodos de paso.

Para las líneas que separan las áreas del sistema de potencia se define la diferencia angular ($\hat{\theta}_c$) a través del área “*cutset*”; esta es una combinación lineal de la diferencia angular de cada línea de transmisión que hace parte del *cutset*. Suponiendo que los datos del sistema como las impedancias de la red, ángulos de tensión en cada nodo son conocidos. Con el área *cutset* que divide al sistema de potencia en dos áreas, por ejemplo en área A y área B, se asume $\hat{\theta}_j$ como la diferencia entre los ángulos de los nodos frontera de cada área, se define la potencia que fluye por el área *cutset* como:

$$P_c = \sum_{j \in c} b_j \hat{\theta}_j \quad (4.1)$$

Donde: b_j es susceptancia de la línea j , $\hat{\theta}_j$ es la diferencia angular a través de la línea j , P_c es la potencia que fluye por las c líneas de transmisión que conforman el área *cutset*. Se define $\hat{\theta}_j$ de forma que la diferencia sea positiva para el flujo sobre la línea j desde la zona A a la zona B. La susceptancia equivalente del área *cutset* o corredor de transmisión se define como:

$$b_c = \sum_{j \in c} b_j \quad (4.2)$$

El ángulo del *cutset* ($\theta_{AB} = \hat{\theta}_c$) es un promedio ponderado de los ángulos de los fasores en los nodos de la frontera de las áreas. Se definen como la combinación lineal de las diferencias angulares ponderadas de acuerdo con susceptancia de cada línea que conforma el área *cutset*, se calcula de la siguiente manera:

$$\hat{\theta}_c = \sum_{j \in c} \frac{b_j}{b_c} \hat{\theta}_j \quad (4.3)$$

La aplicación del método anterior permite supervisar la potencia que se transmite a través del área *cutset* o de una línea determinada. Esta supervisión permite monitorear si se tienen sobrecargas en las líneas de transmisión. Para la estimación del ángulo en *cutset* se requieren medidas del ángulo del fasor en cada uno de los nodos donde llega cada una de las líneas de transmisión que conforman el *cutset*. El cambio de los ángulos del *cutset* entre áreas permiten valorar los cambios que suceden en el sistema, por ejemplo, un aumento de potencia a través del *cutset* o estimación del estrés en las líneas, se define el $\Delta \hat{\theta}_c$ adaptado de (Lopez et al., 2012), como:

$$\Delta \hat{\theta}_{ci} = \hat{\theta}_{c RC} - \hat{\theta}_{c NC} \quad (4.4)$$

Donde: $\Delta \hat{\theta}_{ci}$ es la variación del ángulo *cutset* del área *cutset* i , $\hat{\theta}_{c RN}$ y $\hat{\theta}_{c NC}$ son respectivamente los ángulos *cutset* del sistema en la condición actual y en la operación del caso base o normal.

La diferencia angular da un indicativo de que tan fuerte o débil es un área con respecto a las demás. Por ejemplo, si se tiene una área con una gran variación del ángulo del *cutset*, esta área es débil y por tanto las áreas operacionales que tengan cercanías con esta área son menos resistentes a mantener la integridad del sistema ante alguna perturbación (Lopez et al., 2012).

Según los resultados obtenidos en la sección 4.2, el sistema de 39 nodos se divide en cinco

áreas, para las cuales en la Tabla 4.3 se presentan la información de las líneas que conforman las diferentes áreas *cutset*. Estas se forman al considerar las líneas que unen las diferentes VCAs que se presentan en la Figura 4.3.

Tabla 4.3. Líneas de las áreas *cutset* obtenidas para el sistema de prueba.

<i>Área cutset</i>	<i>VCA frontera</i>	<i>Líneas cutset</i>	<i>Susceptancia (p.u.)</i>
1	VCA 1 – VCA 2	1 --- 2	24.3309
		3 --- 4	46.9484
		15 --- 14	46.0829
2	VCA 1 – VCA 3	26 --- 29	16.000
		26 --- 28	21.0970
3	VCA 1 – VCA 4	16 --- 19	51.2821
4	VCA 1 – VCA 5	16 --- 24	169.4915
		16 --- 21	74.0741

4.5 Monitoreo de estabilidad de tensión en tiempo real

Monitoreo sobre las VCAs:

Antes de ejecutar la evaluación de la estabilidad en tiempo real, se deben identificar las VCAs que conforman el sistema de potencia de prueba, luego para cada VCA y área *cutset* se deben obtener los parámetros óptimos de cada KMAE, esto corresponde al modo de aprendizaje fuera de línea. Para cada VCA identificada se implementa una KMAE que realice el monitoreo de la estabilidad de tensión en cada área, para cada IA se deben obtener los parámetros óptimos de la KMAE, en la Tabla 4.4 se presentan los parámetros encontrados con la metodología presentada en la sección 3.4.1.

Tabla 4.4. Parámetros óptimos identificados para cada área *cutset* (AC).

<i>IA-Regresor</i>	<i>Parámetros identificados</i>	
	<i>Log₂C</i>	<i>Log₂γ</i>
<i>KMAE-VCA1</i>	8.1261	-10.6538
<i>KMAE-VCA2</i>	7.3046	-11.5275
<i>KMAE-VCA3</i>	7.3953	-14.9654
<i>KMAE-VCA4</i>	6.7071	-13.2399
<i>KMAE-VCA5</i>	3.3570	-15.000

En la Figura 4.5 se ilustra la convergencia del MVMO en la identificación de los parámetros C y γ , de cada KMAE. Como se observa en la figura después de 150 evaluaciones no se produce un cambio considerablemente en el valor de la función objetivo en identificación de los parámetros, esto es debido a la característica de convergencia rápida que posee el MVMO.

Luego, con los parámetros óptimos de cada KMAE se entrena y se realiza la validación con 5000 muestras seleccionadas aleatoriamente desde la base de datos. Se evalúa el desempeño usando el MSE y la raíz cuadrada del error medio (RMSE, por sus siglas en inglés), este último corresponde a la evaluación de la desviación estándar de la predicción

realizada. En la Tabla 4.5 se presentan los resultados de los índices de desempeño realizados para cada KMAE de cada VCA del sistema.

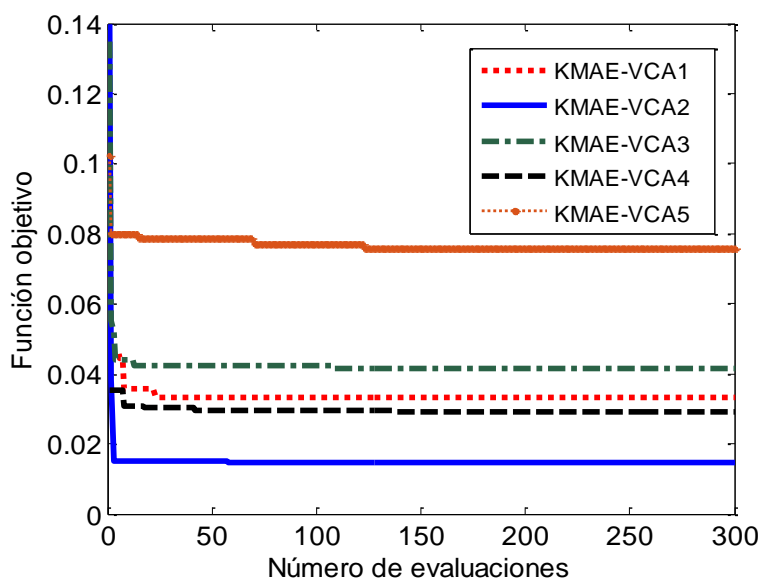


Figura 4.5. Convergencia del MVMO en la identificación de parámetros óptimos para cada KMAE.

Tabla 4.5. MSE y RMSE obtenidos en la validación de KMAE para cada VCA.

<i>IA-Regresor</i>	<i>MSE</i>	<i>RMSE</i>
<i>KMAE-VCA1</i>	0.0030	0.0548
<i>KMAE-VCA2</i>	0.0014	0.0395
<i>KMAE-VCA3</i>	0.0038	0.0631
<i>KMAE-VCA4</i>	0.0028	0.0539
<i>KMAE-VCA5</i>	0.0072	0.0848

De la Tabla 4.5 se observa que cada KMAE tiene una muy buena respuesta en la predicción del índice de estabilidad (VSM) que caracteriza cada VCA, esto se deduce de los valores de errores pequeños que se obtienen en la validación de las KMAE. Esto se confirma en la Figura 4.6 donde observa la proximidad entre los valores de VSM reales y los que son estimados con KMAE-VCA2.

Monitoreo sobre las áreas cutset o líneas de interconexión:

Para cada área cutset (AC) definida se obtienen los parámetros óptimos del KMAE implementada para monitorear las líneas de interconexión entre las VCAs, en la Tabla 4.6 se presentan los parámetros óptimos encontrados para cada IA que vigila las líneas de interconexión.

Tabla 4.6. Parámetros óptimos identificados para cada AC o interconexiones.

<i>IA-Regresor</i>	<i>Parámetros identificados</i>	
	<i>Log₂C</i>	<i>Log₂γ</i>
<i>KMAE-AC1</i>	13.4764	-5.7845

<i>KMAE-AC2</i>	13.9343	-7.4093
<i>KMAE-AC3</i>	14.7865	-8.6979
<i>KMAE-AC4</i>	14.7291	-6.7085

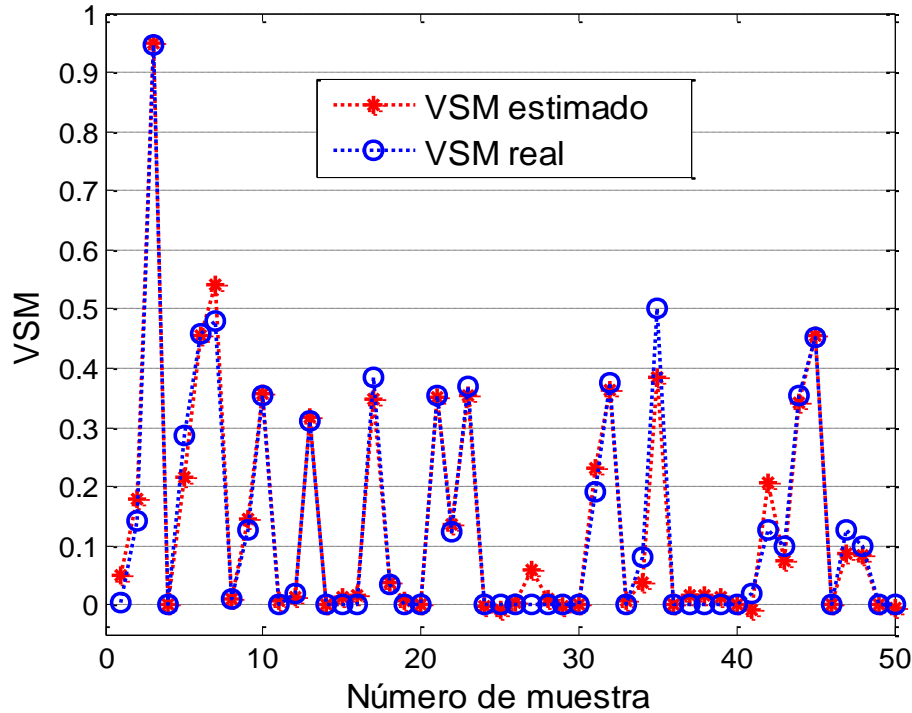


Figura 4.6. Comparación entre los valores reales y estimados de VSM para la VCA2.

Para cada técnica de IA (KMAE-AC) que vigila las interconexiones se define el objetivo a estimar por la IA como la diferencia angular del área cutset expresada en la ecuación (4.4). Para la validación se evalúan 5000 muestras seleccionadas aleatoriamente desde la base de datos. En la Tabla 4.7 se presentan los resultados del MSE y RMSE obtenidos en la prueba de validación de las técnicas KMAE implementadas para vigilar las interconexiones.

Tabla 4.7. MSE y RMSE obtenidos en la validación de KMAE para cada AC.

<i>IA-Regresor</i>	<i>MSE</i>	<i>RMSE</i>
<i>KMAE-AC1</i>	1.79 e-5	0.0042
<i>KMAE-AC2</i>	4.92e-5	0.0070
<i>KMAE-AC3</i>	2.95e-5	0.0054
<i>KMAE-AC4</i>	1.01e-4	0.0101

De la Tabla 4.7 se observa que según el MSE, la KMAE-AC4 presenta el mayor error medio; sin embargo, este se encuentra dentro de los valores aceptables de predicción. El resto de las KMAE-AC tienen un buen desempeño según los valores de MSE reportados. En la Figura 4.7 se presenta la comparación en los valores reales y estimados de $\Delta\hat{\theta}_{ci}$ para la AC4.

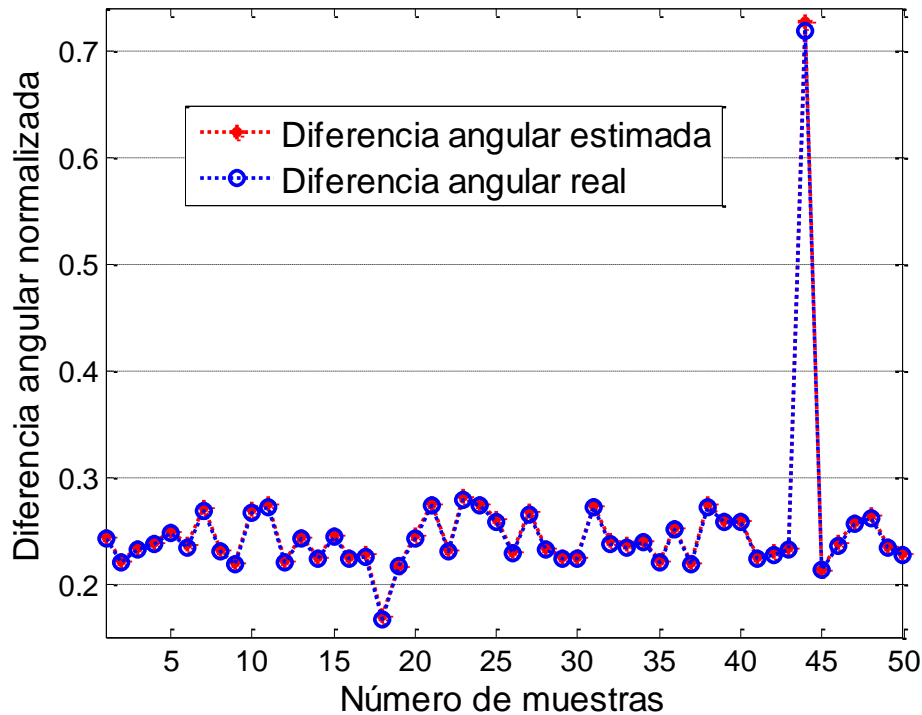


Figura 4.7. Comparación entre los valores reales y estimados de la diferencia angular cutset normalizada [0-1] para AC4.

4.6 Bibliografía

- Cepeda, J. C. (2013). *Evaluación de la vulnerabilidad del sistema eléctrico en tiempo real usando tecnología de medición sincrofasorial* (Tesis Doctoral). Universidad Nacional de San Juan, San Juan, Argentina.
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A Library for Support Vector Machines. *ACM Trans. Intell. Syst. Technol.*, 2(3), 27:1–27:27. <https://doi.org/10.1145/1961189.1961199>
- Dobson, I. (2010). New angles for monitoring areas. In *Bulk Power System Dynamics and Control (iREP) - VIII (iREP), 2010 iREP Symposium* (pp. 1–13). <https://doi.org/10.1109/IREP.2010.5563265>
- Dobson, I. (2012). Voltages Across an Area of a Network. *IEEE Transactions on Power Systems*, 27(2), 993–1002. <https://doi.org/10.1109/TPWRS.2011.2168985>
- Dobson, I., Parashar, M., & Carter, C. (2010). Combining Phasor Measurements to Monitor Cutset Angles. In *2010 43rd Hawaii International Conference on System Sciences (HICSS)* (pp. 1–9). <https://doi.org/10.1109/HICSS.2010.110>
- Glavic, M., & Van Cutsem, T. (2009). Wide-Area Detection of Voltage Instability From Synchronized Phasor Measurements. Part II: Simulation Results. *IEEE Transactions on Power Systems*, 24(3), 1417–1425. <https://doi.org/10.1109/TPWRS.2009.2023272>
- Hsu, C., Chang, C., & Lin, C. (2010). *A practical guide to support vector classification*.
- Huang, G.-B. (2018). Extreme Learning Machines: Random Neurons, Random Features, Kernels [Científica]. Retrieved April 24, 2018, from <http://www.ntu.edu.sg/home/egbhuang/>
- Huang, Zhou, H., Ding, X., & Zhang, R. (2012). Extreme Learning Machine for Regression and Multiclass Classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513–529. <https://doi.org/10.1109/TSMCB.2011.2168604>

- Lopez, G. J., Gonzalez, J. W., Leon, R. A., Sanchez, H. M., Isaac, I. A., & Cardona, H. A. (2012). Proposals based on cutset area and cutset angles and possibilities for PMU deployment. In *2012 IEEE Power and Energy Society General Meeting* (pp. 1–6). <https://doi.org/10.1109/PESGM.2012.6345144>
- Math Works, Inc. (2018). MATLAB. Retrieved April 24, 2018, from <https://la.mathworks.com/products/matlab.html>
- Pai, M. A. (1989). *Energy Function Analysis for Power System Stability*. Springer.
- Washington, U. (2018). Power Systems Test Case Archive - UWEE [Academic]. Retrieved April 16, 2018, from <http://www2.ee.washington.edu/research/pstca/>

5. CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

- La metodología para la evaluación en tiempo real de la estabilidad de tensión permite monitorear la estabilidad en áreas del sistema de potencia, como también vigilar el incremento de potencia a través de la diferencia angular entre las líneas de interconexión entre dichas áreas. Esto significa que se vigilan los mecanismos que causan inestabilidad de tensión, debido tanto al déficit de potencia reactiva en las VCAs como al incremento de flujo de potencia en las líneas de interconexión entre áreas.
- Para la evaluación en tiempo real es importante la definición previa de las VCAs del sistema de potencia de potencia vigilado. Con la delimitación de las VCAs se garantiza un adecuado monitoreo de los nodos débiles, desde el punto de vista de estabilidad de tensión, y se identifican a priori las fuentes de generación que influyen directamente sobre estos nodos; es decir, estos generadores controlan el incremento de la demanda de potencia reactiva en los nodos de carga de la VCA, convirtiéndose en la reserva de potencia reactiva del área.
- Con la identificación de las VCAs para el sistema de potencia se evita la necesidad de usar herramientas de minería de datos para la reducción de características que utilizan para mejorar el desempeño de la IA. Con la división del sistema en VCAs se reduce el número de nodos que vigila cada IA, esta propuesta de reducción de las características se fundamenta en el comportamiento de nodos coherentes con relación a la estabilidad de tensión, más no desde el punto de vista de la minería de datos.
- Por primera vez se implementa la máquina de aprendizaje extremo con kernel (KMAE) para ejecutar la evaluación de la estabilidad de tensión, en la prueba de selección preliminar se muestra que la KMAE comparada con RNA y MSV entrega mejores resultados en la predicción del índice de estabilidad de tensión. La comparación se realiza con el índice desempeño MSE, que compara que tan cerca están la predicción entregada de los valores reales.
- La metodología propuesta garantiza desde la etapa de entrenamiento la adaptación óptima de la IA al problema de evaluación estabilidad de tensión en tiempo real, teniendo como consecuencia el buen desempeño de la IA en la ejecución en tiempo real.
- Se propone un método Monte Carlo para la construcción de la base de datos para la etapa de aprendizaje de la IA. Este método permite considerar diferentes escenarios y diferentes condiciones operativas (Contingencias N-1), garantizando información lo más cercana a la realidad del sistema, siempre y cuando se tome información de entrada cerca a la realidad de la operación del sistema.

5.2 Recomendaciones y Retos Futuros

- Para el buen desempeño de la metodología propuesta se debe disponer de información confiable del sistema de potencia, tal como: la demanda nodal, tipificación de los tipos de usuarios, probabilidad de falla de líneas de transmisión, transformadores y generadores, y la información validada de parámetros de las líneas y transformadores.
- Considerar una mayor cantidad de escenarios de demanda con sus respectivos despachos de generación, también la probabilidad de salida de los elementos de conexión debe ser actualizada cada cierto período de tiempo, por ejemplo un año, con el fin de garantizar información más cercana a la realidad. Por otra parte, dado que la salida de líneas y transformadores tienen mayor influencia en la definición de las VCAs, se debe tener cuidado en el momento de seleccionar las líneas que salen dentro del método de delimitación de VCAs.
- Para garantizar un buen desempeño en la evaluación de la estabilidad de tensión, se debe garantizar que la información de los parámetros del modelo de las líneas sea confiable. La validación de los parámetros de las líneas se puede realizar implementando un método de validación de los parámetros tanto para las líneas como transformadores, esto se logra usando mediciones fasoriales sincronizadas para actualizar los modelos del sistema, lo que permite que los resultados de simulación sean más cercanos al comportamiento real del sistema.
- Para este trabajo de investigación, se usó el índice de estabilidad de tensión denominado margen de carga o VSM, como futuro trabajo se propone realizar un análisis con otros índices de estabilidad de tensión con un comportamiento predecible ante cambios del sistema tanto topológicos como de demanda.

Estudiante:

Walter of Villa

Walter Mauricio Villa Acevedo

Director

Jesús M. Lezama

Jesús María López Lezama

Fecha: Medellín, 04 de Mayo de 2018.