

Evaluación de la estabilidad de tensión en tiempo real usando herramientas de inteligencia artificial

Por:

M.I Walter M. Villa



Grupo de manejo eficiente de la energía, GIMEL

Departamento de Ingeniería Eléctrica

Universidad de Antioquia

Medellín

Diciembre de 2018



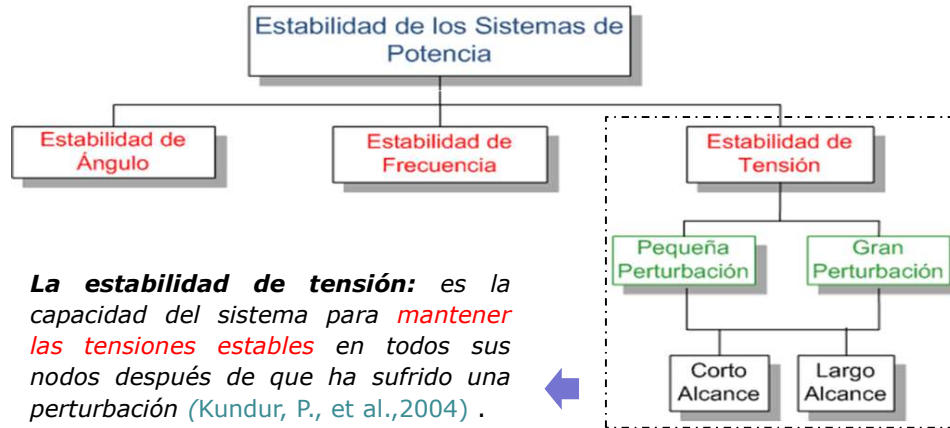
AGENDA



1. Introducción
2. Monitoreo de estabilidad de tensión
3. Planteamiento del problema
4. Objetivo
5. ¿Por qué inteligencia artificial?
6. Metodología desarrollada
7. Resultados
8. Trabajos futuros



1. Introducción



La estabilidad de tensión: es la capacidad del sistema para *mantener las tensiones estables* en todos sus nodos después de que ha sufrido una perturbación (Kundur, P., et al.,2004) .

Necesidad de nuevos métodos de supervisión de la operación en tiempo real para garantizar la operación segura del sistema.

3



1. Introducción

Índice de estabilidad de tensión

Es una magnitud escalar para determinar *la distancia desde punto de operación actual al límite de estabilidad de tensión* del sistema eléctrico.

Algunas características deseadas del índice son (Cañizares, 2002):

- *Sensible* y comportamiento *predecible* frente a los incrementos de carga.
- *Observable* cuando los parámetros del sistema cambian.
- Cálculo *rápido* para aplicaciones en línea del sistema.

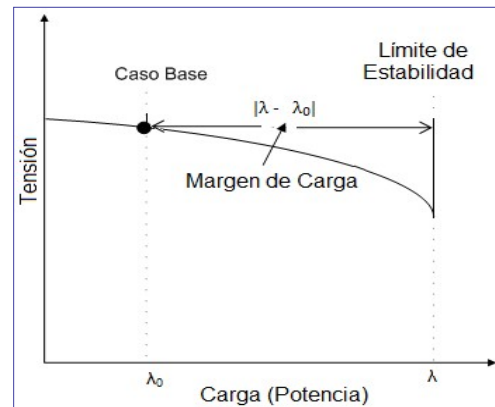


Fig. 1 Margen de carga (VSM).

4



1. Introducción

Mecanismos de inestabilidad de tensión:

1. Pérdida de control de tensión.

- Incapacidad de mantener constante la tensión de los generadores (Schlueter, 1998).
- Reducción del suministro de la potencia reactiva.
- Aumento de las pérdidas.

2. Incapacidad de transmisión.

- Aumento de las pérdidas en las líneas.
- Alcance de límites de operación, disminución de aporte de reactiva.
- Limitación en la capacidad de reactiva (sin alcanzar límites Q en los generadores).




Fig. 2 Colapso de tensión.

2. Monitoreo de la estabilidad de tensión



Cálculo en tiempo real:

- Los datos reflejan la más reciente imagen de las condiciones del sistema.
- Tiempo de cálculo muy corto (**1-3s**).



Cálculo en línea:

- Se considera que el estado del sistema no cambia significativamente.
- Tiempo de cálculo alrededor de **5 a 15 min**.

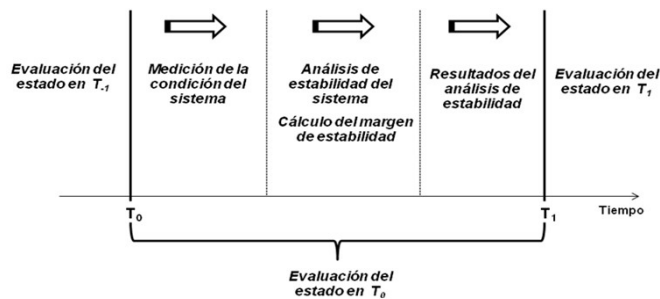


Fig. 3 Pasos en la evaluación de la estabilidad en tiempo real (Nguegan, 2009).



2. Monitoreo de la estabilidad de tensión

Sistemas de medición sincronizada

Las PMUs miden "fasores" de las ondas sinusoidales de tensión y de corriente con respecto a una *referencia común*.

Densidad de muestreo (más de 50 ó 60 medidas por seg)

Etiquetas de tiempo con una exactitud < 1 μ s (Phadke, 1993).

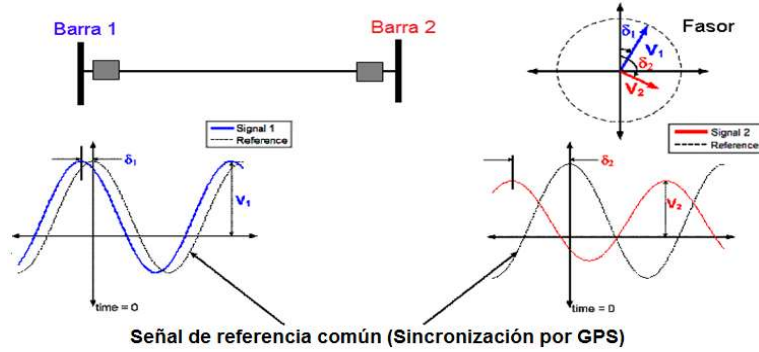
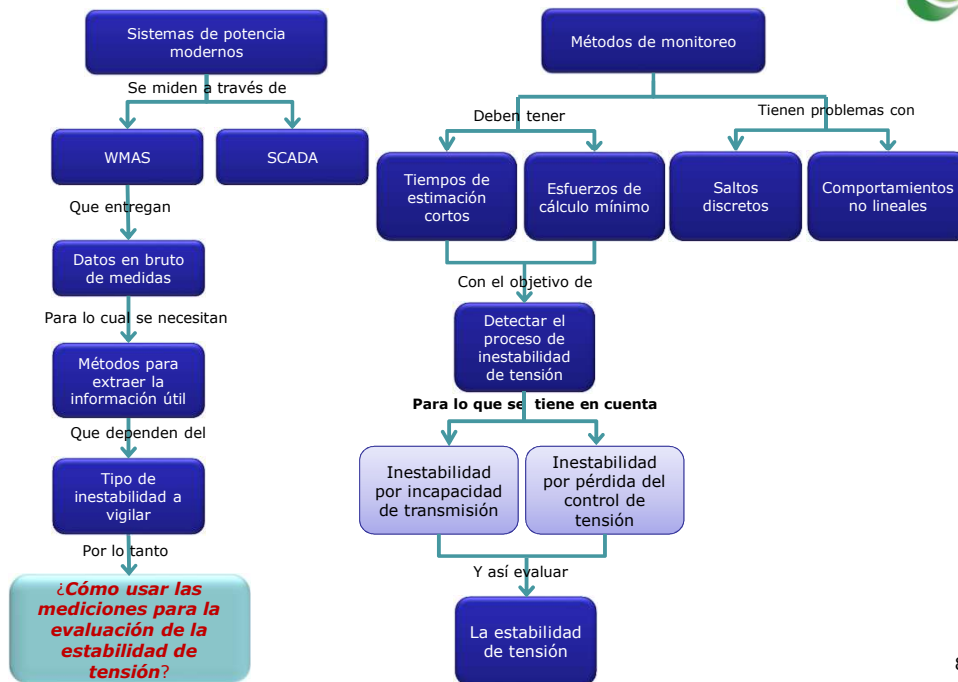


Fig. 4 Medición sincronizada de fasores.

7

3. Planteamiento del problema



8

4. OBJETIVO

Desarrollar una metodología 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.

5. ¿Por qué la IA es una alternativa promisoría?

Ventajas para la evaluación en tiempo real de la estabilidad :

- Rapidez.
- Extracción de conocimiento.
- Capacidad de generalización.
- Menor cantidad de datos.
- Mayor versatilidad.




Fig. 6 Red Neuronal Artificial.




Fig. 5 Arquitectura de Máquina de Aprendizaje Extremo.


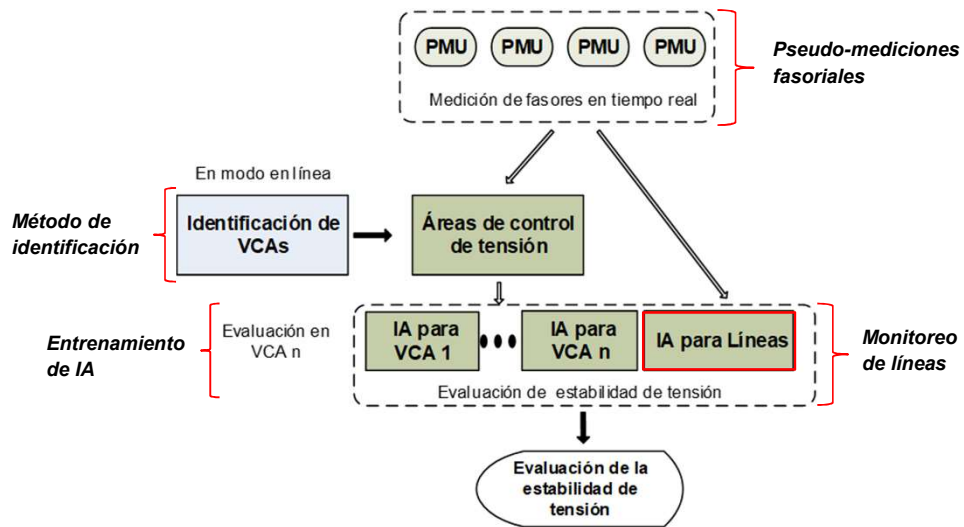


Fig. 7 Máquina de Soporte Vectorial para regresión.



METODOLOGÍA

6. Metodología propuesta




Síntesis de la metodología para la evaluación de estabilidad de tensión

6.1. Áreas de control de tensión (VCAs).

La reserva base de potencia reactiva de un nodo de carga: se define como el conjunto de generadores que alcanzan su **límite Qmax**, en el camino hacia el mínimo de la curva V-Q.

Los nodos PQ, generadores y las líneas que unen todos los nodos conforman un área de control de tensión (Schlueter, 1998).



En las áreas de control de tensión se identifican los nodos del sistema **propensos a la inestabilidad de tensión**

12

6.2. Entrenamiento de IA

Sistemas de inteligencia Artificial




Fig. 8 Regresor de soporte vectorial, ϵ -RSV

$$\min: \frac{1}{2} w^T w + C \sum_{i=1}^l \xi_i + C \sum_{i=1}^l \xi_i^*$$

$$\text{sa: } w^T \phi(x_i) + b - z_i \leq \epsilon + \xi_i,$$

$$z_i - \phi(x_i) - b \leq \epsilon + \xi_i^*,$$

$$\xi_i, \xi_i^* \geq 0, i = 1, \dots, l.$$

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




Fig. 9 Máquina de Aprendizaje Extremo, MAE




Fig. 10 Máquina de Aprendizaje Extremo con kernel, KMAE 13

6.3. Entrenamiento de IA



Identificación de parámetros de las IA





Fig. 11 Desempeño de la MSV en función de los parámetros (Huang G. 2012) .

Se propone proceso de optimización para identificar los parámetros (MVMO, Erlich, 2018).

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


$$\text{sa: } x_{\min} \leq x \leq x_{\max}$$

t es el vector de salidas deseadas
 y es el vector de predicción



Identificación de parámetros de la IA basada en MVMO

6.4. Monitoreo de líneas de interconexión entre VCAs.



Monitorea el estrés de las líneas que unen diferentes VCAs. La estimación del estrés se realiza a través de la diferencia angular de una línea equivalente del área cutset (Dobson, 2010).

$$P_c = \sum_{j \in c} b_j \hat{\theta}_j \quad b_c = \sum_{j \in c} b_j$$

b_j es susceptancia de la línea j , $\hat{\theta}_j$ es la diferencia angular a través de la línea j

Con una IA se vigila inestabilidad por incapacidad de transmisión

RESULTADOS

7. Resultados en sistema de prueba de 39 nodos

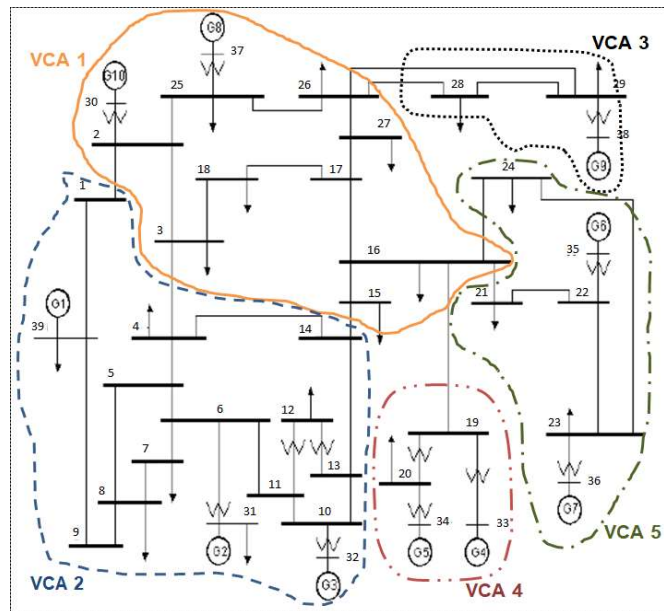


Fig. 12 Configuración más típica de VCAs encontrada.



7. Resultados

Monitoreo de VCAs:

IA-Regresor	Parámetros identificados	
	$\log_2 C$	$\log_2 \gamma$
KMAE-VCA1	8.1261	-10.6538
KMAE-VCA2	7.3046	-11.5275
KMAE-VCA3	7.3953	-14.9654
KMAE-VCA4	6.7071	-13.2399
KMAE-VCA5	3.3570	-15.000

Parámetros óptimos identificados para cada VCA




Fig. 13 Convergencia del MVMO en la identificación de parámetros óptimos para cada KMAE

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

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

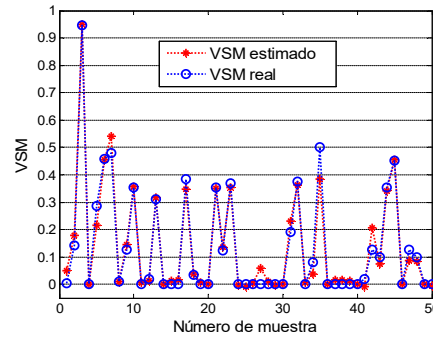


Fig. 14 Comparación entre los valores reales y estimados del VSM para la VCA2.

17

7. Resultados

Método de monitoreo de líneas de interconexión entre VCAs

Área cutset	VCA frontera	Líneas cutset	Susceptancia (p.u.)
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

Líneas de las áreas cutset obtenidas para el sistema de prueba.

IA-Regresor	Parámetros identificados	
	$\log_2 C$	$\log_2 \gamma$
KMAE-AC1	13.4764	-5.7845
KMAE-AC2	13.9343	-7.4093
KMAE-AC3	14.7865	-8.6979
KMAE-AC4	14.7291	-6.7085

Parámetros óptimos identificados para cada AC

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

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

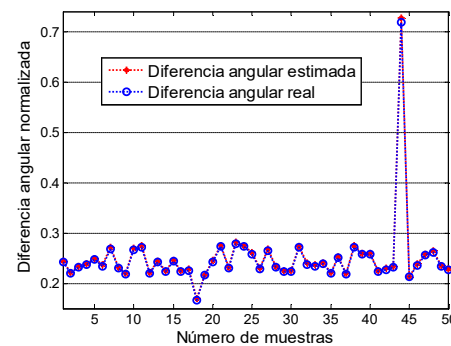


Fig. 15 Comparación entre los valores reales y estimados de la diferencia angular cutset para AC4.

18



CONCLUSIONES

8. Conclusiones y trabajos futuros



- **La metodología planteada de evaluación en tiempo real de la estabilidad de tensión permite monitorear los dos mecanismos de inestabilidad de tensión.**
- La delimitación de las VCAs garantiza el monitoreo de los nodos débiles, y se identifican a priori las fuentes de generación que influyen directamente sobre estos nodos (*reserva de potencia reactiva*).
- Para la evaluación de la estabilidad se debe garantizar que la información de los parámetros de las líneas sea confiable (**validación de los parámetros de las líneas**).
- Para la metodología desarrollada se propone realizar pruebas en un sistemas de mayor numero de nodos usando un simulador en tiempo real.
- **Implementar la metodología propuesta al monitoreo de la estabilidad de tensión de corto alcance.**

9. Referencias

- 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\(91\)90025-1](https://doi.org/10.1016/0378-7796(91)90025-1)
- 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>

¡Gracias por su atención!





Contacto

Docente Walter villa:
walter.villa@udea.edu.co

Correo electrónico:
grupogimel@udea.edu.co

**Grupo de Manejo
Eficiente de la Energía**

Dirección: Calle 62 Número 52 -59
Sede de Investigación Universitaria (Universidad de Antioquia)
Torre 2 Laboratorio 228
Teléfono: (57-4) 219 6445
Medellín, Colombia

<http://www.udea.edu.co/wps/portal/udea/web/inicio/investigacion/grupos-investigacion/ingenieria-tecnologia/gimel/>