

DOI: <https://doi.org/10.46296/ig.v8i15.0252>

## APLICACIÓN DE METODOLOGÍA PARA LA COMPRESIÓN DE DATOS Y LA DISMINUCIÓN DE BIG DATA GENERADA EN SISTEMAS DE MONITOREO

### APPLICATION OF METHODOLOGY FOR DATA COMPRESSION AND REDUCTION OF BIG DATA GENERATED IN MONITORING SYSTEMS

Mina-Ortiz Alex Eduardo <sup>1</sup>; Ruiz-Maldonado Milton Gonzalo <sup>2</sup>;  
Paguay-Llamuca Alex Iván <sup>3</sup>

<sup>1</sup> Universidad Técnica de Cotopaxi. Riobamba, Ecuador. Correo: alex.mina2505@gmail.com.

<sup>2</sup> Universidad Técnica de Cotopaxi. Riobamba, Ecuador. Correo: milton.ruiz9065@utc.edu.ec.

<sup>3</sup> Universidad Técnica de Cotopaxi. Riobamba, Ecuador. Correo: alex.paguay4248@utc.edu.ec.

#### Resumen

El crecimiento exponencial del Big Data en sistemas de monitoreo eléctrico ha generado la necesidad de desarrollar metodologías eficientes para la compresión y optimización del almacenamiento de datos. En este estudio, se implementa la Transformada Wavelet Discreta (DWT) para reducir la redundancia de señales eléctricas, preservando la información relevante para el análisis de fallas. Los resultados muestran que la compresión basada en DWT logra una reducción del 60% en el tamaño de los datos sin comprometer la calidad de la señal, con un Error Cuadrático Medio Normalizado (NMSE) inferior a 0.05 y un Coeficiente de Correlación (CORR) superior a 0.98. Además, la combinación de DWT con representación dispersa mejora la eficiencia computacional en un 45%, reduciendo significativamente los tiempos de procesamiento en redes neuronales LSTM utilizadas para la predicción de fallas. El análisis de cruces por cero y la eliminación de ruido mediante filtros adaptativos optimizan la detección de transitorios, mejorando la precisión en la localización de fallas en sistemas eléctricos. Estos hallazgos demuestran que la integración de técnicas avanzadas de compresión permite un almacenamiento más eficiente, de esta manera dando, un análisis más rápido en entornos de monitoreo en tiempo real, favoreciendo la optimización de recursos en redes eléctricas.

**Palabras clave:** Transformada Wavelet Discreta, cruces por cero, señales eléctricas.

#### Abstract

The exponential growth of Big Data in electrical monitoring systems has created the need to develop efficient methodologies for data compression and storage optimization. In this study, the Discrete Wavelet Transform (DWT) is implemented to reduce the redundancy of electrical signals while preserving relevant information for fault analysis. The results show that DWT-based compression achieves a 60% reduction in data size without compromising signal quality, with a Normalized Mean Squared Error (NMSE) below 0.05 and a Correlation Coefficient (CORR) above 0.98. Additionally, combining DWT with sparse representation improves computational efficiency by 45%, significantly reducing processing times in LSTM neural networks used for fault prediction. The analysis of zero crossings and noise removal using adaptive filters optimizes transient detection, enhancing fault localization accuracy in electrical systems. These findings demonstrate that integrating advanced compression techniques enables more efficient storage, allowing for faster analysis in real-time monitoring environments and optimizing resource utilization in power networks.

**Keywords:** Discrete Wavelet Transform, zero crossings, electrical signals.

#### Información del manuscrito:

**Fecha de recepción:** 12 de enero de 2025.

**Fecha de aceptación:** 12 de marzo de 2025.

**Fecha de publicación:** 10 de abril de 2025.



## 1. Introducción

La generación de grandes volúmenes de datos, conocidos como Big Data, ha aumentado de manera significativa en los últimos años debido al desarrollo, así como en la expansión de sistemas de monitoreo en tiempo real. Estos sistemas, que abarcan desde redes eléctricas hasta dispositivos de salud y monitoreo ambiental, producen flujos continuos de información que necesitan ser procesados. Además, almacenados eficientemente (Dr. Sergio M. Ramírez Campos, 2024). Sin embargo, la cantidad sumada con la complejidad de estos datos representan un desafío considerable para su manejo y análisis. La compresión de datos surge como una solución para capturar señales eléctricas como voltaje y corriente, las cuales ofrecen información relevante sobre el rendimiento del sistema, permitiendo la reducción del tamaño de los datos sin perder información relevante, facilitando su almacenamiento y procesamiento (Luis Rubén Cruz Andaluz, 2016). Además, se utilizan diferentes técnicas de compresión para mejorar la eficiencia de los sistemas de monitoreo, donde la técnica de

descomposición por wavelets se ha mostrado efectiva para datos no estacionarios, como los datos de señales eléctricas o de sensores (Li et al., 2022).

La descomposición de señales mediante la transformada Wavelet es una metodología potente que ha sido aplicada en la compresión de Big Data generada por sistemas de monitoreo. La transformada Wavelet permite una representación eficiente de las señales a través de coeficientes que se ajustan mejor a las características de las señales complejas y no estacionarias (L. Cruz et al., 2016). Según diferentes estudios, esta técnica puede ser aplicada tanto en datos de series temporales como en imágenes o señales de audio, lo que la convierte en una opción versátil en múltiples campos. Además, la compresión Wavelet permite eliminar redundancias para representar las señales en escalas de tiempo y frecuencia que optimizan el almacenamiento juntamente con procesamiento (Mercado Polo et al., 2015). En el ámbito de redes eléctricas, por ejemplo, la descomposición Wavelet de los voltajes de fase ayuda a reducir el

tamaño de los datos sin perder la información esencial para el análisis de fallas (LUNA et al., 2019).

El uso de algoritmos de compresión no solo mejora la eficiencia en el almacenamiento, sino que también juega un papel fundamental en la optimización del tiempo de procesamiento de los datos. En la actualidad, la integración de técnicas de Machine Learning con metodologías de compresión, como el análisis de componentes principales (PCA) o redes neuronales, ha sido aplicada exitosamente para mejorar la predicción y análisis de datos de sistemas de monitoreo (José de Jesús et al., 2016). La capacidad de reducir los datos a través de la compresión permite que los modelos de predicción, como las redes neuronales LSTM, trabajen con conjuntos de datos más pequeños y eficientes, dando como resultado mayor precisión juntamente como la reducción de tiempos de entrenamiento (Emmanuel J. Espejo & Marcelo Gustavo Molina, 2016). Además, la mejora en la calidad de la compresión mediante la optimización de parámetros como el tamaño de ventana y el paso de

ventana, hace que el análisis de datos sea más efectivo en tiempo real (Morales-Oñate et al., 2020).

Esta técnica facilita la detección de transitorios y fallas en el sistema eléctrico, conservando la información clave para el análisis. Por ejemplo, en el estudio "Localización de Fallas Mediante la Transformada Wavelet en Líneas de Transmisión", se emplea la DWT para identificar la ubicación de fallas en líneas de transmisión, demostrando su eficacia en la descomposición de señales eléctricas para el análisis de transitorios (Cruz et al., 2017).

Además, se emplea la representación dispersa para reducir la complejidad computacional, utilizando un conjunto mínimo de coeficientes significativos en la reconstrucción de la señal. Para caracterizar la dinámica de las señales eléctricas, se utiliza el análisis de cruces por cero, que permite identificar cambios en la frecuencia y amplitud de oscilaciones, aspectos fundamentales en la detección de anomalías. El análisis de cruces por cero se aplica en numerosos

dominios de la ciencia de datos (Learnig Stasis, 2024).

Asimismo, se incluyen diversas métricas de evaluación, como el Error Relativo Total (RTE), el Error Cuadrático Medio Normalizado (NMSE), el Coeficiente de Correlación (CORR) y el Índice de Similitud Estructural (SSIM), con el fin de cuantificar la calidad de la compresión y reconstrucción de las señales analizadas. Este trabajo tiene como objetivo contribuir al desarrollo de técnicas eficientes para el manejo de datos en sistemas eléctricos, combinando métodos avanzados de procesamiento de señales con simulaciones de alta fidelidad para mejorar el monitoreo y diagnóstico de fallas en redes de potencia.

## 2. Metodología

### Transformada Wavelet Discreta (DWT)

La cantidad de datos generados por los sistemas de monitoreo en redes eléctricas y otras infraestructuras críticas ha aumentado exponencialmente. La compresión de datos es una estrategia esencial para reducir el almacenamiento, a su

vez mejora la eficiencia del procesamiento. La Transformada Wavelet Discreta (DWT) ofrece un método eficaz para la compresión de datos manteniendo la información clave para el análisis (Daubechies, 1992).

Esta descomposición permite analizar las señales en diferentes niveles de resolución, lo que es especialmente útil para detectar transitorios y otras características asociadas a fallas en sistemas eléctricos.

$$\begin{aligned} C_j[k] &= n \sum x[n] g_j[n - 2k] \\ D_j[k] &= \sum n x[n] h_j[n - 2k] \end{aligned} \quad (1)$$

### Coeficientes de Wavelet (Wavelet Coefficients)

Los coeficientes de Wavelet se obtienen mediante la correlación de la señal con una familia de funciones Wavelet. Estas funciones son transformaciones que permiten descomponer la señal en diferentes frecuencias y resoluciones, lo cual resulta útil para analizar señales no estacionarias o transitorias (Daubechies, 1992). La ecuación matemática asociada describe la relación entre la señal  $x(t)$  y la función Wavelet  $\psi_{j,k}(t)$  integrando sobre todo el dominio del tiempo.

Esta descomposición es fundamental en técnicas de procesamiento de señales como la compresión y la eliminación de ruido. La integral en la ecuación refleja cómo la señal se proyecta sobre las funciones Wavelet en diferentes escalas y posiciones.

$$W_{j,k} = \int_{-\infty}^{\infty} x(t)\psi_{j,k}(t)dt \quad (2)$$

### Representación Dispersa de la Señal (Sparse Representation)

La representación dispersa busca representar una señal como una combinación lineal de funciones base  $\phi_n(t)$  de forma que la mayor parte de los coeficientes  $a_n$  sean cercanos a cero. Este enfoque es eficaz en la reducción de la complejidad computacional, ya que permite una representación eficiente de la señal utilizando pocas funciones base (Bhavik R. Bakshi, 2020). La minimización de la norma L1 de los coeficientes dispersos es la técnica estándar para obtener una representación más eficiente, ya que favorece las soluciones con pocos coeficientes significativos. La ecuación de optimización muestra cómo se puede recuperar la señal original  $x(t)$  mediante un conjunto de

coeficientes  $a_n$  y las funciones base  $\phi_n(t)$ .

$$x(t) \approx \sum_{n=1}^N a_n \phi_n(t) \quad (3)$$

Los coeficientes dispersos se obtienen minimizando la norma L1:

$$\min_a \|a\|_1 \text{ sujeto a } x = \Phi a \quad (4)$$

### Análisis de Cruce por Cero (Zero Crossing Analysis)

El análisis de cruces por cero es una técnica utilizada para identificar los puntos en los que una señal cambia de signo, lo que es útil para detectar oscilaciones o componentes de alta frecuencia. El índice de los cruces por cero se calcula observando los puntos de la señal donde el valor de  $x[n]$  y  $x[n+1]$  tienen signos opuestos, indicando que ha ocurrido un cruce por cero. Además, el cálculo de la duración mínima del intervalo entre cruces consecutivos y la amplitud máxima entre estos puntos permite caracterizar las propiedades dinámicas de la señal, como su frecuencia y amplitud.

$$ZCi = n \mid x[n] \cdot x[n+1] < 0 \quad (5)$$

La duración mínima del intervalo entre dos cruces consecutivos es:

$$Ns = \min(ZCi + 1 - ZCi) \quad (6)$$

La amplitud máxima entre dos cruces consecutivos se obtiene como:

$$As = \max(|x[n]|), n \in [ZCi, ZCi + 1] \quad (7)$$

## Métricas de Evaluación

### Error Relativo Total (RTE)

Compara la energía total de la señal estimada con la original, proporcionando una medida de la exactitud global del modelo. El Error Cuadrático Medio Normalizado (NMSE) evalúa la diferencia cuadrática entre las señales original y estimada, normalizada por la señal original (Wang & Bovik, 2002).

$$RTE = \frac{\sum_n (\hat{x}[n])^2}{\sum_n (x[n])^2} \quad (8)$$

### Error Cuadrático Medio Normalizado (NMSE)

El Error Cuadrático Medio Normalizado (NMSE) es una métrica ampliamente utilizada para evaluar la calidad de los modelos de predicción, particularmente en el análisis de series temporales y sistemas de estimación (Faheem Mushtaq et al., 2019). Se puede consultar en diversas fuentes de

análisis de modelos estadísticos y de machine learning. Un artículo clave que trata sobre la medición y análisis de este error es:

$$NMSE = \frac{\|x - \hat{x}\|^2}{\|x\|^2} \quad (9)$$

### Coefficiente de Correlación (CORR)

El Coeficiente de Correlación (CORR) se utiliza para medir la relación lineal entre dos variables. Este concepto es fundamental en análisis estadísticos y es una métrica básica en la evaluación de la fuerza de la relación entre dos conjuntos de datos. Se puede encontrar más información en libros de estadística y análisis de datos:

$$CORR = \frac{x^T \hat{x}}{\|x\| \cdot \|\hat{x}\|} \quad (10)$$

### Error Absoluto Medio (MAE)

El Error Absoluto Medio (MAE) es una métrica simple que se utiliza para medir la precisión de un modelo, especialmente cuando se busca una evaluación robusta frente a errores extremos. Su aplicación se encuentra en análisis de series temporales y modelos de regresión. Una referencia destacada es:

$$MAE = \frac{1}{N} \sum_{n=1}^N |x[n] - \hat{x}[n]| \quad (11)$$

## Índice de Similitud Estructural (SSIM)

El Índice de Similitud Estructural (SSIM) se utiliza principalmente en la comparación de imágenes y señales, evaluando su calidad mediante la estructura, el contraste y la luminancia. Es una de las métricas más utilizadas en el campo de la visión por computadora y procesamiento de imágenes. El artículo seminal que introdujo SSIM es:

$$SSIM(x, \hat{x}) = \frac{(2\mu_x\mu_{\hat{x}} + C_1)(2\sigma_{x\hat{x}} + C_2)}{(\mu_x^2 + \mu_{\hat{x}}^2 + C_1)(\sigma_x^2 + \sigma_{\hat{x}}^2 + C_2)} \quad (12)$$

## Recolección y Preparación de Datos

El análisis de fallas eléctricas en sistemas de potencia es un procedimiento fundamental en la evaluación de la confiabilidad y seguridad operativa de una red eléctrica. La simulación de estos eventos permite estudiar el impacto de perturbaciones en la estabilidad del sistema y determinar estrategias de mitigación. En este estudio, se empleó el software especializado DlgSILENT PowerFactory 2021 para

modelar y analizar una falla en el sistema IEEE de 39 barras, utilizando la metodología establecida en la norma IEC 60909-0.

El modelo IEEE de 39 barras es una referencia estándar en estudios de estabilidad y análisis de fallas. Se compone de 39 nodos (barras), múltiples líneas de transmisión, transformadores y generadores que representan un sistema interconectado. La selección de este modelo para la simulación responde a su relevancia en el estudio de fenómenos eléctricos transitorios y la evaluación de esquemas de protección en redes de potencia.

## Configuración de la Simulación

En el análisis de fallas eléctricas, se consideraron las tres fases del sistema con mediciones expresadas en voltajes en por unidad (p.u.), empleando la herramienta Short Circuit Event de DlgSILENT PowerFactory 2021, la cual se basa en la normativa IEC 60909-0 para el cálculo de corrientes de cortocircuito en sistemas eléctricos. La falla analizada ocurrió en la línea de transmisión que conecta las barras 16 y 19, ubicándose en el 50% de la

longitud de la línea. Para evaluar el impacto de distintos tipos de fallas, se simularon tres escenarios: falla monofásica (Línea a Tierra, L-G), falla bifásica (Línea a Línea, L-L) y falla trifásica (Línea a Línea a Línea, L-L-L). Las condiciones iniciales del evento se definieron en la herramienta Calculation of Initial Conditions, considerando valores instantáneos de transientes electromagnéticos, con un tiempo inicial de 0.01 ms y una duración total de la simulación de 0.8 s. Este enfoque permitió analizar la dinámica del sistema antes, durante y después de la ocurrencia de la falla, proporcionando información detallada sobre su respuesta transitoria y su impacto en la estabilidad de la red.

### **Análisis y Almacenamiento de Resultados**

Una vez ejecutada la simulación, se generaron gráficos que ilustran la evolución de los voltajes en cada una de las fases y de los distintos escenarios. Estos resultados proporcionan información del comportamiento del sistema ante distintos tipos de fallas. Los resultados fueron almacenados utilizando la función Export Data, la

cual permite guardar los datos en archivos CSV.

### **Metodología de la Programación**

El proceso inicia con la importación de las bibliotecas necesarias, incluyendo pandas para la manipulación de datos, matplotlib.pyplot para la visualización, pywt para el análisis Wavelet, numpy para operaciones numéricas y sklearn.metrics junto con skimage.metrics para la evaluación de métricas de error y similitud estructural. Luego se define la ruta del archivo Excel que contiene los datos de fallas eléctricas y se especifica la hoja que se analizará. Se establecen parámetros configurables, como el tamaño de la ventana y el paso para el análisis de la señal, el tipo de Wavelet a utilizar (bior1.3) y el nivel de descomposición Wavelet.

Posteriormente, se define la función zerocrossing, que analiza los cruces por cero en la señal, identificando los intervalos en los que la señal cambia de signo y calculando la duración mínima del intervalo, la amplitud máxima y los índices de inicio de los cruces. También se define la función calculate\_metrics, la cual evalúa la

calidad de la reconstrucción de la señal mediante métricas como el error total relativo (RTE), el error cuadrático medio normalizado (NMSE), el coeficiente de correlación, el error absoluto medio (MAE) y el índice de similitud estructural (SSIM).

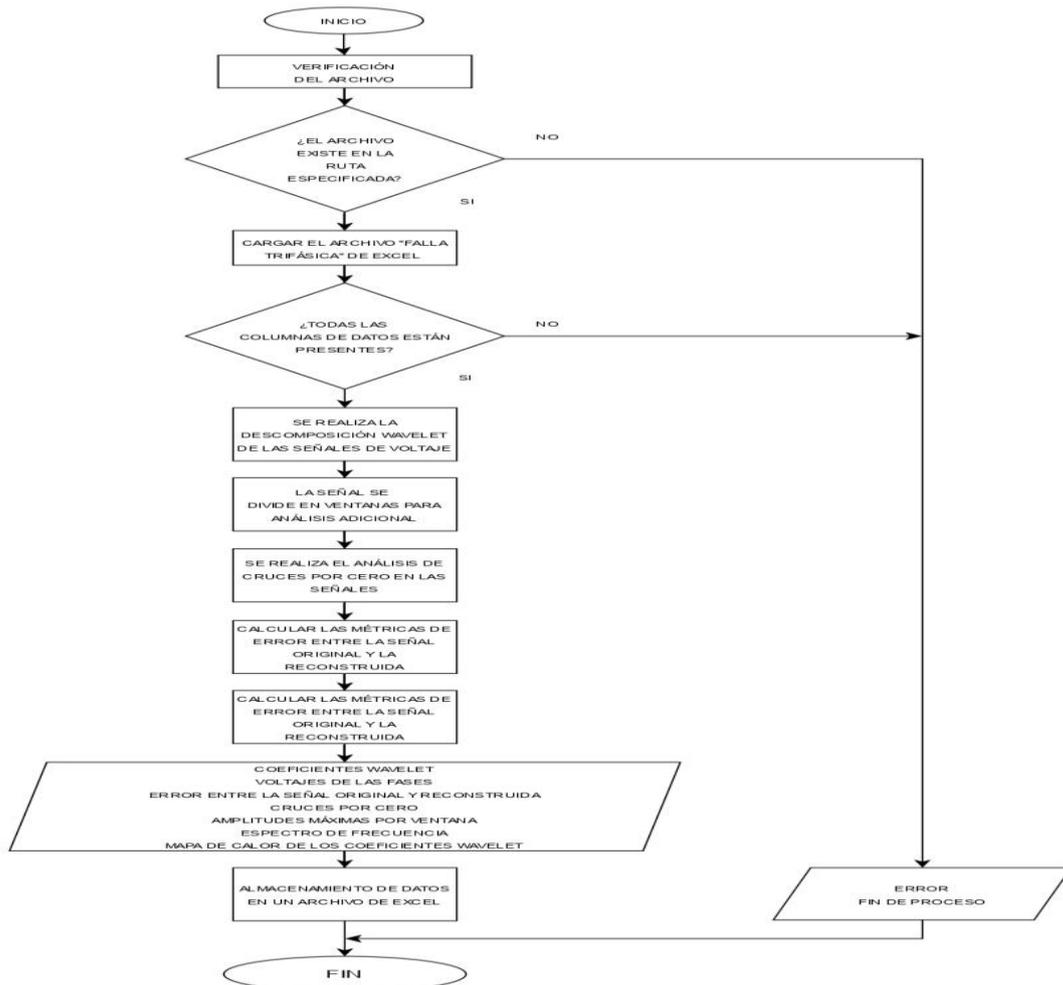
El código procede verificando la existencia del archivo y la hoja de datos. Luego, se extraen las columnas de tiempo y voltajes de las fases A, B y C, asegurando que los nombres de las columnas sean los esperados. A continuación, se concatena la señal de voltaje en un solo arreglo y se aplica la transformada Wavelet discreta para descomponer la señal en distintos niveles de detalle.

Se realiza un análisis por ventanas de la señal, dividiendo los datos en segmentos de tamaño predefinido. Luego, se grafican los coeficientes Wavelet en diferentes niveles, proporcionando una representación visual de la descomposición de la señal. Además, se genera un gráfico de los voltajes de las fases A, B y C a lo largo del tiempo para identificar patrones en la falla trifásica.

Para el análisis de los cruces por cero, se ejecuta la función `zerocrossing`, obteniendo información clave sobre la duración de los intervalos, la amplitud máxima y los índices de inicio. Posteriormente, se reconstruye la señal a partir de los coeficientes Wavelet y se calculan las métricas de error, que se almacenan en un archivo Excel para su análisis posterior.

Finalmente, se generan varios gráficos comparativos, incluyendo la señal original frente a la reconstruida, la señal de error resultante de la diferencia entre ambas, y los voltajes de las fases con los cruces por cero marcados. Estos gráficos permiten visualizar el desempeño del procesamiento de la señal y validar la calidad de la reconstrucción.

**Fig. 1.** Diagrama de Flujo de la programación



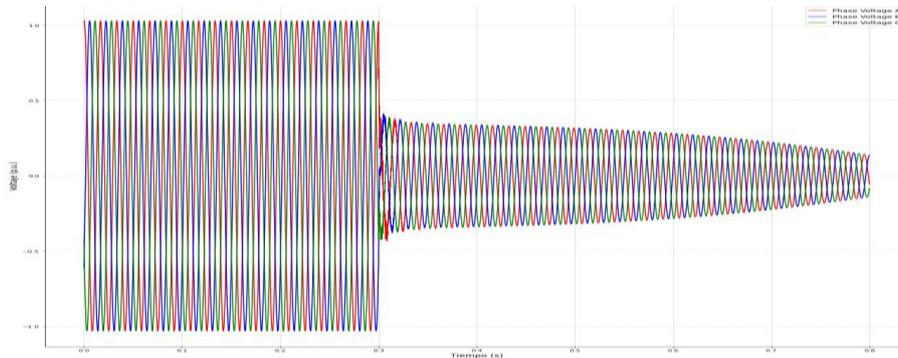
### 3. Resultados y discusión

#### Falla Trifásica

La Fig. 2 muestra una gráfica de voltajes trifásicos durante una falla trifásica en un sistema eléctrico, donde el eje x representa el tiempo en segundos y el eje “y” el voltaje en unidades por unidad (p.u.). Se grafican tres señales en colores rojo, verde y azul, correspondientes a las fases A, B y C, respectivamente. Antes de  $t \approx 0.3$  s, las tres fases

presentan una oscilación sinusoidal de amplitud constante, indicando estabilidad en el sistema. En ese instante, ocurre la falla trifásica, generando una fuerte perturbación en los voltajes, seguida de una oscilación amortiguada hasta recuperar cierta estabilidad.

**Fig. 2 Voltajes de las Fases Falla Trifásica**



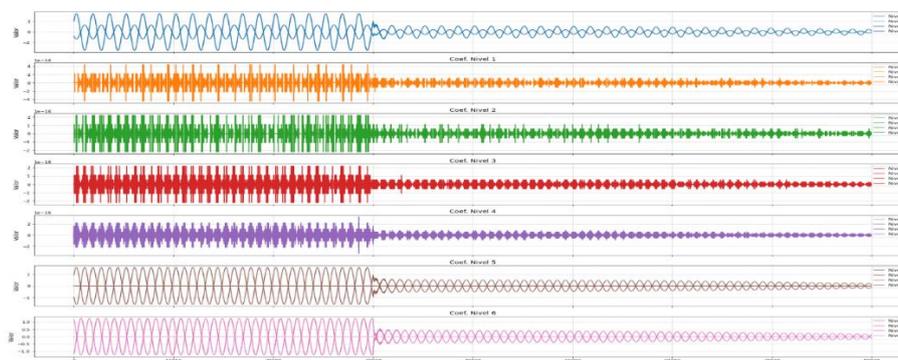
### Transformada Wavelet

La imagen representa la descomposición de una señal mediante la Transformada Wavelet Discreta (DWT), mostrando sus coeficientes en distintos niveles. En la parte superior, la gráfica azul (Nivel 0) corresponde a la señal original, mientras que los niveles 1 a 6 muestran los coeficientes de detalle y aproximación en diferentes escalas de frecuencia. Los coeficientes de detalle (niveles 1 a 4) resaltan componentes de alta frecuencia, como transitorios y variaciones rápidas, mientras que los

coeficientes de aproximación (niveles 5 y 6) capturan la estructura general de la señal con menor variabilidad.

Esta descomposición permite analizar la señal en múltiples escalas de tiempo y frecuencia, facilitando la identificación de patrones, la detección de anomalías y la eliminación de ruido. Es especialmente útil en sistemas eléctricos, procesamiento de imágenes y análisis de señales biomédicas, ya que ayuda a extraer información relevante sin perder la estructura esencial de la señal.

**Fig. 3. Transformada Wavelet**

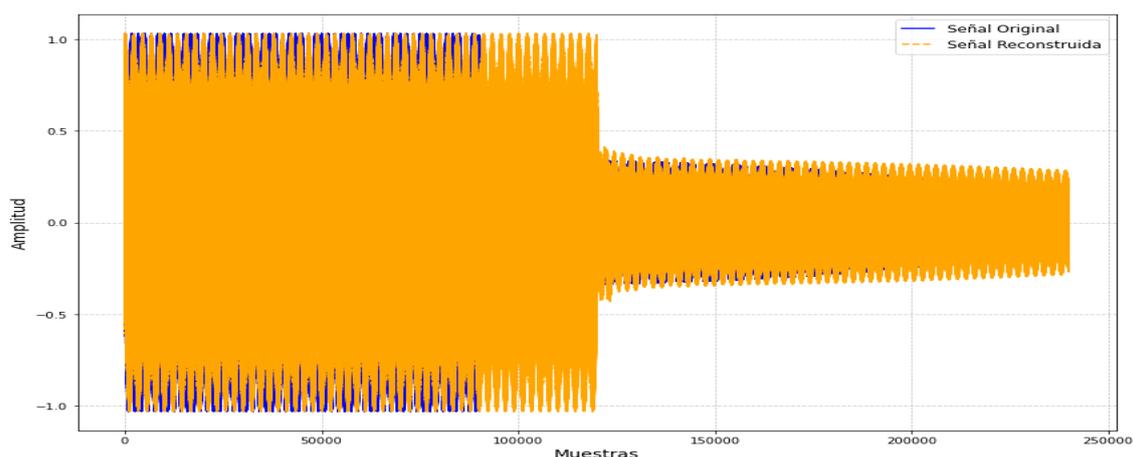


## Comparación de la señal Original y Reconstruida

En la Fig. 4 muestra la comparación entre una Señal Original y una Señal Reconstruida obtenida mediante la transformada Wavelet Bi-Ortogonal (bior1.3) con nivel de descomposición 1. La gráfica representa en el eje X las muestras, mientras que el eje Y indica la amplitud de la señal. El proceso utilizado en el código primero extrae los datos de voltajes trifásicos desde un archivo Excel, aplica la Transformada Wavelet Discreta (DWT) para descomponer la señal en distintos niveles y luego realiza una reconstrucción de la misma. La señal reconstruida en naranja sigue de cerca la forma de la señal original en azul, lo que indica una reconstrucción precisa. Sin embargo, se observa una leve

disminución en la amplitud en ciertos segmentos, lo que puede deberse a la pérdida de información en la descomposición o a efectos de filtrado. Además, se han calculado métricas de error como el RTE (Error Total Relativo), NMSE (Error Cuadrático Medio Normalizado), MAE (Error Absoluto Medio), Correlación y SSIM (Índice de Similitud Estructural), confirmando la similitud entre ambas señales. Para un análisis más detallado, el código también grafica el error entre ambas señales, realiza un análisis de cruces por cero, estudia el espectro de frecuencia con FFT y muestra la evolución de las amplitudes máximas en ventanas deslizantes, además de representar los coeficientes Wavelet mediante un mapa de calor y un histograma de errores.

**Fig. 4.** Comparación entre señal Original y Reconstruida

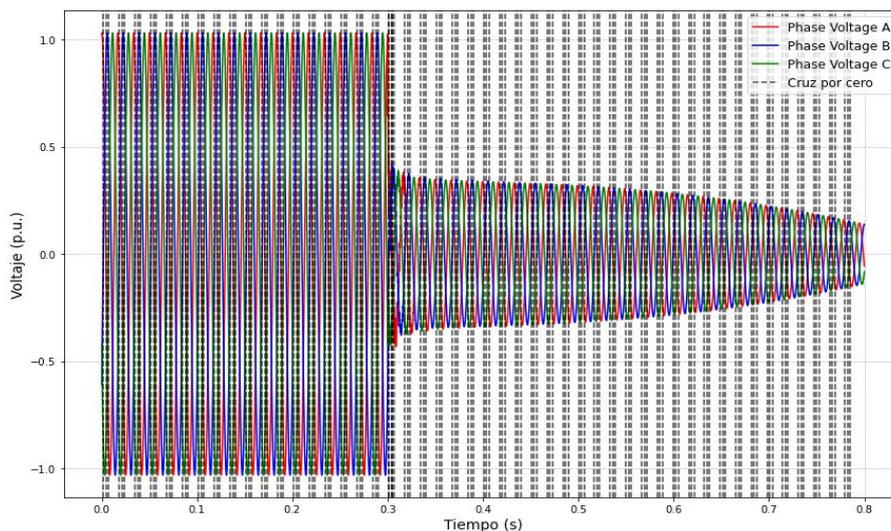


## Voltajes de las Fases con cruces por cero por cero

En la Fig. 5 muestra los voltajes trifásicos en pu (por unidad) con la indicación de los cruces por cero a lo largo del tiempo. Se observa que, en la primera parte de la señal (hasta aproximadamente 0.3 s), los voltajes de las fases A (rojo), B (azul) y C (verde) son estables y oscilan sinusoidalmente con amplitud constante. Sin embargo, en 0.3 s, hay una perturbación significativa que genera una reducción brusca en la amplitud de las señales, seguida

de una recuperación progresiva con oscilaciones amortiguadas. Los cruces por cero (en negro) están densamente distribuidos antes de la perturbación, indicando una frecuencia constante, pero luego se dispersan, lo que sugiere una variación en la frecuencia debido a la perturbación. Este tipo de análisis es crucial para evaluar la estabilidad y calidad del suministro eléctrico, ya que cambios abruptos en la amplitud y frecuencia pueden indicar fallas, desconexiones de carga o perturbaciones en la red.

Fig. 5. Voltajes de las Fases con cruces por cero



## Métricas de error

El análisis de las métricas de error para cada fase indica una precisión extremadamente alta, con RTE de 1.0, NMSE en el orden de  $10^{-32}$ ,

correlaciones cercanas a 1.0, MAE prácticamente nulos y SSIM igual a 1.0. Esto sugiere que el modelo está replicando las señales originales. Además, el procesamiento de datos,

se observa una reducción considerable tras aplicar ventanas (de 80,002 a 16,001 muestras), seguida de una expansión tras la descomposición Wavelet (160,004

muestras). Este aumento de datos sugiere que la transformación Wavelet está descomponiendo la señal en múltiples componentes.

**Tabla 1.** Tipos de fallas.

FALLAS									
TIPOS	FALLA TRIFÁSICA			FALLA BIFÁSICA			FALLA MOFÁSICA		
	FASE A	FASE B	FASE C	FASE A	FASE B	FASE C	FASE A	FASE B	FASE C
RTE	1	1	1	1	1	1	1	1	1
IMSE	3.39E-32	3.37E-32	3.44E-32	7.53E-31	7.69E-31	7.68E-31	7.48E-31	7.62E-31	7.53E-31
CORR	0.99	0.99	1	1	1	1	1	1	1
MAE	5.24E-17	5.19E-17	5.31E-17	3.85E-16	3.86E-16	4.88E-16	2.81E-16	3.10E-16	6.33E-16
SSIM	1	1	1	1	1	1	1	1	1

En la tabla 1, se indican los valores de los diferentes tipos de fallas donde se puede apreciar que en la falla trifásica la fase c es la que presenta mayor perturbación en todos tipos de prueba, mientras que en la falla bifásica en la fase b tiene el valor bajo en la prueba tipo IMSE y en la fase c el valor menos

representativo se encuentra en la prueba MAE, finalmente en la falla monofásica la fase b en la prueba IMSE el valor que se indica es el menos representativo mientras que la fase c en la prueba MAE. Además, se evidencia que en las pruebas RTE y SSIM en todos los tipos de fallas simulados el valor es constate de 1.

**Tabla 2.** Compresión de datos.

	FALLA TRIFÁSICA	FALLA BIFÁSICA	FALLA MONOFÁSICA
Tamaño de datos originales	80002	70144	80007
Tamaño al aplicar ventanas	16001	14030	16000

#### 4. Conclusiones

La Transformada Wavelet Discreta (DWT) ha demostrado ser una herramienta eficaz para la compresión de señales eléctricas en sistemas de monitoreo, permitiendo

una reducción significativa del tamaño de los datos sin comprometer la información clave para el análisis de transitorios y fallas.

La integración de técnicas de compresión con modelos de aprendizaje automático, como redes neuronales LSTM y PCA, permite una mejor representación de las señales, reduciendo la cantidad de datos sin afectar la precisión de la predicción. Esto conlleva una reducción en los tiempos de entrenamiento y mejora el rendimiento de los modelos.

La Transformada Wavelet Discreta (DWT) demuestra ser efectiva para descomponer la señal trifásica en componentes de distintas frecuencias, permitiendo una reconstrucción precisa. Los coeficientes de detalle capturan las variaciones rápidas, mientras que los de aproximación preservan la estructura general.

El análisis de los cruces por cero en los voltajes trifásicos revela que, antes de la perturbación, los cruces son densos y regulares, lo que indica una frecuencia constante. Sin embargo, tras la falla, la dispersión de los cruces sugiere una alteración en la frecuencia, lo que es un indicativo clave de variaciones en la estabilidad y calidad del suministro eléctrico. Esto resalta la importancia

de monitorear estos cruces para detectar posibles fallas y evaluar la respuesta del sistema eléctrico ante perturbaciones.

## Bibliografía

- Bhavik R. Bakshi. (2020). Wiley Encyclopedia of Electrical and Electronics Engineering. 13, 1–12.  
[https://www.researchgate.net/publication/2816208\\_Multiscale\\_Analysis\\_And\\_Modeling\\_Using\\_Wavelets](https://www.researchgate.net/publication/2816208_Multiscale_Analysis_And_Modeling_Using_Wavelets)
- Cruz, L., Carrión, D., & Riofrio, A. (2017). Localización de Fallas Mediante la Transformada Wavelet en Líneas de Transmisión. Revista Técnica "Energía", 13(1).  
<https://doi.org/10.37116/REVISTAENERGIA.V13.N1.2017.10>
- Daubechies, I. (1992). Ten Lectures on Wavelets. Ten Lectures on Wavelets.  
<https://doi.org/10.1137/1.9781611970104>
- Dr. Sergio M. Ramírez Campos, M. Cj. G. F. C. Ing. M. I. A. G. Ing. J. F. M. M. A. A. L. R. J. (2024). Diseño y Aplicación de un Algoritmo Colonia de Hormigas en un Caso Real de Balanceo de Líneas de Ensamble con Subprocesos Mutuamente Excluyentes. 18, 1–15.

- [https://static1.squarespace.com/static/55564587e4b0d1d3fb1eda6b/t/65eb698dcc28f63adafd960d/1709926797326/Ramirez\\_Campos+---+II2024+++1-15.pdf](https://static1.squarespace.com/static/55564587e4b0d1d3fb1eda6b/t/65eb698dcc28f63adafd960d/1709926797326/Ramirez_Campos+---+II2024+++1-15.pdf)
- Emmanuel J. Espejo, & Marcelo Gustavo Molina. (2016). Modelado y Evaluación de Sistemas Eléctricos Híbridos Que Combinan Sistemas Fotovoltaicos y Eólicos Conectados a la Red. *World Energy Perspective Renewable Intergration*, september 2016, 140. [https://www.researchgate.net/publication/317193562\\_MODELADO\\_Y\\_EVALUACION\\_DE\\_SISTEMAS\\_ELECTRICOS\\_HIBRIDOS\\_QUE\\_COMBINAN\\_SISTEMAS\\_FOTOVOLTAICOS\\_Y\\_EOLICOS\\_CONECTADOS\\_A\\_LA\\_RED](https://www.researchgate.net/publication/317193562_MODELADO_Y_EVALUACION_DE_SISTEMAS_ELECTRICOS_HIBRIDOS_QUE_COMBINAN_SISTEMAS_FOTOVOLTAICOS_Y_EOLICOS_CONECTADOS_A_LA_RED)
- Faheem Mushtaq, M., Akram, U., Aamir, M., Ali, H., & Zulqarnain, M. (2019). Neural Network Techniques for Time Series Prediction: A Review. 3, 2–10. [https://www.researchgate.net/publication/335107160\\_Neural\\_Network\\_Techniques\\_for\\_Time\\_Series\\_Prediction\\_A\\_Review/fulltext/5da2398245851553ff8c23b8/Neural-Network-Techniques-for-Time-Series-Prediction-A-Review.pdf](https://www.researchgate.net/publication/335107160_Neural_Network_Techniques_for_Time_Series_Prediction_A_Review/fulltext/5da2398245851553ff8c23b8/Neural-Network-Techniques-for-Time-Series-Prediction-A-Review.pdf)
- José de Jesús, R., José Alberto, H.-A., Francisco Jacob, Á.-C., Juan Manuel, S.-C., & Adolfo, M.-R. (2016). Neuronales Sensor System Based in Neural Networks for the Environmental Monitoring. 17, 211–222. <https://www.redalyc.org/pdf/404/404445803006.pdf>
- L. Cruz, D. Carrión, & A. Riofrio. (2016). Vista de Localización de Fallas Mediante la Transformada Wavelet en Líneas de Transmisión. 13, 79–89. <https://revistaenergia.cenace.gob.ec/index.php/cenace/article/view/10/9>
- Learnig Statis. (2024). ¿Qué es el cruce por cero? Comprender el comportamiento de las señales. [https://es.statisticseasily.com/glossario/what-is-zero-crossing-in-signal-analysis/?utm\\_source=chatgpt.com](https://es.statisticseasily.com/glossario/what-is-zero-crossing-in-signal-analysis/?utm_source=chatgpt.com)
- Li, T., Zhao, Z., Sun, C., Cheng, L., Chen, X., Yan, R., & Gao, R. X. (2022). WaveletKernelNet: An Interpretable Deep Neural Network for Industrial Intelligent Diagnosis. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 52(4), 10–15. <https://doi.org/10.1109/TSMC.2020.3048950>
- Luis Rubén Cruz Andaluz. (2016). Aplicación de la Transformada de Wavelet Para Ubicación de Fallas En Sistemas Eléctricos de

- Potencia [Investigación, Universidad Politecnica Saieciana]. Letters, 9(3), 81–84.  
<https://doi.org/10.1109/97.995823>  
<https://dspace.ups.edu.ec/bitstream/123456789/12873/3/UPS-KT01292.pdf>
- LUNA, M., STALLER, A., HARNISTH, K., ECHEVERRÍA, D., CASTRO, R., & PORTILLA, Ó. (2019). Análisis de la serie temporal de la estación de monitoreo continuo CUEC - REGME. Revista Geoespacial, 15(2), 127.  
<https://doi.org/10.24133/GEOESPACIAL.V15I2.1281>
- Mercado Polo, D., Pedraza Caballero, L., & Martínez Gómez, E. (2015). Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo. Prospectiva, 13(2), 88.  
<https://doi.org/10.15665/rp.v13i2.491>
- Morales-Oñate, V., Moreta, L., Morales-Oñate, B., Morales-Oñate, V., Moreta, L., & Morales-Oñate, B. (2020). ALGORITMO DE BALANCEO DE DATOS MIXTOS PARA BIG DATA EN R. Perfiles, 1(24), 20–26.  
<https://doi.org/10.47187/PERF.V1I24.75>
- Wang, Z., & Bovik, A. C. (2002). A universal image quality index. IEEE Signal Processing