

## MITIGACIÓN DE RUIDO IMPULSIVO MEDIANTE TÉCNICAS DE CONTROL ACTIVO CON FILTRO ADAPTATIVO BASADO EN KERNEL

**Baldini, Patricia N.**

Grupo SITIC  
Faculta Regional Bahía Blanca  
Universidad Tecnológica Nacional  
11 de Abril 461 – B8000LMI Bahía Blanca  
e-mail: pnbaldi@frbb.utn.edu.ar

**Resumen.** *El control activo es una metodología que ha demostrado ser efectiva para atenuar ruido acústico en el rango espectral de baja frecuencia. Su principio de funcionamiento es la interferencia destructiva en una región acotada del espacio, superponiendo al ruido ondas de sonido generadas de modo controlado por dispositivos electroacústicos que copian su magnitud pero en contrafase. El caso particular del ruido impulsivo, tan nocivo como frecuente tanto en ambientes laborales e industriales como en la vida cotidiana, representa un desafío a la estabilidad del algoritmo de control que aún es motivo de estudio. Los valores atípicos en las señales medidas provocan sobrecorrecciones en el ajuste adaptativo de los pesos del controlador, lo que puede producir inestabilidad. En este trabajo se presenta los resultados de la aplicación de una nueva metodología robusta para atenuar el ruido impulsivo en un sistema monocanal. Se propone el uso de un algoritmo de filtrado adaptativo basado en kernel que no requiere información estadística de la señal a procesar. Este tipo de algoritmos de procesamiento basados en la teoría de la información tiene asociada una complejidad computacional similar a la de metodologías tradicionales pero han demostrado mejores propiedades de convergencia y error estacionario en presencia de ruido no Gaussiano en diversas aplicaciones tales como identificación de sistemas y predicción de estado. El ruido impulsivo se caracteriza mediante el modelo alfa-estable simétrico. Las propiedades de velocidad de convergencia, robustez frente a alta impulsividad así como la efectividad del control se verifican comparativamente mediante simulación en diferentes ambientes de ruido no estacionario.*

**Palabras clave:** Ruido Impulsivo, Control Activo, Filtros Adaptativos basados en Kernel, Optimización Robusta.

## 1. INTRODUCCIÓN

El ruido acústico provocado por la actividad humana representa un contaminante ambiental de alto impacto en la salud pública. Sus efectos nocivos afectan gravemente la calidad de vida de las personas tanto desde el punto de vista físico como psicológico. Como consecuencia, resulta indispensable desarrollar técnicas y metodologías eficientes para garantizar la reducción de la exposición en el tiempo a niveles sonoros excesivos, no solo en ambientes laborales sino también en diferentes espacios urbanos.

Uno de los componentes fundamentales de la gestión del ruido es el diseño de mecanismos para su control y reducción. Los métodos convencionales orientados en esa dirección son los conocidos como técnicas pasivas por no requerir aporte de energía. Básicamente, se utilizan barreras físicas para bloquear la propagación de las ondas de sonido o materiales absorbentes para atenuar la energía acústica directa y reverberante. Sin embargo, cuando las longitudes de onda de la señal a silenciar crecen dentro del espectro audible, el incremento significativo en volumen y costo torna ineficiente al abordaje pasivo. En todo caso, carece de la flexibilidad suficiente para contemplar cambios temporales del entorno acústico o de la fuente de ruido. Para superar estos inconvenientes se ha propuesto el control activo (*ANC*) que busca transformar favorablemente el campo sonoro inicial en regiones espaciales acotadas, mediante el uso de dispositivos electroacústicos. Se trata de generar nuevas ondas de sonido (*anti-ruido*) de forma controlada que se superponen al campo ruidoso original. Por interferencia destructiva se logra una zona de silencio en regiones del espacio tanto más grandes cuanto mayores sean las longitudes de onda del ruido a cancelar (Elliot, 2001).

Los avances en la tecnología de los procesadores digitales de señal sumados al desarrollo de eficientes algoritmos de procesamiento adaptativo, permitieron la implementación de sistemas de *ANC* eficaces en distintas aplicaciones. De todos modos, el caso de ruido de impacto o impulsivo representa aún un desafío que sigue siendo motivo de estudio. Este tipo de ruido se caracteriza por un número significativo de perturbaciones sonoras de gran intensidad y corta duración que ocurren al azar con una baja probabilidad y no puede describirse mediante un modelo gaussiano. La presencia de esos valores atípicos compromete la convergencia de los algoritmos adaptativos basados en momentos de segundo orden, pudiendo causar inestabilidad. Se han propuesto diversos métodos para superar esta limitación que pueden clasificarse en tres categorías. La primera incluye a los algoritmos que suavizan el efecto de los valores atípicos sobre la actualización de parámetros del controlador mediante el empleo de transformaciones no lineales con crecimiento acotado (Akhtar y Mitsuhashi, 2009; Akhtar, 2017; Liang *et al.*, 2021). La segunda categoría incluye a los algoritmos basados en la minimización del momento fraccional de orden  $p$  ( $p < 2$ ) del error residual, teniendo en cuenta que no existen los de segundo orden para la descripción estadística del ruido impulsivo (Bergamasco *et al.*, 2012). Recientemente han adquirido relevancia algoritmos de control que pueden encuadrarse en una nueva categoría sustentada en el aprendizaje basado en la Teoría de la Información, que no requieren conocimiento a priori de las características estadísticas del ruido (*ITL*). En particular, uno de los criterios de optimización más populares debido a su simplicidad y robustez es la maximización de la correntropía (*MCC*). De todos modos, los resultados son altamente dependientes de la selección adecuada del ancho del kernel (Wang *et al.*, 2017; Lu y Zhao, 2017; Huang *et al.*, 2017).

En este trabajo se propone un algoritmo robusto para la actualización de los parámetros del

filtro adaptativo, que minimiza una función de costo sensible al riesgo en el espacio inducido por el kernel que, a conocimiento propio, no se ha aplicado en aplicaciones de ANC. En base al algoritmo presentado por Chen y Wang (2015) se plantea incluir la variación automática del ancho del kernel en base a la medida del error de filtrado. El algoritmo resultante presenta buenas características de convergencia y error de estado estacionario en situaciones de señales de ruido no Gaussiano, con alto grado de impulsividad, no estacionario, para sistemas de fase mínima y no mínima. Los resultados se analizan mediante simulaciones en base a los índices de comportamiento usuales. El ruido impulsivo se modela mediante una distribución alfa-estable simétrica (S $\alpha$ S).

## 2. DESCRIPCIÓN DEL SISTEMA Y DE LA METODOLOGÍA ADOPTADOS

### 2.1. Configuración básica de un sistema de ANC

El ANC se basa en el principio de interferencia destructiva entre ondas acústicas. Esencialmente, el ruido se cancela en una determinada región del espacio al superponerle otro generado en forma controlada de igual amplitud pero en contrafase.

La configuración feedforward básica de un sistema de ANC de un solo canal comprende (Figura 1): un sensor de referencia para captar el ruido fuente o primario,  $x(n)$ ; un parlante que actúa como transductor electroacústico para convertir en ondas sonoras de cancelación,  $y(n)$ , la señal eléctrica de control generada por el filtro adaptativo con función transferencia  $H(z)$ , y un micrófono de error para detectar el nivel de ruido residual,  $e(n)$ , en la zona de silencio predeterminada (Elliot, 2001).

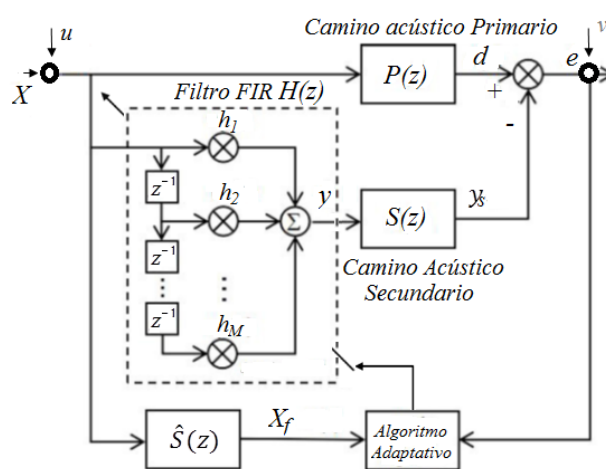


Figura 1. Esquema del sistema de ANC monocanal de tipo *feedforward*.

La efectividad de la cancelación dependerá de la precisión con la que se estimen la amplitud y la fase del *anti-ruido* por lo que se recurre a un control adaptativo. En este tipo de control se deben establecer la estructura del controlador o filtro y el algoritmo que optimiza sus parámetros iterativamente, en tiempo real, en base a la información proveniente de los sensores. En general se adoptan filtros de respuesta de impulso finito (*FIR*) por su estabilidad mientras que el algoritmo se selecciona de acuerdo al tipo de ruido a cancelar.

En términos generales, un filtro adaptativo tiene como objetivo ajustar secuencialmente un sistema desconocido utilizando las observaciones disponibles. El valor cuadrático medio del

error de filtrado se usa ampliamente como un costo de adaptación debido a su convexidad, suavidad, simplicidad, bajo la suposición implícita de que el error resultante es una variable aleatoria de tipo gaussiano, justificada por el teorema del límite central.

Para una estructura de filtro *FIR* de longitud  $L$ , con vector de salida  $\mathbf{y}$ ,  $\mathbf{y}(k)=[y(k) \ y(k-1)\cdots y(k-L+1)]^T$ , donde  $[\cdot]^T$  denota transposición, el error residual queda definido por

$$e(k) = d(k) - \mathbf{S}^T \mathbf{y}(k) + v(k) \quad (1)$$

$$\mathbf{y}(k) = \mathbf{H}^T(k) \mathbf{x}(k) \quad , \quad d(k) = \mathbf{P}(k)^T \mathbf{x}(k)$$

$\hat{\mathbf{S}}$ ,  $\mathbf{S}$  y  $\mathbf{P}$  son los vectores de las respuestas al impulso estimada y real del camino acústico secundario, y real del camino acústico primario, modelados por las funciones transferencias  $\hat{S}(z)$ ,  $S(z)$  y  $P(z)$ , respectivamente. Los procesos aleatorios  $\mathbf{u}(k)$  y  $v(k)$  representan, respectivamente, ruido de medida de la señal de entrada y del error residual y  $x_f(k) = \hat{\mathbf{S}}^T(k)(\mathbf{x}(k) + \mathbf{u}(k))$  es la señal de entrada filtrada por la estimación (fuera de línea) de la respuesta impulsiva del camino secundario.

Cuando el ruido a cancelar es de tipo impulsivo, la gran amplitud ocasional en las señales medidas produce una actualización repentina significativa de coeficientes del filtro que puede comprometer la convergencia e inestabilizar al sistema. Si bien se han propuesto distintas estrategias para superar estas limitaciones, el obstáculo común para implementarlas en la práctica es la complejidad computacional asociada, la respuesta insatisfactoria para procesos no lineales y/o la alta dependencia con los parámetros de ajuste.

## 2.2. Filtrado adaptativo basado en kernel

En los filtros adaptativos se fija una estructura, generalmente la *FIR*, mientras que los coeficientes se ajustan iterativamente en tiempo real en función de la información proveniente de los sensores, en cada instante de muestreo. El proceso de actualización se efectúa de modo de optimizar una función de costo basada en alguna medida de similitud estadística entre las salidas deseada y real del filtro. Entre las medidas conocidas, las más populares debido a su simplicidad y buen desempeño, son las basadas en estadísticas de segundo orden como el error cuadrático medio. Desafortunadamente, la eficacia de estos algoritmos se pierde cuando se trata con procesos no lineales y señales no gaussianas y no estacionarias. Particularmente, los momentos de segundo orden no existen para ruido de tipo impulsivo (Bergamasco *et al.*, 2012). Por lo tanto, resulta indispensable considerar criterios robustos que contemplen esta característica.

En los últimos años, el aprendizaje basado en la *ITL* se ha desarrollado como un marco de aprendizaje alternativo con relación directa con los métodos basados en kernels (Príncipe, 2010). Más específicamente, la mayoría de las medidas de similitud desarrolladas en la *ITL* se pueden describir eficientemente en un nuevo espacio de mayor dimensionalidad inducido por un kernel de Mercer, denominado espacio de Hilbert con kernel reproductor (*RKHS*). Este enfoque se basa en el teorema de representación y el denominado “truco del núcleo”. Se emplea una transformación no lineal sobre el espacio de entrada al que pertenecen las muestras, como biyección al *RKHS* lo que facilita la extracción de la información contenida en los datos. En este nuevo espacio se aplican los métodos de actualización convencionales

resultando un filtro no lineal en el espacio original. Para la implementación, se tiene la ventaja de que solo es necesario conocer el kernel que puede ser aplicado directamente al vector de muestras. No se requiere la representación explícita de la transformación ni de los vectores transformados.

En el marco de *ITL*, las métricas de aprendizaje se definen como funciones que contienen toda la información estadística de los datos. El estimador no paramétrico de ventanas de Parzen permite determinar elegantemente la densidad de probabilidad a partir de las muestras, lo que hace que estas métricas sean adecuadas en aprendizaje en tiempo real.

Un ejemplo que se ha utilizado en control activo de ruido impulsivo (*AINC*) es la correntropía, definida como una medida de la similitud local entre dos variables aleatorias sobre una ventana de observación determinada por el ancho de banda del kernel. En el *RKHS*, representa una métrica local que generaliza a la correlación. El ancho de banda del kernel permite reducir el efecto de valores atípicos y ruido impulsivo dotando a los algoritmos de optimización asociados de robustez (Wang *et al.*, 2017; Lu y Zhao, 2017). De todos modos, la superficie de performance de la pérdida correntrópica en el espacio paramétrico puede ser muy pronunciada entorno a la solución óptima y extremadamente plana en una región alejada, con consecuencias desfavorable en la velocidad de convergencia y la exactitud estacionaria.

Recientemente se derivó una medida de similitud modificada llamada pérdida sensible al riesgo en el espacio kernel (*KRSL*, Chen y Wang, 2015; Chen *et al.*, 2017), que ha demostrado lograr una velocidad de convergencia mayor con mejor precisión de filtrado, manteniendo la robustez frente a valores atípicos en varias aplicaciones (Niu *et al.* 2021, Ma *et al.* 2022). Sin embargo, fijar el ancho del kernel sigue siendo crucial. En el presente trabajo se propone emplear un nuevo algoritmo para el filtrado adaptativo para el *AINC* monocanal, basado en una modificación del *KRSL* que muestra en las simulaciones buenos resultados y soluciona efectivamente los inconvenientes.

### 2.3. Función de Costo Sensible al Riesgo en el Espacio del Kernel

El criterio sensible al riesgo utiliza como función de costo a minimizar la esperanza del cuadrado del error de filtrado pesado exponencialmente, evaluado en el *HSRK* usando el “truco del kernel”. La robustez frente a impulsos se induce al evitar actualizaciones inapropiadas enfatizando los errores mayores en forma exponencial en la cuantificación de la similitud de las dos variables aleatorias. En Boel *et al.* (2002) se puede encontrar una interpretación precisa sobre la eficacia de los filtros sensibles al riesgo frente a outliers. Las cuestiones fundamentales sobre la existencia y unicidad de la estimación bajo este criterio se han estudiado en Chen *et al.* (2017). Los métodos basados en kernel han sido ampliamente usados en procesamiento de señales. El kernel (invariante al desplazamiento) representa el producto interno en el espacio de características o *HSRK*, al que se mapean los datos mediante la transformación implícita  $\varphi(\cdot)$ . La función de costo para el entrenamiento del sistema adaptativo puede ser estimada directamente a partir de las medidas usando el estimador de Parzen. Generalmente se adopta un kernel Gaussiano con ancho de banda  $\sigma$  ( $>0$ ), para las variables aleatorias  $d$  e  $y$  con distribución conjunta  $F_{DY}$ , según la expresión

$$\begin{aligned} \kappa(d - y) &= \varphi(d)^T \varphi(y) \\ \kappa(d - y) &= G_\sigma(d - y) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(d - y)^2}{2\sigma^2}\right). \end{aligned} \tag{2}$$

En el espacio de entrada asociado a los datos, aplicando el truco del kernel (ecuación (2)) como se detalla en Chen *et al.* (2017), se llega a :

$$\begin{aligned} J_{KRSL} &= \frac{1}{\lambda} E \left[ \exp \left( \lambda (1 - G_{\sigma}(d - y)) \right) \right] = \\ &= \frac{1}{\lambda} \int \exp \left( \lambda (1 - G_{\sigma}(d - y)) \right) dF_{DY}(d, y) \end{aligned} \quad (3)$$

donde  $\lambda$  es un parámetro de ajuste adicional sensible al riesgo.

En las aplicaciones a ANC solo se dispone de un número finito de muestras  $\{e_k = d_k - y_k\}_{n}^{N+n}$  de modo que se recurre a la aproximación:

$$J_{KRSL} = \frac{1}{\lambda N} \sum_{k=n}^{n+N} \exp \left( \lambda (1 - G_{\sigma}(e_k)) \right) \quad (4)$$

Esta función empírica puede ser considerada como una distancia entre los vectores de valores deseados  $[d_n \ \cdots \ d_{N+n}]^T$  y valores obtenidos  $[y_n \ \cdots \ y_{N+n}]^T$ .

La superficie de performance en el espacio paramétrico es acotada lo que da la robustez, aplanada cerca del óptimo reduciendo desajustes estacionarios y resulta abrupta lejos del óptimo acelerando la convergencia como puede observarse para el caso de un vector de parámetros bidimensional en la Figura 2 donde se la compara con la de MCC (Chen *et al.*, 2017).

La relación establecida por la transformación  $\phi$  entre la medida instantánea de similaridad conocida como LRS,  $J_{RSL}$ , y su versión “kernelizada” (en el HSRK),  $J_{KRSL-H}$ , se muestra en las expresiones dadas en (5).

$$J_{RSL} = \frac{1}{\tilde{\lambda}} E \left[ \exp \left( \tilde{\lambda} \|d - y\|^2 \right) \right] \Rightarrow J_{KRSL-H} = \frac{1}{\tilde{\lambda}} E \left[ \exp \left( \tilde{\lambda} \|\phi(d) - \phi(y)\|_H^2 \right) \right] \quad (5)$$

Si se emplea un método convencional de búsqueda del óptimo basado en el gradiente, el vector de coeficientes del filtro,  $\mathbf{H}$ , se actualizan según (6), ( $\mu$  es el paso de actualización).

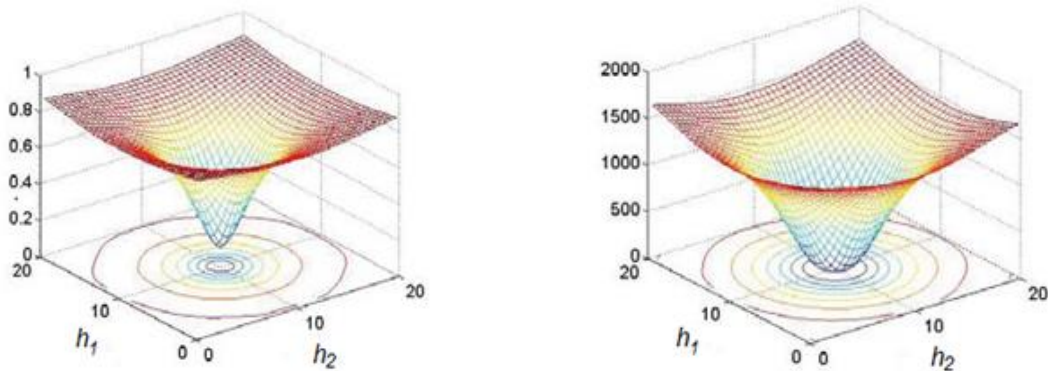
$$\mathbf{H}_k = \mathbf{H}_{k-1} - \tilde{\mu} \frac{\partial J_{KRSL}}{\partial \mathbf{H}} = \mathbf{H}_{k-1} + \frac{\tilde{\mu}}{N\sigma^2} \sum_{i=n}^{N+n} \exp \left[ \lambda (1 - G_{\sigma}(e_i)) - \frac{e_i^2}{2\sigma^2} \right] e_i \mathbf{x}_i \quad (6)$$

De todos modos, para el algoritmo en tiempo real se toman valores instantáneos (N=1) para aproximar la esperanza (ecuación (7)).

$$\mathbf{H}_k = \mathbf{H}_{k-1} + \mu \exp \left[ \lambda (1 - G_{\sigma}(e_k)) \right] G_{\sigma}(e_k) e_k \mathbf{x}_k \quad (7)$$

#### 2.4. Algoritmo KRSL con ancho de kernel variable para AINC propuesto

En este trabajo se propone usar un filtro adaptativo basado en KRSL para ajustar los coeficientes del filtro que pretende mejorar la estabilidad y el comportamiento estacionario en ambientes de ruido desfavorables, sin incrementar el almacenamiento ni aumentar significativamente el costo de cómputo. Considerando el efecto determinante del ancho del



**Figura 2:** Superficies de performance para *C-Loss* y *KRSI* ambos con  $\sigma=2$ .

kernel en el balance entre la velocidad de convergencia y la precisión estacionaria se incorpora una variación automática en función de la magnitud del error

$$\sigma_{k+1} = \eta\sigma_k + (1 - \eta)|e_k| \tag{8}$$

donde  $\eta$  es el factor de olvido. El algoritmo resultante se muestra en la **Tabla 1**.

**Tabla 1.** Algoritmo *KRSI* con paso variable propuesto.

---

Input:  $\eta, \lambda, \mu, \hat{S}$

---

Initialize:  $\sigma^2_0, \mathbf{P}(0), \mathbf{H}(0)$

while {  $x(k), e(k)=e_k$  } available

$$\mathbf{x}_{fk} = \mathbf{x}_f(k) = \hat{S}^T \mathbf{X}(k)$$

$$G_{\sigma k} = \exp\left(-\frac{e_k^2}{2\sigma_k^2}\right)$$

$$\mathbf{H}(k+1) = \mathbf{H}(k) + \mu \exp[\lambda(1 - G_{\sigma k})] G_{\sigma k} e_k \frac{\mathbf{x}_{fk}}{\mathbf{x}_{fk}^T \mathbf{x}_{fk} + \epsilon}$$

$$\sigma_{k+1} = \eta\sigma_k + (1 - \eta)|e_k|$$

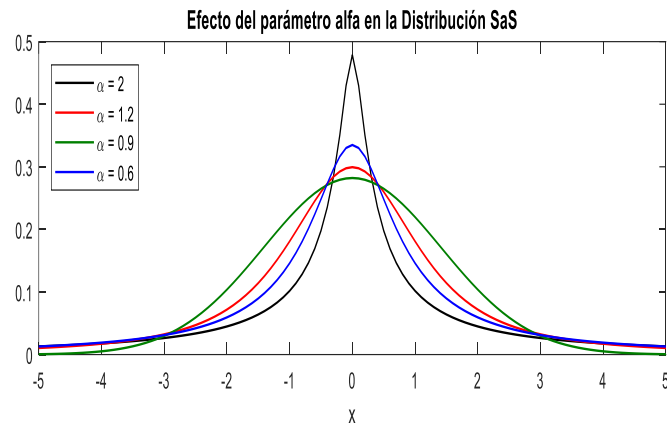
end while

Output:  $\mathbf{H}^* = \mathbf{H}(k+1)$

---

### 2.5. Modelo Estadístico del Ruido Impulsivo

El ruido impulsivo se caracteriza por la aparición de muestras de gran valor con baja probabilidad de ocurrencia. En la literatura reciente sobre *AINC*, es una práctica habitual modelar este tipo de ruido no gaussiano usando una distribución alfa-estable simétrica (S $\alpha$ S). Un proceso aleatorio es S $\alpha$ S si su función característica se puede expresar como  $\varphi(x) = e^{-\gamma|x|^\alpha}$ , donde  $\gamma (>0)$  es el parámetro de dispersión y  $\alpha (1 < \alpha \leq 2)$  es el exponente característico. En particular, se considera que la fuente de ruido se modela mediante una distribución S $\alpha$ S estándar ( $\gamma=1$ ), donde el grado de impulsividad será tanto mayor cuanto menor sea el exponente característico  $\alpha$  (Figura 3).




**Figura 3.** Función distribución de probabilidad SaS en función de  $\alpha$ .

El caso particular de  $\alpha=2$  corresponde a la distribución Gaussiana que es la única que admite momento de segundo orden finito. En el resto de los casos de ( $\alpha < 2$ ) solo existen momentos de orden fraccional  $p < \alpha$ .

### 3. RESULTADOS Y DISCUSIÓN

#### 3.1. Análisis mediante simulación del efecto de parámetros de ajuste

Los resultados de diferentes valores del ancho del kernel y del parámetro sensible al riesgo en



a) Variación del valor fijo de ancho del kernel

b) Variación del valor del parámetro sensible al riesgo

**Figura 4.** Convergencia para diferentes valores de los parámetros de ajuste.

el algoritmo *KRSL* clásico para un caso típico de simulación (*FT* de *FM*) se muestran en la Figura 4. Puede observarse la influencia sobre la velocidad de convergencia y el valor estacionario en cada caso. Esto fue empleado para adoptar valores apropiados en las siguientes experiencias.

#### 3.2. Experimentos de simulación

Los resultados de aplicar el algoritmo *KRSL* y la modificación propuesta (*KRSLmodif*) fueron analizados, en una primera instancia, mediante simulación computacional utilizando la plataforma *Matlab*. Se consideraron distintas experiencias consistentes en variar el grado de impulsividad del ruido primario mediante el parámetro  $\alpha$ , incluyendo casos que contemplan su variación en el tiempo.



La velocidad de convergencia se evalúa mediante el índice de desempeño propuesto en la bibliografía (Akhtar y Mitsuhashi, 2009; Bergamasco *et al.*, 2012; Lu y Zhao; 2017), que calcula la reducción de ruido promedio,  $RRP$ , mediante estimadores de promedio móvil definidos por las ecuaciones (9) y (10):

$$RRP(n) = 20 \log_{10} \left( \frac{A_e(n)}{A_d(n)} \right) \tag{9}$$

donde

$$\begin{aligned} A_e(n) &= \lambda A_e(n-1) + (1-\lambda) |e(n)| \\ A_d(n) &= \lambda A_d(n-1) + (1-\lambda) |d(n)| \end{aligned} \tag{10}$$

El valor adoptado del factor de olvido es  $\lambda = 0.99$ , y se realiza un promediado sobre una serie de 20 conjuntos independientes de datos de entrenamiento aleatoriamente generados.

La estimación del camino secundario se realiza fuera de línea, previa a la aplicación del control y la longitud del filtro  $FIR$  de control se fija en  $L=16$ . En todo caso se hace la comparación de resultados con los del algoritmo  $MCC$  con ancho de kernel variable.

### 3.2.1. Primer experimento. Ruido estacionario

En esta experiencia se considera un ruido altamente impulsivo, con  $\alpha = 1.2$  (Figura 5) y funciones transferencia ( $FT$ ) de los caminos acústicos primario y secundario de fase mínima ( $FM$ ) (Figura 6 a) y de fase no mínima ( $FNM$ ) (Figura 6 b).




Figura 5. Ruido impulsivo a cancelar, señal de cancelación y ruido residual para  $FT FM$ .

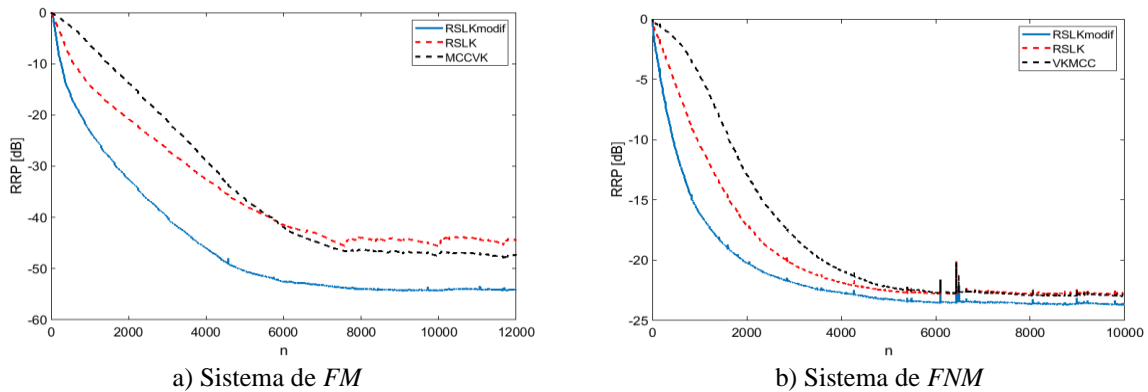


Figura 6. Comparación de  $RRP$  para algoritmos  $KRSLmodif$ ,  $MCC$  y  $KRSL$  ( $\alpha=1.2$ ):

La reducción de ruido en el caso de *FT* de *FM* es aproximadamente de 55dB mientras que en el caso de *FNM*, si bien se reduce a 24dB, es un valor altamente satisfactorio teniendo en cuenta la limitación estructural implícita y otros valores publicados.

### 3.2.2. Segundo experimento. Ruido no estacionario

En esta experiencia se incluye ruido impulsivo con características probabilísticas variables en el tiempo. Se considera un cambio abrupto (variación escalonada, VE) del grado de impulsividad en dos instantes de tiempo, según se indica en la expresión *a*) de (11), para modelar una modificación de la probabilidad de ocurrencia de *outliers* (VE: Figuras 7, con *FT* a) *FM* y b) *FNM*). También se analiza una variación suave de tipo sinusoidal (VS) según la expresión *b*) de (11) (VS: Figura 8, con *FT* a) *FM* y b) *FNM*).

$$a) \begin{cases} \alpha = 1.8 & , \quad 0 \leq k \leq 4000 \\ \alpha = 1.3 & , \quad 4000 \leq k \leq 9000 \\ \alpha = 1.5 & , \quad 9000 \leq k \leq 20000 \end{cases} \quad b) \alpha = 1.5 + 0.3 \operatorname{sen} \left( 2 \frac{\pi}{4000} k \right) \quad (11)$$

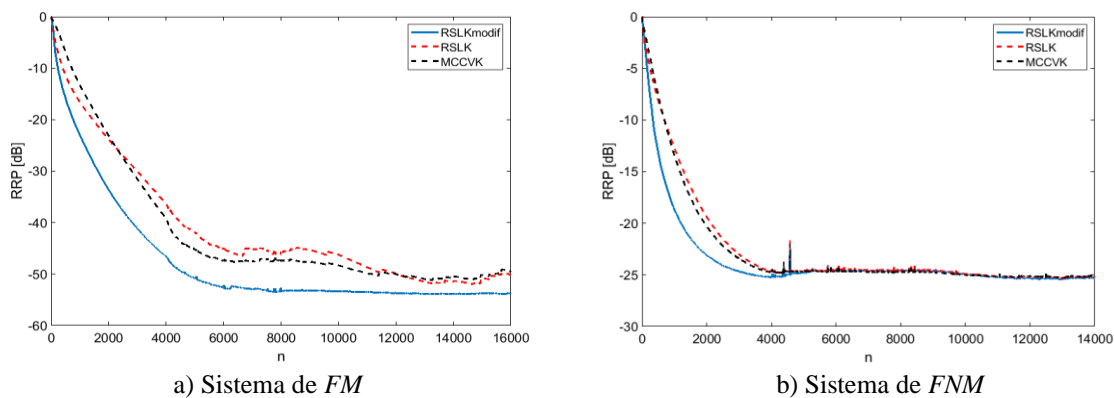


Figura 7. Comparación de *RRP* para ruido no estacionario (VE) con algoritmos *KRSLmodif*, *KRSL* y *MCC*




Figura 8. Comparación de *RRP* para ruido no estacionario (VS) con algoritmos *KRSLmodif*, *KRSL* y *MCC*

### 3.2.3. Tercer experimento. Ruido estacionario en sistema no estacionario

En este caso se comparan los algoritmos propuestos con el *MCC* para el caso de  $\alpha=1.4$  con una modificación del entrono acústico modelada mediante una *FT* de *FM* que se modifica abruptamente en el tiempo. La superioridad de la nueva metodología es notable tanto en la

velocidad de convergencia como en el valor estacionario (Figura 9).




Figura 9. RRP para cambio abrupto del entorno acústico.

#### 4. CONCLUSIONES

En este trabajo se propone una estrategia de control adaptativo para la atenuación de ruido impulsivo unidimensional, *KRSL* con kernel Gaussiano, que fue empleada con éxito en otras aplicaciones. Para este algoritmo se introduce como modificación la variación iterativa del ancho del kernel ya que su valor afecta inversamente la velocidad de convergencia y la precisión estacionaria. El análisis de la performance basado en simulaciones en variadas condiciones de operación permite concluir en principio que:

- Se comprueba la robustez frente a ruido altamente impulsivo aún en el caso de ser no estacionario y de modelos de caminos primario y secundario de *FNM*.
- El algoritmo propuesto representa una mejora considerable tanto en la velocidad de convergencia como en la precisión en estado estacionario, comparado con el *KRSL* clásico y otro algoritmo robusto como el *MCC*, en la mayoría de las situaciones analizadas.
- Se reduce el impacto de la selección de parámetros del algoritmo adoptado en los resultados.
- La mejora en la reducción de ruido se logra sin aumentar significativamente el costo computacional y de almacenamiento.
- La metodología puede ser extendida para su aplicación a sistemas multicanal.

En una siguiente etapa se buscará corroborar los resultados en un prototipo de laboratorio.

#### 5. BIBLIOGRAFÍA

Akhtar, M.T., Mitsuhashi, W. (2009). Improving performance of FxLMS algorithm for active noise control of impulsive noise. *Journal of Sound and Vibration*, 327, 647-656.

Akhtar, M.T. (2017) "An adaptive algorithm, based on modified tanh non-linearity and fractional processing, for impulsive active noise control systems". *Journal of Low Frequency Noise, Vibration and Active Control*, 37 (3), 1-14.

Bergamasco, M., Della Rossa, F., Piroddi, L. (2012) "Active noise control with on-line estimation of non-Gaussian noise characteristics". *Journal of Sound and Vibration*, 33, 27-40.

Boel, R. K., James, M. R., Petersen, I. R. (2002). Robustness and risk-sensitive filtering. *IEEE Transactions on Automatic Control*, 47 (3).

Chen, B., Wang, R. (2015). Risk-sensitive loss in kernel space for robust adaptive filtering. *IEEE*

International Conference on Digital Signal Processing (págs. 921-925) Singapore: IEEE.

Chen, B., Xing, L., Xu, B., Zhao, H., Zheng, N., Príncipe, J. C. (2017). Kernel Risk-Sensitive Loss: Definition, Properties and Application to Robust Adaptive Filtering. *IEEE Transactions on Signal Processing*, 6 (11), 2888-2901.

Chen, S., Gu, F., Liang, C., Meng, H., Wu, K., Zhou, Z. (2022). Review on Active Noise Control Technology for  $\alpha$ -Stable Distribution Impulsive Noise. *Circuits, Systems and Signal Processing*, 41, 956–993. Web: <https://doi.org/10.1007/s00034-021-01814-6>

Elliott, S.J. (2001). *Signal Processing for Active Control*. San Diego, USA: Academic Press.

Huang, F., Zhang, J., Zhang, S. (2017) “Adaptive Filtering Under a Variable Kernel Width Maximum Correntropy Criterion”. *IEEE Tran. Circuits and Systems—II: Express Briefs*, 64 (10), 1247-1251.

Liang, T., Li, Y., Zakharov, Y.V., Xue, W., Qi, J. (2021). Constrained least Incosh adaptive filtering algorithm. *Signal Processing*. 183,108044.

Lu, L., Zhao, H. (2017). Active impulsive noise control using maximum correntropy with adaptive kernel size. *Mechanical Systems and Signal Processing*, 87, Part A, 180-191.

Ma, W., Kou, X., Hu, X., Qi, A., Cheng, B. (2022). Recursive minimum kernel risk sensitive loss algorithm with adaptive gain factor for robust power system's estimation. *Electric Power Systems Research*, 206, 107788.

Niu, Z.X., Jiao, C.N., Ren, L.R., Zhu, R., Wang, J., Liu, J.-X. (2021). Kernel risk-sensitive mean  $p$ -power loss based hyper-graph regularized robust extreme learning machine and its semi-supervised extension for sample classification. *Applied Intelligence*. Springer

Príncipe, J.C. (2010). Capítulos 9 y 11. En: *Information Theoretic Learning: Renyi's Entropy and Kernel Perspectives*. New York: Springer.

Qian, G., Dong, F., Wang, S. (2020). Robust constrained minimum mixture kernel risk-sensitive loss algorithm for adaptive filtering. *Digital Signal Processing*, 107, 102859.

Rastegarnia, A., Malekian, P., Khalili, A., Bazzi, W.M., Sanei, S. (2019). Tracking Analysis of Minimum Kernel Risk-Sensitive Loss Algorithm under General Non-Gaussian Noise. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 66 (7), 1262-1266.

Wang, W., Zhao, H., Lu, L., Yu, Y. (2018). Robust Nonlinear Adaptive Filter Based on Kernel Risk-Sensitive Loss for Bilinear Forms. *Circuits, Systems, and Signal Processing*. Web: <https://doi.org/10.1007/s00034-018-0928-z>

Wang, W., Zhao, J., Qu, H., Chen, B. (2017). A correntropy inspired variable step-size sign algorithm against impulsive noises. *Signal Processing*, 141, 168-175.

Yu, N., Li, Z., Wu, Y., Chen, B. (2020). Convex combination-based active impulse noise control system”. *Journal of Low Frequency Noise, Vibration and Active Control*, 39 (1). Web: <https://doi.org/10.1177/1461348419838394>

Zhang, T., Wang, S., Zhang, H., Xiong, K., Wan, L. (2019). Kernel Risk-Sensitive Mean  $p$ -Power Error Algorithms for Robust Learning. *Entropy*, 21 (588).

Zhao, S., Chen, B., Príncipe, J.C. (2011). Kernel Adaptive Filtering with Maximum Correntropy Criterion. *Proceedings of International Joint Conference on Neural Networks*, (pág. 2012-2017). California, USA: IEEE.