

## Estudio comparativo de técnicas de reducción de ruido en señales industriales mediante Transformada Wavelet Discreta y selección adaptativa del umbral

Antonio Cedeño Pozo, Ing.<sup>a,\*</sup>, Rafael Trujillo Codorníu, Dr.<sup>b</sup>

<sup>a</sup>Universidad de las Ciencias Informáticas, Km 2½ Autopista La Habana - San Antonio de los Baños, La Lisa, 17100, La Habana, Cuba.

<sup>b</sup>Instituto Superior Minero Metalúrgico de Moa, Las Coloradas, Moa, 28006, Holguín, Cuba.

### Resumen

Las técnicas de reducción de ruido son ampliamente utilizadas en la grabación de audio, la edición de imágenes y en el procesamiento de señales industriales. La idea es reconstruir los datos originales a partir de la señal ruidosa suprimiendo toda, o casi toda, la distorsión generada por el ruido inherente a los procesos físicos. En el presente trabajo se realiza una comparación de diferentes métodos de supresión de ruido que se basan en la selección adaptativa del umbral. Estas técnicas han sido usadas extensivamente en el procesamiento de imágenes pero el objetivo de este trabajo es evaluar su rendimiento en la reducción de ruido de señales industriales. En particular se analiza el comportamiento de los métodos Bayes Shrink, Normal Shrink, Modified Shrink y Neight Shrink para la reducción de ruido gaussiano en estas señales. A tales efectos se utilizó un conjunto de señales patrón, que incluye a las señales propuestas por Donoho y otras mediciones representativas obtenidas de procesos reales en las plantas de Níquel cubanas. Las pruebas realizadas revelan que el algoritmo Neigh Shrink es el que mejor se comporta en los datos analizados. Copyright © 2013 CEA. Publicado por Elsevier España, S.L. Todos los derechos reservados.

**Palabras Clave:** transformada wavelet, ruido, señales industriales, ruido gaussiano

### 1. Introducción

Es conocido por los ingenieros, que trabajan con datos obtenidos del mundo real, que no existen señales libres de ruido. En condiciones ideales el nivel del ruido es insignificante con respecto al nivel de la señal, por lo que la reducción del mismo es innecesaria. En la práctica, sin embargo, es generalmente necesario remover el ruido que altera la señal para cualquier análisis posterior de los datos. Tradicionalmente para reducir el ruido se han utilizado diferentes técnicas de filtrado lineal, dentro de las que se destaca la utilización del filtro de Wiener, así como otros esquemas basados en filtros que trabajan directamente sobre la señal en cuestión. Otro conjunto de técnicas para remover el ruido de las señales son las basadas en el uso de transformadas, donde la más conocida y utilizada es la transformada de Fourier (FT), ideal para señales estacionarias cuyos valores varían muy poco en el tiempo, pero no igual de efectiva para el análisis de señales con variaciones significativas en el tiempo (ver ejemplos (Rioul and Vetterli, 1991) y (Solano, 2002)). Tanto las técnicas de filtrado lineal como las basadas

en FT presentan importantes dificultades para el tratamiento de señales no estacionarias (Dolabdjian et al., 2002).

En este contexto aparece la transformada Wavelet (Discrete Wavelet Transform, DWT). El concepto clave de esta transformada es la adaptación del análisis en el tiempo y la frecuencia de forma simultánea. En este ámbito, ha emergido una amplia teoría acerca de la utilización de técnicas no lineales para reducir el ruido y se han diseñado diferentes esquemas para la supresión del ruido mediante la DWT y la aplicación de umbrales. La reducción de ruido basada en wavelet proporciona una base adecuada para separar el ruido de la señal. Esta técnica involucra tres pasos básicos, que son: descomposición en sub-bandas wavelet mediante la DWT, modificación de los coeficientes wavelet (generalmente mediante la utilización de umbrales) y reconstrucción de la señal a partir de los coeficientes modificados.

De manera más precisa si se asume que los datos observados

$$x(t) = s(t) + \eta(t) \quad (1)$$

contienen la señal pura  $s(t)$  con un ruido auditivo  $\eta(t)$  como funciones muestreadas en el tiempo y mediante  $W(\cdot)$  y  $W^{-1}(\cdot)$  se denotan la transformada Wavelet directa e inversa respectivamente, entonces la técnica de reducción de ruido a que se hace referencia involucra los siguientes pasos:

\*Autor en correspondencia.

Correos electrónicos: [acedeno@uci.cu](mailto:acedeno@uci.cu) (Antonio Cedeño Pozo, Ing.),  
[rtrujillo@edistancia.uo.edu.cu](mailto:rtrujillo@edistancia.uo.edu.cu) (Rafael Trujillo Codorníu, Dr.)  
URL: [www.uci.cu](http://www.uci.cu) (Antonio Cedeño Pozo, Ing.)

1. Obtención de los coeficientes wavelet de la señal ruidosa

$$y = W(x) = \zeta + \nu; \quad \zeta = W(s); \nu = W(\eta) \quad (2)$$

2. Modificación de los coeficientes obtenidos a partir de la aplicación de umbrales.

$$Z = D(y, \lambda) \quad (3)$$

Donde  $D(., \lambda)$  es un operador que para un valor de  $u$  actúa de una de las siguientes maneras:

$$D_s(u, \lambda) = \begin{cases} 0 & \text{si } |u| \leq \lambda \\ u - \lambda & \text{si } u > \lambda \\ u + \lambda & \text{si } u < -\lambda \end{cases} \quad (4)$$

$$D_h(u, \lambda) = \begin{cases} 0 & \text{si } |u| \leq \lambda \\ u & \text{si } |u| > \lambda \end{cases} \quad (5)$$

La fórmula (4) corresponde a la llamada umbralización suave o flexible mientras que la fórmula (5) se corresponde con la llamada umbralización fuerte o fija.

3. Reconstrucción de la señal  $s(t)$  mediante la transformada inversa

$$\hat{s}(t) = W^{-1}(Z) \quad (6)$$

El objetivo de los métodos de supresión de ruido es minimizar la relación

$$\|s(t) - \hat{s}(t)\| \quad (7)$$

en la reconstrucción, o sea suprimir el ruido manteniendo, en lo posible, las propiedades de la señal original. El valor de  $\lambda$ , que regula cómo deben cambiar los coeficientes wavelet, se denomina umbral.

La reducción de ruido mediante la aplicación de umbrales a los coeficientes wavelet de la señal comenzó con los trabajos de Donoho (Donoho et al., 1993) y (Donoho and Johnstone, 1995). En (Donoho et al., 1993) se introdujeron los métodos RiskShrink que es un umbral de tipo minimax y VisuShrink con un umbral universal. En (Donoho and Johnstone, 1995) se introduce el método SureShrink basado en un umbral que minimiza el riesgo de Stein. Posterior a estos trabajos aparecieron algunos métodos de selección del umbral que son adaptativos con respecto a las características espaciales de la señal. Los métodos adaptativos han resultado ser más efectivos en las experiencias realizadas sobre todo en imágenes. Debe destacarse sin embargo, que el umbral universal ha sido retomado por (Xia et al., 2007) para un esquema de reducción de ruido “online”. Entre los métodos adaptativos un lugar especial ocupan los que están basados en las reglas de Bayes (BayesShrink, Modified BayesShrink, NormalShrink y NeightShrink).

Ha sido demostrado, desde el punto de vista teórico, que estas técnicas de umbralización wavelet son casi óptimas cuando se tiene poca información acerca de las características de las señales a analizar. Sin embargo, en muchos problemas prácticos se tiene algún conocimiento “a priori” acerca de

la clase de señales que son de interés. La optimalidad de un algoritmo para la reducción de ruido, por ejemplo, en una clase específica de imágenes, no conlleva necesariamente a que este algoritmo sea óptimo para otro tipo de imágenes y menos aún para señales con características diferentes como las señales industriales.

Estas consideraciones han motivado la aparición de varios trabajos en los cuales se realizan comparaciones experimentales de los diferentes métodos para clases específicas de señales. El primer experimento de Monte-Carlo para comparar procedimientos de reducción de ruido fue realizado por Taswell y publicado precisamente por Donoho en (Donoho and Johnstone, 1995). En él se utilizan un conjunto de señales sintéticas que, de acuerdo a los autores, representan adecuadamente un gran número de señales de carácter científico y se comparan, entre otros, los métodos VisuShrink, RiskShrink y SureShrink.

En varios trabajos se han comparado, sobre imágenes y de forma experimental, los métodos bayesianos Bayes Shrink, Modified Bayes Shrink, Normal Shrink y Neight Shrink (ver ejemplos (Elyasi and Zarmehi, 2009) y (Sihag et al., 2011)). Para estas comparaciones generalmente se utiliza un conjunto de imágenes patrón que ya se ha convertido en un estándar de facto para las investigaciones de reducción de ruido y de compresión de imágenes.

En el presente material se realiza una evaluación de los métodos bayesianos referidos anteriormente sobre un conjunto de señales con diferentes características y propiedades tomadas en su mayoría del entorno industrial. Desafortunadamente, hasta donde conocemos, no se ha establecido en la comunidad científica un conjunto patrón de señales de carácter industrial, que pueda utilizarse para realizar las comparaciones de los diferentes métodos, más allá de las señales sintéticas introducidas por Donoho. En las experiencias que se muestran en este trabajo se incluyeron aquellas señales sintéticas de Donoho que simulan adecuadamente señales industriales. Ellas garantizan además la reproducibilidad de la experiencia. Adicionalmente se analizaron los archivos históricos de varias plantas industriales de gran escala, tales como las plantas de Níquel cubanas y algunas refinerías de petróleo. Como resultado, se decidió incluir en los análisis un conjunto de mediciones que consideramos representativo (temperaturas, presiones, niveles, mediciones de corriente, flujos, etc.) y que abarcan señales suaves, señales constantes a tramos (como los valores deseados de lazos de control), señales impulsivas y señales con patrones periódicos.

## 2. Bayes Shrink (BS)

El método Bayes Shrink fue propuesto por Chang, Yu y Vetterli (Chang et al., 2000). El objetivo del método es minimizar el riesgo Bayesiano. Utiliza una umbralización flexible en la cual el umbral es calculado para cada sub-banda de coeficientes wavelet. El umbral

$$\lambda_B = \begin{cases} \frac{\sigma_\eta^2}{\sigma_s} & \text{si } \sigma_\eta^2 < \sigma_y^2 \\ \max(|y_i|) & \text{si } \sigma_\eta^2 \geq \sigma_y^2 \end{cases} \quad (8)$$

donde  $\sigma_\eta^2$  es la varianza del ruido,  $\sigma_s^2$  la varianza de la señal pura y  $\sigma_y^2$  la varianza de la señal original.

La varianza del ruido ( $\sigma_\eta^2$ ) debe ser calculada previamente. Esta varianza se puede estimar a partir de la señal ruidosa de diferentes maneras. Uno de los estimadores más utilizados viene dado por la siguiente expresión:

$$\hat{\sigma}_\eta = \frac{\text{median}(|y_i|, y \in H_1)}{0.6745} \quad (9)$$

donde  $H_1$  es la primera sub-banda de detalles de la DWT. Una vez obtenida la varianza del ruido se puede estimar la varianza de la señal pura para cada sub-banda  $H_k$  de acuerdo a:

$$\sigma_{sk} = \sqrt{\max\left(\left(\frac{1}{\text{size}(H_k)} \sum_{y_i \in H_k} y_i^2\right) - \sigma_\eta^2, 0\right)} \quad (10)$$

donde  $\text{size}(H_k)$  representa la cantidad de coeficientes del nivel de descomposición de subíndice  $k$ .

### 3. Modified Bayes Shrink (MBS) y Normal Bayes Shrink (NBS)

Iman Elyasi y Sadegh Zarmehi proponen el esquema **MBS** (Elyasi and Zarmehi, 2009), mientras que Lakhwinder, Savita Gupta y R.C.Chauhan proponen el esquema **NBS** (Kaur et al., 2002); ambos esquemas son modificaciones de **BS** y consisten en la introducción de un factor  $\beta_k$  para cada sub-banda de detalles que regula el umbral:

$$\lambda = \frac{\beta_k \sigma_\eta^2}{\sigma_s} \quad (11)$$

Para **MBS**,

$$\beta_k = \sqrt{\frac{\log(\text{size}(H_k))}{2k}} \quad (12)$$

donde  $\text{size}(H_k)$  es la cantidad de coeficientes wavelet para cada subbanda y  $k$  es el nivel de descomposición que se analiza en la subbanda en cuestión. Mientras que para **NBS**,

$$\beta_k = \sqrt{\log\left(\frac{\text{size}(H_k)}{j}\right)} \quad (13)$$

donde  $j$  representa la cantidad de niveles de descomposición.

### 4. Neigh Shrink (NS)

El esquema Neigh Shrink básicamente propone que la umbralización se realice de manera individual para cada coeficiente wavelet considerando la influencia de los coeficientes colindantes. En el **NS** el umbral utilizado para cada coeficiente wavelet se determina de acuerdo a la suma de los cuadrados de los coeficientes colindantes. Suponiendo que  $\{y_j\}$  es el conjunto de coeficientes wavelet de la señal ruidosa, si:

$$S_j^2 = \{y_{j-1}^2 + y_j^2 + y_{j+1}^2\} \quad (14)$$

es menor o igual que  $\lambda^2$ , entonces se establece  $y_j$  en cero. En caso contrario  $y_j$  se modifica de acuerdo a:

$$y_j = y_j \left(1 - \frac{\lambda^2}{S_j^2}\right) \quad (15)$$

donde  $\lambda = \sqrt{2\sigma_\eta^2 \log N}$ ;  $N$  es la longitud de la señal y  $\sigma_\eta^2$  la varianza estimada del ruido.

## 5. Resultados experimentales

En los experimentos se utilizaron tres funciones propuestas por D. Donoho (Donoho et al., 1993), y siete funciones muestreadas provenientes de procesos reales, para todos los casos en este material se utilizaron 2048 muestras. Algunas señales fueron escaladas para que los intervalos de variación de las mismas fueran similares y se les adicionó ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ . Las métricas que se utilizaron para la evaluación de los algoritmos fueron el Error Medio Cuadrático (MSE) y la Relación Señal-Ruido (SNR)-(PSNR), descritas en las siguientes ecuaciones:

$$MSE = \frac{1}{N} \sum_{i=1}^N (X_i - \bar{X})^2 \quad (16)$$

$$SNR = -20 \log \left( \sqrt{\frac{\sum_{i=1}^N (X_i - \bar{X})^2}{\sum_{i=1}^N X_i^2}} \right) \quad (17)$$

$$PSNR = 10 \log \left( \frac{(\max(|X_i|))^2}{MSE} \right) \quad (18)$$

donde  $N$  es la cantidad de muestras de la señal, el vector  $X$  representa la señal original y  $\bar{X}$  representa a la señal una vez tratada con los algoritmos propuestos.

En todos los casos se emplea la transformada wavelet Cohen-Daubechies-Feauveau (CDF-2.2) con cinco niveles de descomposición, y el ruido presente en la señal se estima mediante la expresión (9). En (Leigh et al., 2011) se analizan otros estimadores del nivel de ruido y se hace una amplia discusión acerca de la efectividad de cada uno de ellos en el contexto de la reducción de ruido.

### 5.1. Descripción de los resultados

Las Figuras 1 y 2 muestran las señales utilizadas en los experimentos, y las Tablas 1, 2, 3, 4, 5, 6, 7, 8, 9 y 10 recogen los resultados de las pruebas realizadas sobre el conjunto de señales seleccionado (Blocks, Nivel de crudo, Heavisine, Presión 007, Presión A, Temperatura 4, Temperatura 057, Temperatura TH4, Rata de flujo y Bumps), resaltándose en negrita los mejores valores de MSE, SNR y PSNR en cada caso.

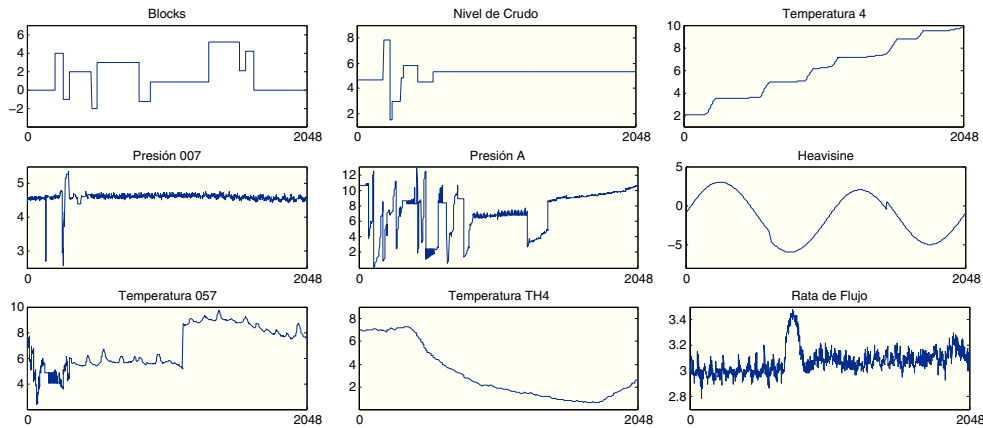


Figura 1: Señales de prueba utilizadas en la reducción de ruido

Tabla 1: Señal Blocks. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00967354	34.4642	27.9732
	Normal	0.00771855	35.4447	28.9537
	Modified	0.00843808	35.0576	28.5666
	Neight	<b>0.00237133</b>	<b>40.5702</b>	<b>34.0791</b>
0.03	Bayes	0.042823	28.0033	21.5123
	Normal	0.016474	32.1521	25.6611
	Modified	0.0250273	30.3359	23.8449
	Neight	<b>0.0155454</b>	<b>32.404</b>	<b>25.913</b>
0.06	Bayes	0.0317046	29.3088	22.8178
	Normal	0.0570075	26.7607	20.2697
	Modified	0.0219013	30.9154	24.4243
	Neight	<b>0.00715184</b>	<b>35.7759</b>	<b>29.2849</b>

Tabla 3: Señal HeaviSine. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00247458	41.628	36.1436
	Normal	0.00119642	44.7842	39.2998
	Modified	<b>0.00103207</b>	<b>45.4259</b>	<b>39.9416</b>
	Neight	0.00125645	44.5716	39.0872
0.03	Bayes	0.00968315	35.7029	30.2185
	Normal	<b>0.00606056</b>	<b>37.7379</b>	<b>32.2535</b>
	Modified	0.00806939	36.4946	31.0102
	Neight	0.00622292	37.6231	32.1387
0.06	Bayes	0.0025786	41.4492	35.9648
	Normal	0.00351602	40.1025	34.6181
	Modified	0.00261295	41.3917	35.9073
	Neight	<b>0.00249157</b>	<b>41.5983</b>	<b>36.1139</b>

Tabla 2: Señal Nivel de Crudo. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.0120341	37.1048	33.5985
	Normal	0.00868121	38.5232	35.0168
	Modified	0.00796543	38.8969	35.3905
	Neight	<b>0.00178139</b>	<b>45.4014</b>	<b>41.895</b>
0.03	Bayes	0.0268172	33.6248	30.1185
	Normal	0.0171679	35.5618	32.0554
	Modified	0.0215	34.5846	31.0782
	Neight	<b>0.00856307</b>	<b>38.5827</b>	<b>35.0763</b>
0.06	Bayes	0.0231891	34.2561	30.7498
	Normal	0.0262456	33.7184	30.212
	Modified	0.0164169	35.7561	32.2497
	Neight	<b>0.00402496</b>	<b>41.8613</b>	<b>38.355</b>

Tabla 4: Señal Presión 007. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00557311	37.1456	35.7823
	Normal	0.00430722	38.2646	36.9013
	Modified	0.00479596	37.7978	36.4345
	Neight	<b>0.00244478</b>	<b>40.7242</b>	<b>39.3609</b>
0.03	Bayes	0.0137151	33.2346	31.8713
	Normal	<b>0.00885652</b>	<b>35.1339</b>	<b>33.7706</b>
	Modified	0.0147272	32.9254	31.5621
	Neight	0.00952357	34.8186	33.4553
0.06	Bayes	0.00630032	36.6129	35.2496
	Normal	0.00693613	36.1954	34.8321
	Modified	0.00636058	36.5716	35.2083
	Neight	<b>0.00411316</b>	<b>38.4648</b>	<b>37.1015</b>

Tabla 5: Señal Presión A. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00942653	42.4693	38.0349
	Normal	0.00904945	42.6466	38.2122
	Modified	0.00913394	42.6063	38.1719
	Neight	<b>0.0079409</b>	<b>43.2141</b>	<b>38.7798</b>
0.03	Bayes	0.0583009	34.5561	30.1217
	Normal	0.0438829	35.7899	31.3555
	Modified	0.0493127	35.2833	30.8489
	Neight	<b>0.0302719</b>	<b>37.4024</b>	<b>32.9681</b>
0.06	Bayes	0.0291107	37.5723	33.1379
	Normal	0.024079	38.3965	33.9621
	Modified	0.0259744	38.0674	33.633
	Neight	<b>0.017633</b>	<b>39.7496</b>	<b>35.3152</b>

Tabla 6: Señal Temperatura 4. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00106797	49.5273	46.0244
	Normal	0.000934228	50.1084	46.6054
	Modified	0.00108444	49.4609	45.9579
	Neight	<b>0.000862353</b>	<b>50.4561</b>	<b>46.9531</b>
0.03	Bayes	0.00781709	40.8825	37.3795
	Normal	<b>0.00277189</b>	<b>45.3852</b>	<b>41.8822</b>
	Modified	0.00505655	42.7744	39.2714
	Neight	0.00381226	44.0011	40.4981
0.06	Bayes	0.00249313	45.8455	42.3425
	Normal	<b>0.00211388</b>	<b>46.5621</b>	<b>43.0591</b>
	Modified	0.00219285	46.4028	42.8999
	Neight	0.00234571	46.1102	42.6072

Tabla 7: Señal Temperatura 057. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00939749	40.0019	37.2416
	Normal	0.0067311	41.4511	38.6908
	Modified	0.00754242	40.9569	38.1966
	Neight	<b>0.00350625</b>	<b>44.2836</b>	<b>41.5233</b>
0.03	Bayes	0.0335442	34.4758	31.7155
	Normal	0.0277723	35.2959	32.5356
	Modified	0.0324598	34.6185	31.8582
	Neight	<b>0.0168431</b>	<b>37.4678</b>	<b>34.7075</b>
0.06	Bayes	0.0245426	35.8328	33.0725
	Normal	0.0165178	37.5525	34.7922
	Modified	0.0186794	37.0184	34.2581
	Neight	<b>0.00815669</b>	<b>40.6169</b>	<b>37.8565</b>

Tabla 8: Señal Temperatura TH4. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00230806	43.5829	38.2359
	Normal	0.00166696	44.9961	39.6491
	Modified	0.00178893	44.6895	39.3424
	Neight	<b>0.00159649</b>	<b>45.1837</b>	<b>39.8367</b>
0.03	Bayes	0.0172551	34.8462	29.4991
	Normal	0.00663495	38.997	33.65
	Modified	0.0124964	36.2475	30.9005
	Neight	<b>0.00554178</b>	<b>39.7789</b>	<b>34.4318</b>
0.06	Bayes	0.00252301	43.1962	37.8492
	Normal	<b>0.00234196</b>	<b>43.5196</b>	<b>38.1725</b>
	Modified	0.00269691	42.9067	37.5597
	Neight	0.00240762	43.3995	38.0525

Tabla 9: Señal Rata de Flujo. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00279998	36.3638	35.2848
	Normal	0.0019648	37.9022	36.8232
	Modified	0.00257259	36.7316	35.6527
	Neight	<b>0.00190969</b>	<b>38.0257</b>	<b>36.9467</b>
0.03	Bayes	0.0122376	29.9584	28.8794
	Normal	<b>0.00479431</b>	<b>34.0281</b>	<b>32.9491</b>
	Modified	0.00998418	30.8422	29.7632
	Neight	0.00681275	32.5021	31.4231
0.06	Bayes	0.00299466	36.0719	34.9929
	Normal	0.00245179	36.9405	35.8615
	Modified	0.00262572	36.6429	35.5639
	Neight	<b>0.0024441</b>	<b>36.9541</b>	<b>35.8752</b>

Tabla 10: Señal Bumps. Comparación de diferentes esquemas para reducir ruido gaussiano con varianza  $\sigma^2=0.01$ ,  $\sigma^2=0.03$  y  $\sigma^2=0.06$ .

Ruido	Algoritmo	MSE	SNR	PSNR
0.01	Bayes	0.00452094	37.5182	20.6187
	Normal	0.00366656	38.4279	21.5284
	Modified	0.00356645	38.5481	21.6486
	Neight	<b>0.00212495</b>	<b>40.797</b>	<b>23.8975</b>
0.03	Bayes	0.0149625	32.3204	15.4209
	Normal	0.0290999	29.4315	12.532
	Modified	0.0150245	32.3025	15.403
	Neight	<b>0.0122962</b>	<b>33.1727</b>	<b>16.2732</b>
0.06	Bayes	0.0112352	33.5646	16.6651
	Normal	0.0395668	28.0971	11.1976
	Modified	0.012865	32.9764	16.0769
	Neight	<b>0.00663921</b>	<b>35.8493</b>	<b>18.9498</b>



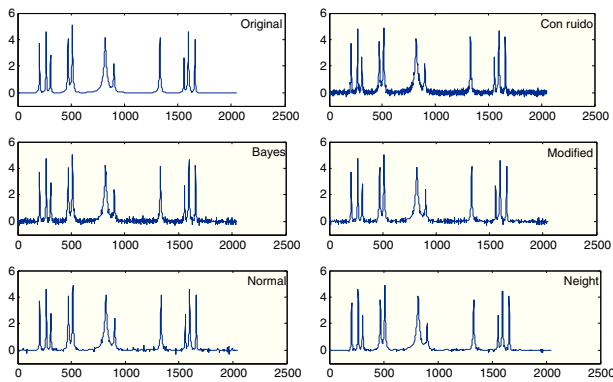


Figura 2: Señal Bumps. Representación gráfica luego de aplicar los diferentes algoritmos para reducir ruido con varianza  $\sigma^2=0.01$

En la Figura 2 se aprecia que la señal filtrada utilizando el esquema Neigh Shrink es la que mejor mantiene las características de la señal original.




Figura 3: Rendimiento de los diferentes esquemas de reducción de ruido basado en el PSNR promedio de las señales analizadas. El esquema Neigh Shrink alcanza, para los tres niveles de ruido, mayores valores de PSNR promedio

## 6. Conclusiones

Los resultados obtenidos, a partir de las pruebas empíricas realizadas que se muestran en las tablas previas y en la Figura 3, indican que el esquema Neigh Shrink exhibe, como promedio, mejor rendimiento que el resto de los esquemas, tanto sobre el conjunto de funciones definidas por Donoho (Donoho et al., 1993), como en las señales obtenidas de procesos reales.

## English Summary

### Comparative review of denoising techniques for industrial signals using Discrete Wavelet Transform and adaptive threshold selection

#### Abstract

Noise reduction techniques are widely used for audio recording, image editing, and industrial signal processing. The idea is to reconstruct the original data from the noise-corrupted

signal suppressing, all or almost all, the distortion caused by the inherent noise of the physical processes. In the present paper, we perform a comparative review of several noise reduction techniques based on adaptive threshold selection. These techniques have been extensively used for image processing. However, we aimed at evaluating their performance for industrial signal noise reduction. In particular, we analyze the behaviour of the Bayes Shrink, Normal Shrink, Modified Shrink, and Neigh Shrink methods for the reduction of the Gaussian noise in industrial signals. To that aim, we perform experiments on a set of pattern signals proposed by Donoho and other representative measurements obtained from real processes in Cuban's Nickel plants. Our results indicate that, for this kind of data, the Neigh Shrink algorithm outperforms the other techniques.

**Keywords:** wavelet transform, noise, industrial signals.

## Agradecimientos

El trabajo ha sido patrocinado por:

- Universidad de las Ciencias Informáticas (UCI).
- Instituto Superior Minero Metalúrgica de Moa (ISMM).

## Referencias

- Chang, S. G., Yu, B., Vetterli, M., 2000. Adaptive wavelet thresholding for image denoising and compression. *IEEE Transactions on Image Processing* 9 (9), 1532–1546.
- Dolabdjian, C., Fadili, J., Leyva, E. H., 2002. Classical low-pass filter and real-time wavelet-based denoising technique implemented on a DSP: a comparison study. *The European Physical Journal Applied Physics* 20, 135–140.
- Donoho, D., Johnstone, I., Johnstone, I. M., 1993. Ideal spatial adaptation by wavelet shrinkage. *Biometrika* 81, 425–455.
- Donoho, D., Johnstone, I. M., 1995. Adapting to unknown smoothness via wavelet shrinkage. *Journal of the American Statistical Association* 90, 1200–1224.
- Elyasi, I., Zarmehi, S., 2009. Elimination noise by adaptive wavelet threshold. *World Academy of Science, Engineering and Technology* 56, 56–86.
- Kaur, L., Gupta, S., Chauhan, R. C., 2002. Image denoising using wavelet thresholding. In: *Indian Conference on Computer Vision, Graphics and Image Processing*, Ahmedabad.
- Leigh, A., Wong, A., Clausi, D. A., Fieguth, P., 2011. Comprehensive analysis on the effects of noise estimation strategies on image noise artifact suppression performance. *Proceedings of the IEEE International Symposium on Multimedia ISM '11*, 97–104.
- Rioul, O., Vetterli, M., Oct. 1991. Wavelet and signal processing. *IEEE Signal processing Magazine* 8 (4), 14–38.
- Sihag, R., Sharma, R., Setia, V., 2011. Wavelet thresholding for image de-noising. *IJCA Proceedings on International Conference on VLSI, Communications and Instrumentation (ICVCI)* (14), 20–24, published by Foundation of Computer Science.
- Solano, J. J. P., 2002. Supresión de interferencias mediante transformadas wavelet en sistemas de comunicación con espectro ensanchado por salto de frecuencia. Ph.D. thesis, Universidad de Valencia.
- Xia, R., Meng, K., Qian, F., Wang, Z.-L., 2007. Online wavelet denoising via a moving window. *Acta Automatica Sinica* 33 (9), 897 – 901.