

# Análisis de singularidades en líneas de producción utilizando transformada Wavelet en un sistema embebido.

Acuña García José Alfredo, Canchola Magdaleno Sandra Luz.  
Facultad de informática, Universidad Autónoma de Querétaro,  
Querétaro, Qro.

jose.alfredo.acuna@uaq.mx, sandra.canchola@uaq.mx

**Recibido:** 18 de noviembre de 2019

**Aceptado:** 2 de diciembre de 2019

## RESUMEN

El proceso de sinterizado es uno de los más comunes en la manufactura de partes para la industria automotriz, y sus fases incluyen el prensado de polvos metálicos y la fundición por medio de procesos a altas temperaturas. La presencia de defectos de fabricación por sinterizado a alta temperatura, está relacionada con la presencia de sucesos singulares, que son motivo de interés para la toma de decisiones en líneas de producción. La presente investigación aplica la Transformada Discreta Wavelet (DWT) en dispositivos embebidos para el análisis puntual de líneas de producción en el proceso de sinterizado de piezas, identificando singularidades que afecten negativamente la calidad de la fabricación de partes. El dispositivo embebido obtiene las lecturas y las transforma al dominio Wavelet para su análisis. La información es enviada a un servidor de base de datos para análisis por medio de técnicas de inteligencia artificial y Sistemas de Decisiones Basados en Casos (CBR). Preliminarmente el análisis de datos permite analizar patrones de información utilizando técnicas de Clustering observando los coeficientes Wavelet como indicadores de agrupación, para su comparación con eventos sucedidos en la producción y en apoyo a la toma de decisiones.

**Palabras claves:** Línea de producción, Wavelet, Embebido, Sinterizado, CBR.

## ABSTRACT

The sintering process is one of the most common in the manufacture of parts for the automotive industry, and its phases include the pressing of metal powders and smelting by means of processes at high temperatures. The presence of manufacturing defects by sintering at high temperature, is related with detection of singular effects, that are of interest for decision-making in production lines. The present investigation applies the Wavelet Discrete Transform (DWT) in embedded devices for the timely analysis of production lines in the process of sintering parts, identifying singularities that negatively affect the quality of parts manufacturing. The embedded device obtains the readings and transforms them to the Wavelet domain for analysis. The information is sent to a database server for later analysis through artificial intelligence techniques and Case Based Decision Systems (CBR). Preliminarily the data analysis allows to see information patterns that analyzed by Clustering techniques taking the Wavelet coefficients as grouping indicators, for comparison with events occurred in the production in support of decision making.

**Key Word:** Production line, Wavelet, Embedded, Sintering, CBR.

## 1. INTRODUCCIÓN

El proceso de sinterizado es uno de los más comunes en la manufactura de partes para la industria automotriz, y sus fases incluyen el prensado de polvos metálicos y la fundición por medio de procesos a altas temperaturas. El sinterizado, también conocido como pulvimetalurgia, es un proceso que consiste en aplicar presión y alta temperatura, sin llegar al punto de fusión, a un material en polvo. De esta manera el material se compacta y forma una pieza sólida (Rodríguez, et al., 2017).

En detalle la operación de sinterizado tiene cuatro fases:

- Dosificado y mezcla de polvos para conseguir la composición deseada.

- Presión del polvo en un molde para formar el cuerpo en verde o en crudo.
- Sinterizado a alta temperatura para la fundición de partículas.
- Operaciones de acabado.

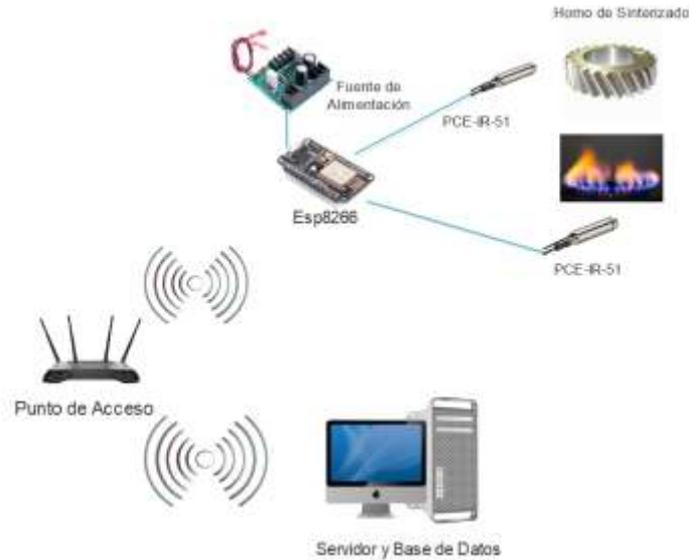
Con este método se pueden conformar materiales como tungsteno, molibdeno, renio o carbono sin la necesidad de calentar hasta el punto de fusión, que en estos casos es muy alto. El proceso de sinterizado presenta algunas ventajas: composición completamente controlada, no existen pérdidas de material, piezas estructurales con formas complejas, porosidad controlada, se pueden conseguir propiedades especiales como dureza y resistencia al desgaste, gran precisión y buen acabado superficial, grandes series de piezas con pequeñas tolerancias (Sintermex, 2018).

El procesamiento de señales por medio de Wavelets es un área que cobra cada vez más importancia en el análisis de información no evidente en series de tiempo. Un método para analizar señales en series de tiempo es transformarlas a un dominio que aporte información valiosa para su análisis, como por ejemplo el dominio de la frecuencia. La Transformada Discreta Wavelet (DWT- Discrete Wavelet Transform) permite descomponer un conjunto de datos de un dominio original hacia un dominio que representa elementos de frecuencia de los datos que se transforman. La DWT es aplicable a datos organizados en 1 Dimensiones (1D) la cual se utilizó en este trabajo, y es posible aplicarla a N Dimensiones (ND), sobre una serie de datos que varían con el tiempo, utilizando para su transformación un dispositivo embebido (Chui, 1992).

En esta investigación se monitorean los datos de temperatura adquiridos de líneas de producción de un proceso de sinterizado. Los datos son adquiridos por medio de dos sensores de temperatura para medición infrarroja de temperaturas de hasta 1,100°C por cada punto de recolección. En cada punto, coordinando la adquisición de datos de los dos sensores de temperatura, se encuentra un dispositivo embebido que tiene como función realizar las mediciones, transformarlas por medio de la DWT, y transferirlas a la base de datos de un servidor.

El dispositivo embebido obtiene 64 lecturas en lapsos de tiempo de 30 segundos, determina el promedio y transforma las lecturas al dominio Wavelet para su análisis a la recepción de datos en el servidor. Se realiza el monitoreo de dos líneas de fundición del proceso de sinterización, por medio de 10 puntos de adquisición.

El proceso de utilizar la DWT en el dispositivo embebido requiere de realizar una implementación del algoritmo adaptándolo a las características de programación del dispositivo embebido, con sus limitaciones de memoria y velocidad. El dispositivo utilizado es un NodeMCU modelo ESP8266, con un procesador RISC de 32-bit Tensilica Xtensa LX106 a una frecuencia de reloj de 80 MHz, comunicación WIFI y puertos seriales de comunicación. Los dispositivos sensores de temperatura son PCE-IR-51 para un rango de temperaturas hasta los 1,100°C. En la Figura 1 se describe a detalle la configuración diseñada e implementada en el proceso de sinterizado.



**Figura 1. Diagrama esquemático del diseño del dispositivo de monitoreo de datos. Fuente: Elaboración propia (2019).**

La información es enviada al servidor y se almacena para su análisis posterior procesándola para su clasificación e identificación de casos para apoyo en la toma de decisiones en los eventos de producción. Se utiliza para su almacenamiento una base de datos MariaDB sobre un servidor XAMPP de Apache foundation.

La importancia de esta investigación radica en apoyar la toma de decisiones en el proceso de gestión de la calidad de líneas de producción de sinterizado, y permite organizar el monitoreo en forma que facilite detectar singularidades que afecten negativamente la calidad de la fabricación de partes. El objetivo de la presente investigación es analizar de las singularidades presentes en las lecturas de un sistema de monitoreo de líneas de producción de sinterizado de piezas, para el mejoramiento de la calidad de la fabricación, utilizando la DWT de 1 dimensión, análisis por Clustering y CBR. El análisis se extiende a estudiar las causas que provocan piezas con defectos, y apoya la toma de decisiones con el análisis de datos para prever condiciones adversas probables en la fabricación de piezas.

El presente documento abordada la investigación en 5 secciones principales, siendo la primera esta introducción, marco teórico y antecedentes a esta investigación. En la sección de metodología establece los pasos para realizar las pruebas que se mostrarán en la siguiente sección. La sección de resultados muestra cuadros e imágenes aplicando la metodología definida, seguida de la sección de discusión. Finalmente, la última sección presenta conclusiones y posibles estudios futuros.

### 1.1. Marco teórico

Una señal que cambia en el tiempo, también conocida como serie de tiempo, representada por una serie de datos discretos se representa matemáticamente en la ecuación 1.

$$f(t) = \sum_{k=1}^{\infty} \mu_k \phi_k(t) \quad (1)$$

Donde  $f(t)$  es una señal definida por una serie de tiempo,  $\mu_k = \langle f(t) | \phi_k(t) \rangle$  y  $\phi_k(t)$  son funciones básicas compuestas por varias señales de ondiculas. En consecuencia, los coeficientes de las señales ondiculas integradas en las funciones están dadas por diferentes valores de  $k$  y pueden generalizarse como indica la ecuación 2.

$$\mu_k = \langle f(t) | \phi_k(t) \rangle = \int f(t) \phi_k(t) dt \quad (2)$$

Una Wavelet es una función caracterizada por diferentes ondas que dependen en su integración de su localización a lo largo de una variable independiente en el eje del tiempo ( $t$ ). Una Wavelet que tiene la propiedad de ser normalizada, debe cumplir con la condición de que su valor medio debe ser cero como lo expresa la ecuación 3. (Chui, 1992).

$$\int_{-\infty}^{\infty} \varphi_i(t-i) dt = 0 \quad (3)$$

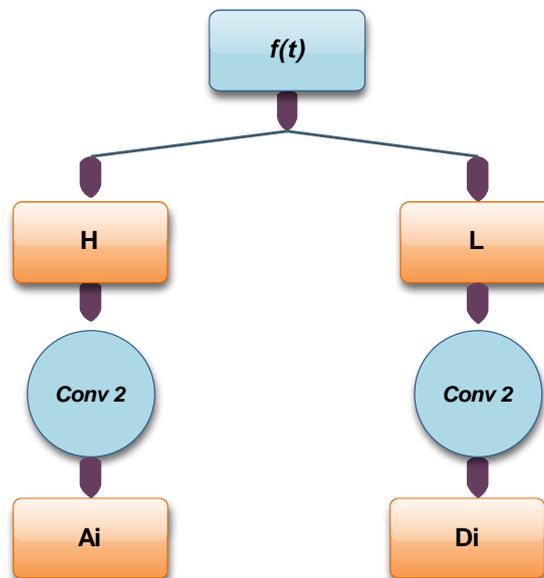
Donde  $\varphi_i(t-i)$  representa la Wavelet,  $i$  es un valor que varía sobre el eje  $x$ , y cuya integración de valores es en promedio cero.

La DWT está fundamentada en la integración discreta de dos funciones a lo largo de su eje de variable independiente (el eje del tiempo para una serie de tiempo). La que es sujeta de análisis, que es una señal de duración indefinida, y la Wavelet tiene una duración definida. El método aplica la Wavelet a la señal de análisis integrándola, en la longitud de la Wavelet y desplazándola sobre el eje del tiempo para seguir cubriendo la de la señal de análisis. El proceso de integrar de forma discreta las señales se le conoce como convolución matemática. De este proceso se obtienen coeficientes expresados en las ecuaciones 4 y 5, para un análisis multi-resolución de dos resoluciones.

$$A_i = \int_{-\infty}^{\infty} 2^{\frac{1}{2}} \phi_0(2^{-1}t - i) f(t) dt \quad (4)$$

$$D_i = \int_{-\infty}^{\infty} 2^{\frac{1}{2}} \varphi_0(2^{-1}t - i) f(t) dt \quad (5)$$

Donde  $\phi(t)$  y  $\varphi_0(t)$  son las Wavelet de convolución en el dominio del tiempo, que definen coeficientes de altas y bajas bandas de frecuencia,  $A_i$  representa los coeficientes de mayor frecuencia de la transformación Wavelet y  $D_i$  los de menor frecuencia. Este proceso se puede ver esquematizado en la figura 2.



**Figura 2. Esquema de la Transformación Wavelet Discreta a dos niveles de resolución en 1D.**  
Fuente: Elaboración propia (2019).

## 1.2. Antecedentes

El uso de la Transformada Wavelet se ha ocupado en diferentes aplicaciones de análisis de frecuencias y su utilización práctica ha sido en la eliminación de ruido en señales, identificación, extracción de características, encriptamiento entre varios usos más.

La reducción de ruido de una señal es una aplicación que realiza el investigador Cedeño (Cedeño et al., 2014) en el cual se propone el tratamiento de señales industriales SCADA para la atenuación de ruido gaussiano. Utiliza un kernel Haar para la Wavelet, e identifica en los coeficientes de mayor frecuencia la señal de ruido a atenuar, aplicando directamente un método de escalamiento y reconstrucción.

Siguiendo una metodología similar, el investigador Yu (Yu, et al., 2017), utiliza la Transformada Wavelet Continua (CWT), para realizar su análisis, siendo que esta transformación obtiene mayor cantidad de coeficientes, pero es de un orden superior de complejidad. El autor Yaseen (Yaseen, et al., 2016), hace uso de la Transformada Wavelet Discreta (DWT) para eliminar el ruido en una señal 1D de uso biomédica. La investigación de Santamaría (Santamaría, et al., 2011), para el tratamiento de señales lumínicas y reducción de ruido con la DWT.

El uso de las Wavelet se aplica a una serie de tiempo financiera en la investigación de Eliasson (Eliasson, et al., 2018). Para el análisis de los datos financieros se utiliza la CWT de una dimensión. Fundamentalmente su metodología se basa en la Transformación de la serie de tiempo al dominio Wavelet y la identificación de patrones que sean característicos de movimientos singulares en el mercado financiero, sobre ciertas acciones del sector de inversiones. La identificación inspira el trabajo que presenta para descubrir elementos singulares.

En la investigación de Parmar (Parmar, et al., 2014), se propone un análisis de parámetros de calidad del agua en ciertos aspectos específicos de un río, utilizando la CWT 1D con el kernel Daubechies D5, D4, D3, D2 y D1, realizando mediciones y transformaciones para la identificación en diferentes series de tiempo.

El uso de la transformación Wavelet en el análisis de genes para la predicción es motivo del trabajo del investigador Farhadian (Farhadian, et al., 2014), el cual analiza específicamente la DWT en el tercer nivel de descomposición para identificar las variaciones de la secuencia genética tomada como una serie de tiempo.

En el área de los mercados financieros, se utiliza para detectar puntos de cambio que representan eventos especiales en el comportamiento financiero. La metodología utilizada se basa en la transformación Wavelet de los movimientos bursátiles de ciertas acciones, que son representadas por una serie de tiempo. La descomposición se realiza aplicando diferentes capas por medio del método de Quandt-Andrews, donde se va descomponiendo la señal en frecuencias. Cada banda de frecuencias puede indicar si ocurrió un evento de cambio y se puede determinar la fecha del evento y analizar las circunstancias del mismo. Se puede decir que cada evento especial se debe analizar y este es un método interesante a aplicar en el actual trabajo de investigación (Zang, et al., 2018).

En el trabajo presentado por el investigador Xing, se analiza un evento hidrológico por medio de series de tiempo, y se diseñó un algoritmo de transformación Wavelet como parte de su metodología. El propósito fue realizar un modelo de pronóstico utilizando un modelo ARIMA y uno RBF con redes neuronales. El resultado de esta combinación de métodos fue más acertado que la aplicación de los métodos por separado. El pronóstico resultante se consideró acertado, lo cual confirma las bondades de la metodología utilizada. Este análisis permite observar la posibilidad de ocupar estos métodos para hacer un resultado predictivo (Xing, et al., 2019).

En la identificación de riesgos en sistemas de seguridad se puede ocupar el análisis de series de tiempo utilizando la transformada Wavelet. Fueron estudiadas diferentes características de la serie de tiempo para la identificación de riesgos, que son identificados como eventos que se presentan con una determinada frecuencia, y que pueden indicar la presencia de posibles violaciones de seguridad. La transformada Wavelet se utiliza por considerar que presenta mejores resultados en el análisis de señales no-estacionarias. Las conclusiones presentadas permiten observar eventos singulares presentadas en gráficas de descomposición de bandas de frecuencia. Para

la actual investigación se consideraron criterios del investigador Amosov en cuanto a la no-estacionalidad de la serie de tiempo y el análisis de frecuencia (Amosov, et al., 2018).

El uso de la inteligencia artificial para la identificación de ciertas estructuras textiles, para analizar las propiedades de los productos de esta industria es un trabajo que presenta el investigador Bullon (Bullon, et al., 2016). Para el cotejo del análisis de las estructuras atípicas utiliza Razonamiento Basado en Casos (CBR), en donde una vez identificados los casos, se puede hacer una identificación en línea de cada una de las lecturas singulares obtenidas en las tomas de información.

De forma similar el investigador Acuña (Acuña, 2011) realiza un análisis de información contable de una empresa para la predicción de eventos en base a la identificación de patrones y su comparación con eventos identificados. Utiliza herramientas de Clustering y CBR como apoyo en la identificación y predicción.

Elementos importantes del proceso de sinterizado se analizan por el investigador Rodríguez (Rodríguez, et al., 2017), en cuanto a las materias primas, las tolerancias, propiedades y composición química, y el proceso de prensado y fundición de piezas. Este artículo es muy útil para comprender la importancia de la etapa de fundido en la rastreabilidad y detección de comportamientos singulares por identificar.

## **2. METODOLOGIA**

Se propone la siguiente metodología para el logro del propósito de este proyecto de investigación. La investigación es de tipo cualitativo, y obtiene como resultado un análisis de las singularidades presentes en las lecturas de un sistema de monitoreo de líneas de producción de sinterizado de piezas, con el objetivo de lograr el mejoramiento de la calidad de la fabricación. Se utiliza la DWT de 1 dimensión, análisis por Clustering utilizando la distancia euclidiana como criterio de similitud y se analiza por medio de técnicas de CBR.

Un primer propósito parcial es la transformación al dominio de las Wavelets, de una señal de temperatura adquirida por medio de dispositivos embebidos en una línea de producción de una empresa de sinterización. Un segundo propósito es permitir su comunicación a una base de datos en un servidor de la empresa y su análisis en la búsqueda de comportamientos singulares por medio de técnicas de Clustering. Estos comportamientos se analizan de forma preliminar, utilizando técnicas de CBR para la identificación de singularidades en el proceso de producción de partes que afecten la calidad de las mismas.

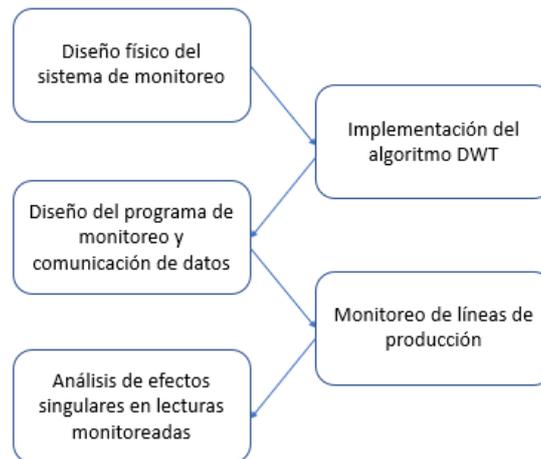
El presente trabajo incluyo el diseño del sistema embebido de monitoreo de temperaturas implementado en el proceso de sinterizado, la implementación de el algoritmo DWT adaptada a la arquitectura del dispositivo embebido y del sistema integral de monitoreo y de la comunicación con el servidor.

Una vez construido el dispositivo de monitoreo, se implementó el algoritmo DWT-1D (DWT de 1 Dimensión) para el procesador ESP8266, adaptándolo a las características del hardware, para poder realizar las 64 lecturas cada 30 segundos, y realizando su transformación. Se utiliza un kernel Daubechies D2 y se obtienen 2 grupos de coeficientes de bandas de frecuencia.

Se monitorean dos puntos por cada punto de producción, y por cada línea 5 puntos tomando como muestra 10 días. Se implementó la operación completa de monitoreo de sensores de temperatura y comunicación con el servidor por medio del protocolo 802.11g.

Analizando las lecturas del monitoreo, por medio de herramientas de Clustering en el servidor, en la búsqueda de comportamientos singulares y su catalogación en casos para apoyo al razonamiento y para la mejora de la fabricación. Así se identifican posibles problemas utilizando técnicas de CBR, en la fundición o en los dispositivos que permiten la fundición, además de permitir la rastreabilidad de lotes con posibles problemas estructurales.

En la figura 3 se presenta el esquema general de la metodología utilizada.



**Figura 3. Esquema de la metodología. Fuente: Elaboración propia (2019).**

El pseudocódigo implementado en ESP8266 está fundamentado en el algoritmo de Mallat. En la Figura 4 se muestra el algoritmo adaptado en la implementación.

```
# Función de transformación enviando señal tamaño n
# y regresando el resultado tamaño m
Función DWT_Daub2(señal[],n, resultados[],m)
  Si (n>=4)
    definición de coeficientes kernel Daubechies 2 en h
    h0=0.48296, h1=0.83651, h2=0.22414 y h3=-0.12940
    definición de coeficientes complementarios en g
    g0=-h3, g1=h2, g2=-h1, g3=h0
    m es igual a n /2
    para cada j=0, mientras j<m incrementa j en 1
      resultados[j] = convolución señal[(2*j+d)%n]*coeficientes
                    kernel variando d (1..3)
      resultados[j+m]= convolución señal[(2*j+d)%n]*coeficientes
                    complementarios variando d (1..3)
```

**Figura 4. Seudocódigo del algoritmo DWT implementado en el embebido. Fuente: Elaboración propia (2019).**

### 3. RESULTADOS.

Los coeficientes Wavelet y lecturas promedio del monitoreo de las líneas de sinterizado son almacenados en un servidor local en su base de datos. La estructura de la base de datos registra por cada lectura: la fecha, hora detallada hasta centésimas de segundo, el identificador del punto de monitoreo o identificador del dispositivo embebido, el sensor que se monitorea de los dos disponibles, la temperatura promedio de los 30 segundos, los 32 coeficientes de la resolución alta y los 32 de la resolución baja enviados y transformados por el dispositivo embebido. Todas las lecturas en formato flotante de 32 bits.

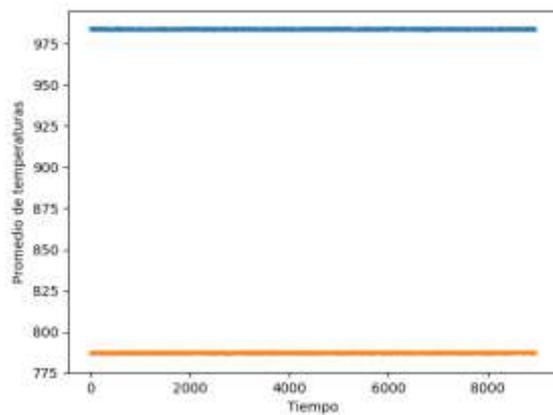
Las lecturas para este análisis constan de aproximadamente 10 días de captura, 1,152,000 momentos de captura, tomando los promedios de las 64 temperaturas y la transformación Wavelet de estas 64 lecturas.

El análisis de clustering se realiza sobre lecturas de las dos líneas de producción, sobre los 10 puntos de monitoreo. La primera lectura es solo utilizando el sensor dirigido a la banda de transferencia de partes (*Caso*

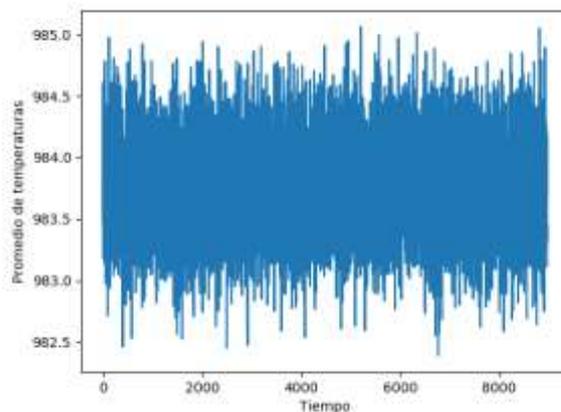
A). El segundo análisis se realiza de igual forma, pero sobre el sensor dirigido al quemador de la banda de transferencia (*Caso B*).

En la figura 5a se muestran la gráfica de los valores de temperaturas promedio de los 10 puntos de monitoreo en el *Caso A* y *B*.

En la figura 5a se puede observar que la temperatura de cada grupo de sensores en el caso A en azul, y para el caso B en naranja. La diferencia entre estas lecturas observa una clara diferencia en el promedio de aproximadamente 100°C. En la gráfica de la figura 5b se muestra el caso A, de la figura 5a, y las lecturas adquiridas por los dispositivos embebidos; se pueden observar variaciones de 2.5 grados en promedio, en la temperatura detectada, sin observar mayores distorsiones en cada punto en cada intervalo de tiempo de análisis (30 segundos).



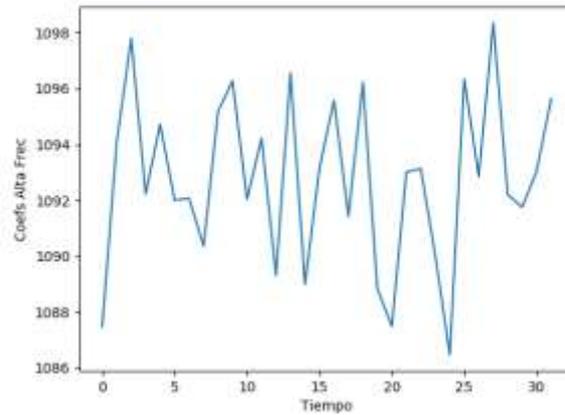
(a)



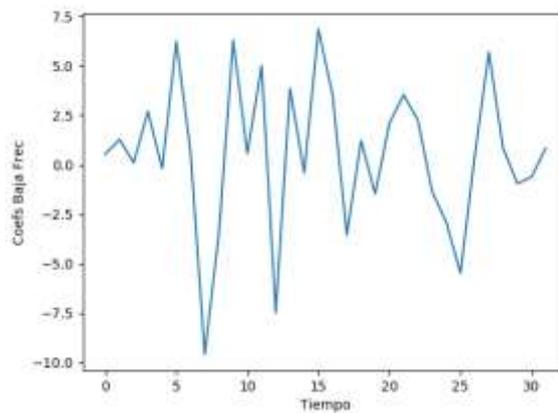
(b)

**Figura 5. Valores de temperatura detectadas en el tiempo. (a) Caso A y B, y (b) únicamente caso B. Fuente: Elaboración propia (2019).**

En la figura 6a se ven las variaciones que se presentan en los coeficientes de alta resolución de la transformación Wavelet, y en la Figura 6b se observan los coeficientes de baja resolución. Se observa que a pesar de que el análisis de la información de temperaturas promedio presenta poca variación, los coeficientes de la transformación presentan patrones que reflejan variaciones no evidentes en la serie de tiempo en el dominio del tiempo.



(a)



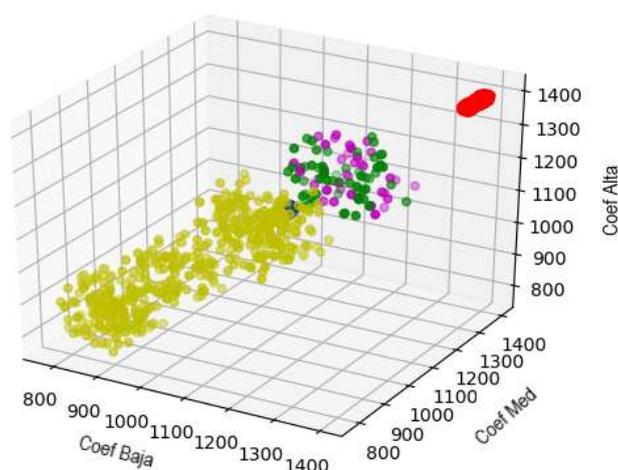
(b)

**Figura 6. Valores de los coeficientes Wavelet en el tiempo. (a) Coeficientes de alta y (b) baja resolución. Fuente: Elaboración propia (2019).**

Para cada una de las lecturas obtenidas en el dominio del tiempo por los sensores, se registra el promedio de las 64 lecturas adquiridas durante 30 segundos y se reportan a la base de datos. Estas lecturas en el dominio del tiempo no presentan un comportamiento singular en los datos.

En el dominio de las Wavelet se observa una mayor variación que se presenta en la figura 6a y 6b. En ellas se presentan magnitudes de variación mayores en los coeficientes de mayor frecuencia que en los de baja frecuencia, por lo que, en el proceso inverso de la DWT, es más representativa la señal de alta frecuencia para la reconstrucción de la señal hacia su dominio original. Los coeficientes de baja frecuencia mostrados en la figura 5b, tienen menor impacto en la transformación inversa de la DWT y en consecuencia representan menormente la señal en su dominio original.

El análisis de los coeficientes Wavelet transformados de las lecturas de temperatura, se realizó por medio de la técnica de Clustering, considerando para el estudio los coeficientes de alta resolución Wavelet. El resultado de este análisis se presenta en la figura 7, y permite observar una clara distinción entre los grupos formados. Los 5 grupos formados son los que presentan una mayor diferenciación en la identificación de elementos singulares.



**Figura 7. Análisis de coeficientes Wavelet de alta frecuencia por medio de Clustering.**

**Fuente: Elaboración propia (2019).**

Los grupos formados representan la agrupación de puntos con características comunes. En la tabla 1 se puede observar la distribución que presentan los centroides obtenidos por el proceso de Clustering de los 32 elementos de alta resolución del Caso A, relacionada con los coeficientes de baja, media y alta frecuencia. Se observa que tienen mayor representatividad solo 3 agrupamientos (rojo, azul y amarillo). Como se puede visualizar, los grupos 0, 1 y 3 agrupan a la mayor cantidad de datos (99.96%). Considerando los eventos ocurridos en las líneas de producción durante el periodo de monitoreo, se puede decir que estos datos representan el proceso normal de sinterizado de la línea de producción. Especialmente los grupos 2 y 4 se pueden considerar singulares.

**Tabla 1. Clústeres del análisis de coeficientes Wavelet de alta frecuencia.**

**Fuente: Elaboración propia (2019).**

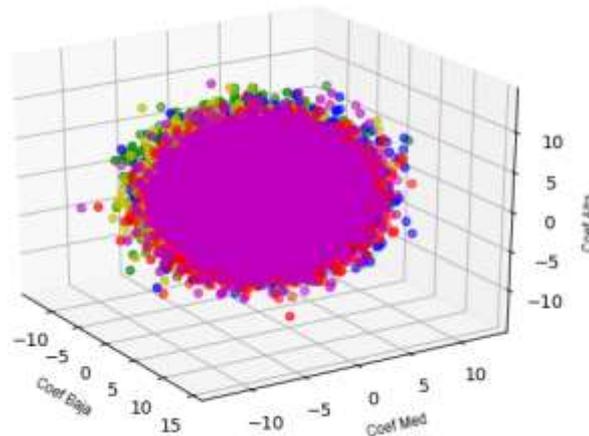
Clúster	Coefficientes Baja	Coefficientes Med	Coefficientes Alta	Población	Color
0	1407.0	1407.0	1413.9	49.847%	Rojo
1	1131.3	1131.3	1136.9	29.883%	Azul
2	1210.0	1220.0	1212.7	0.032%	Verde
3	1115.3	1115.3	1120.8	20.216%	Amarillo
4	1228.0	1225.6	1229.6	0.021%	Magenta

De la tabla 1 se desprende en análisis de los grupos singulares que son motivo de un análisis cualitativo en base a la técnica CBR. Estos casos singulares analizados puntualmente son los que se presentaron por problemas de temperatura en la línea de producción. En el caso de los puntos verdes del clúster 2, fueron casos con alteraciones fuertes de temperatura a la baja. Los casos magentas del grupo 4 son representativos de problemas para mantener la temperatura constante y se presentaron durante tiempos relativamente cortos (4 segundos) pero que se presentaron con mucha frecuencia.

El análisis de los datos de estos casos son los elementos que por singularidad se busca identificar para formar la base de datos de casos que permita comparar los eventos con sucesos de la producción. La importancia de la identificación se debe de poder realizar desde el momento de la recepción de la información en el servidor para

poder ser reportada a los supervisores de producción de la empresa. La oportunidad de la información es importante para tomar las acciones correctivas pertinentes en tiempos semi-inmediatos.

En la figura 8 se presenta el agrupamiento obtenido para los coeficientes de resolución Wavelet que representan la baja frecuencia. En este caso los datos poco representan a la señal en el dominio del tiempo, al realizar la reconstrucción de la señal, por su baja magnitud y poca diferenciación.



**Figura 8. Análisis de coeficientes Wavelet de baja frecuencia por medio de Clustering.**  
**Fuente: Elaboración propia (2019).**

Los coeficientes en el dominio de la Wavelet son de poca magnitud, y en el análisis de Clustering, los clústeres formados por los coeficientes Wavelet tienen aproximadamente una representación similar en porcentaje. Existe poca diferenciación e identificación de datos singulares y se considera que los datos mantienen una distribución uniforme entre el 19% y 20% por cada rango. Los clústeres observados en la tabla 2, mantienen un gráfico muy homogéneo que requiere de un análisis detallado para definir si representan casos singulares especiales y que representen un impacto en los elementos indicadores de un evento en las líneas de producción.

**Tabla 2. Clústeres del análisis de coeficientes Wavelet de baja frecuencia.**  
**Fuente: Elaboración propia (2019).**

Clúster	Coefficientes Baja	Coefficientes Med	Coefficientes Alta	Población	Color
0	-0.5	-0.2	-0.4	20.080%	Rojo
1	0.8	-0.2	-0.7	19.923%	Azul
2	0.5	0.4	1.0	19.922%	Verde
3	-1.3	1.1	0.5	20.196%	Amarillo
4	0.5	-1.1	-0.4	19.879%	Magenta

#### 4. DISCUSION

El análisis de las singularidades presentes en las lecturas de un sistema de monitoreo por medio de Wavelets y técnicas de Clustering resulta muy importante para la gestión de la calidad de las piezas fabricadas en un proceso de sinterizado. Este análisis permite la identificación de los factores de temperatura para el mejoramiento de la calidad de la fabricación. Como consecuencia permite el análisis de varias posibles causas que pueden derivar en piezas con defectos de fabricación y rechazos en lotes entregados a clientes finales.

Adicionalmente se aporta información que apoya la toma de decisiones pronosticando condiciones posibles que provoquen problemas de calidad en la fabricación de piezas y apoyando la administración de mantenimiento a las líneas de producción, el análisis de los insumos para el calentamiento de los hornos de sinterizado, o la detección de problemas con las bandas de transmisión o con los quemadores de los hornos.

Es claro que existe información que no es evidente en las lecturas promedio de monitoreo de las líneas de producción, y que se presentan de forma clara en el análisis de los coeficientes Wavelet (transformadas las lecturas al dominio de las Wavelets) en bandas de alta frecuencia, organizadas por medio de la técnica de Clustering. Esta información clasificada es importante en la toma de decisiones correctivas semi-inmediatas. Las decisiones correctivas permiten tomar medidas semi-inmediatas en los sistemas de fundición o en la identificación de lotes que no cuentan con la calidad para ser liberados a clientes.

## **5. CONCLUSIONES.**

La información resultante del procesamiento de los datos que se presentan en una serie de tiempo, contiene información oculta que no es evidente en el dominio del tiempo y no es identificada si solo se analiza desde su dominio original. Se resalta que los datos ocultos en un dominio original, son identificados en el dominio de las Wavelet, y presentan información que identifica problemas singulares que afectan los procesos que representan las series de tiempo.

En el caso particular de las líneas de producción de un proceso de sinterizado, donde la temperatura del proceso de fundido es un elemento definitorio en la calidad del producto, se vuelve fundamental conocer al instante los eventos que representan variaciones singulares. El resultado de esta investigación permite que la información de datos singulares se presente de forma ágil a los supervisores de las líneas de producción mediante un tablero de control. De esta manera permite tomar decisiones correctivas que afecten lo menos posible los productos que se procesan en la línea.

Los resultados permiten tomar medidas correctivas semi-inmediatas, y realizar análisis forense que identifique más casos de apoyo al razonamiento. Estos casos agregados a la base de datos CBR permitirá adicionarlas al sistema de identificación semi-inmediata. Finalmente, esto tiene un impacto económico en la empresa, apoyando a las decisiones tomadas oportunamente sobre las líneas de producción.

El presente trabajo tiene aplicaciones futuras en la identificación de los casos en donde el análisis de las series de tiempo, en el dominio de las Wavelets, determine que existen eventos que afectan la producción de partes de forma negativa, que no han sido identificados. La identificación de nuevos casos se realizará por medio de la aplicación de técnicas de aprendizaje profundo para enriquecer el sistema CBR.

La aplicación de técnicas de aprendizaje profundo se aplicará en futuros trabajos para realizar pronósticos relacionados con la probabilidad de falla en los equipos, o la detección de mezclas incorrectas en las materias primas (gases) que se utilizan para los quemadores de las líneas de producción, entre otros. También se planea analizar la realización de una investigación que estudie la serie de tiempo por medio de un análisis Wavelet continuo y redes neuronales, lo que aportaría información de recurrencia de eventos singulares en el proceso de producción.

## **6. REFERENCIAS BIBLIOGRAFICAS**

- Acuña, J., (2011). Modelo de apoyo al razonamiento prospectivo empresarial utilizando inteligencia artificial: caso de estudio en una empresa. Universidad Autónoma de Querétaro. Tesis de maestría.
- Amosov, O., Amosova, S. and Muller N. (2018). Identification of Potential Risks to System Security Using Wavelet Analysis, the Time-and-Frequency Distribution Indicator of the Time Series and the Correlation Analysis of Wavelet-Spectra. International Multi-Conference on Industrial Engineering and Modern Technologies.

- Bullón, J., Gonzalez, A., Hernandez, A. and Queiruga, A. (2016). Textile Engineering and Case Based Reasoning. Distributed Computing and Artificial Intelligence, 13th International Conference pp 423-431.
- Cedeño, A. and Trujillo, R. (2014). Esquema basado en Wavelet para la reducción de ruido online en señales industriales. Revista Cubana de Ciencias Informáticas, Vol. 8, No. 3, Julio-septiembre, 2014.
- Chui, C. (1992). Wavelet analysis and its applications, USA. Academic Press.
- Eliasson, K. (2018). An Application of the Continuous Wavelet Transform to Financial Time Series. Department of Electrical and Information Technology Lund University.
- Farhadian, M. Mahjub, H., Moghimbeigi, A., Poorolajal, J. and Mansoorizadeh M. (2014) A Gene Selection Method for Survival Prediction in Diffuse Large B-Cell Lymphomas Patients using 1D Discrete Wavelet Transform. Iranian J Publ Health, Vol. 43, No.8, Aug 2014, pp. 1091-1098.
- Parmar, K. and Bhardwaj, R. (2014). Trend Time Series and Wavelet Analysis of River Water Dynamics. Non-Linear Dynamics Lab, Department of Mathematics University School of Basic and Applied Sciences Guru Gobind Singh Indraprastha.
- Rodríguez, A., Shimomoto, E., Silverio, R., Garcia, G., Chagoyen, C. and Moya, J. (2017). Sintering, a process of metal forming as an economic alternative with a low environmental impact. Editorial Feijóo.
- Santamaría, F., Cortés, C. and Román, F. (2011). Uso de la Transformada de Ondeletras (Wavelet Transform) en la Reducción de Ruidos en las Señales de Campo Eléctrico producidas por Rayos. Información Tecnológica Vol. 23 N° 1 – 2012.
- Sintermex. (2018). Manual: Sintering process in metallurgy and powders. EEUU. Sintermex.
- Xing, S. and Luo Y. (2019). Hydrological time series forecast by ARIMA+PSORBF combined model based on wavelet transform. IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference.
- Yaseen, A., Pavlov, A. and Hramov A. (2016). Speech signal denoising with wavelet-transforms and the mean opinion score characterizing the filtering quality. Proceedings Volume 9707, Dynamics and Fluctuations in Biomedical Photonics XIII.
- Yu, Z., Abma, R., Etgen, J. and Sullivan, C. (2017). Attenuation of noise and simultaneous source interference using wavelet denoising. Society of Exploration Geophysicists.
- Zhang, S. and Cong, X. (2018). The Application of Wavelet Analysis in Financial Multiple Change Points Time Series, 5th International Conference on Industrial Economics System and Industrial Security Engineering.