



1 Introducción

1.1 El problema de filtrado

Tareas de procesamiento de la información:

1. **Filtrado**, extracción de información sobre una cantidad de interés disponible en un instante n utilizando datos medidos hasta e inclusive ese instante.
 2. **Suavizado**, difiere del filtrado en que la información sobre la cantidad de interés no necesita estar disponible en el instante n y datos medidos posteriormente al instante n pueden utilizarse. Esto significa que en suavizado existe un retardo en producir el resultado de interés.
 3. **Predicción**, permite el pronóstico de la información. El objetivo es obtener información sobre como la cantidad de interés será en un futuro instante de tiempo $n + \tau$, para algún $\tau > 0$, usando los datos medidos hasta e inclusive el instante n .
- En la solución estadística al problema de **filtrado lineal** (la salida función lineal de las observaciones) se supone conocidos ciertos parámetros estadísticos (como media y correlación). El objetivo minimizar algún criterio de la señal de error obtenida.
 - Para entradas estacionarias, **filtro de Wiener**, óptimo en sentido medio cuadrático.
 - Para ambientes no estacionarios el filtro óptimo debe asumir una formavariante en el tiempo: **filtro de Kalman**.



1.2 Filtros adaptivos

- Cuando los parámetros estadísticos adecuados para el filtro de Wiener no están disponibles existen diferentes tipos de soluciones.
- Solución posible, no muy eficiente, estimar esos parámetros en línea y utilizar una ecuación no recursiva para obtener una solución aproximada al filtro de Wiener.
- Solución más adecuada para operación en tiempo real es la utilización de un **filtro adaptivo**. Los coeficientes se ajustan siguiendo un criterio. Ajuste coeficientes mediante **algoritmo recursivo** cuyas propiedades conduzcan a una buena aproximación de la solución de Wiener.

Algunos factores importantes en análisis de filtros adaptivos

- **Velocidad de convergencia.** Número de iteraciones requerida por el algoritmo, en respuesta a entradas estacionarias, para convergir en forma suficientemente próxima a la solución de Wiener en un sentido medio cuadrático.
- **Desajuste.** Medida de la cantidad por la cual el valor final del error medio cuadrático (utilizado usualmente como criterio a minimizar), se desvía del mínimo del filtro de Wiener.
- **Seguimiento.** Operación en un ambiente no estacionario, el algoritmo requiere seguir (tracking) las variaciones estadísticas. El desempeño está influenciado por: la velocidad de convergencia y la fluctuación de estado estacionario debido a ruido del algoritmo.



- **Robustez.** Para que un filtro adaptivo sea robusto, perturbaciones de pequeña energía deben resultar en errores de estimación pequeños.
- **Requerimientos computacionales.** Número de operaciones requeridas para completar una iteración del algoritmo, tamaño de memoria requerido para almacenar los datos y el programa y la inversión requerida para desarrollar el algoritmo.
- **Estructura.** Flujo de información en el algoritmo y forma en que será implementado el hardware.
- **Propiedades numéricas.** Los errores de cuantización son debido a la conversión A/D de los datos de entrada y a la representación digital interna. (la fuente más considerable). Dos aspectos: estabilidad numérica y precisión numérica.



1.3 Estructuras de filtros lineales

1. Filtro transversal

$$y(n) = \sum_{k=0}^{M-1} w_k x(n - k) \quad (1)$$

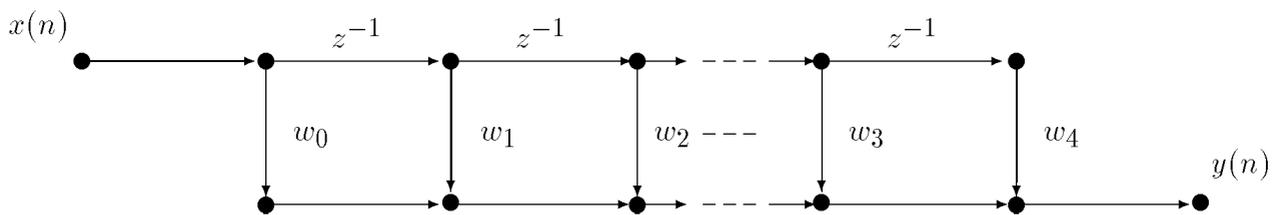


Figura 1: Filtro transversal.

2. Predictor lattice.

$$f_m(n) = f_{m-1}(n) + K_m b_{m-1}(n - 1)$$

$$b_m(n) = b_{m-1}(n - 1) + K_m f_{m-1}(n)$$

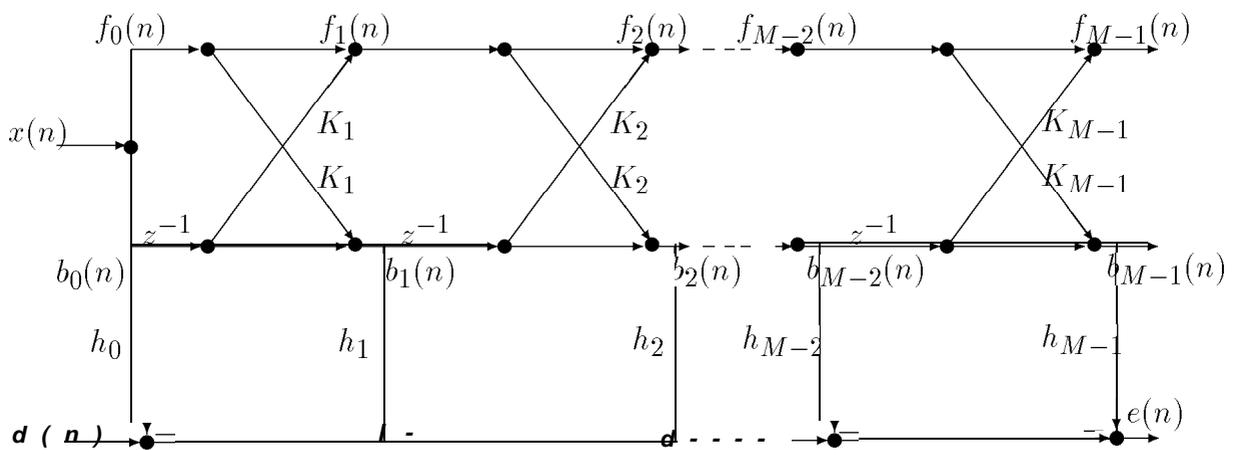


Figura 2: Filtro lattice



1.4 Algoritmos de filtrado adaptivo

- No existe una solución única para el problema de filtrado adaptivo, sino más bien una variedad de herramientas representadas por un conjunto de algoritmos, cada uno de los cuales ofrece características adecuadas a cierta aplicación.
- Es posible identificar en forma general dos formas distintas para derivar algoritmos recursivos para la operación de filtros adaptivos lineales
 - Aproximación de gradiente estocástico.
 - Estimación de Cuadrados Minimos.

1.4.1 Aproximación de gradiente estocástico

El algoritmo típico es conocido como **least-mean-square (LMS)**,

$$\begin{pmatrix} \text{valor próximo} \\ \text{del vector de} \\ \text{coeficientes} \end{pmatrix} = \begin{pmatrix} \text{valor actual} \\ \text{del vector de} \\ \text{coeficientes} \end{pmatrix} + \begin{pmatrix} \text{parámetro} \\ \text{de} \\ \text{convergencia} \end{pmatrix} \begin{pmatrix} \text{vector} \\ \text{de} \\ \text{entradas} \end{pmatrix} \begin{pmatrix} \text{señal} \\ \text{de} \\ \text{error} \end{pmatrix}$$

1.4.2 Estimación de Cuadrados Minimos

El método de cuadrados mínimos puede formularse para **estimación en bloques** ó **estimación secuencial**.

La estimación de **cuadrados mínimos recursivo (RLS)** puede interpretarse como un caso especial de **filtrado Kalman**.

$$\begin{pmatrix} \text{valor próximo} \\ \text{del vector de} \\ \text{coeficientes} \end{pmatrix} = \begin{pmatrix} \text{valor actual} \\ \text{del vector de} \\ \text{coeficientes} \end{pmatrix} + \begin{pmatrix} \text{Ganancia} \\ \text{de} \\ \text{Kalman} \end{pmatrix} \begin{pmatrix} \text{vector} \\ \text{de} \\ \text{innovación} \end{pmatrix}$$



Clasificación familia **RLS** de algoritmos de filtrado adaptivo:

1. **Algoritmos RLS estandar**, resultado básico del álgebra lineal conocido como **lema de inversión de matrices**. Este algoritmo goza de las mismas virtudes y sufre los mismos defectos que el algoritmo Kalman estandar. Las limitaciones incluyen carencia de robustez numérica y complejidad computacional excesiva.
2. **Algoritmos RLS factorizados**, están basados en la descomposición **QR** de la matriz de datos de entrada. DOS técnicas son la **transformación de Householder** y las **rotaciones de Givens**. Son estables y robustos.
3. **Algoritmos RLS rápidos**, Los anteriores complejidad computacional que aumenta con $O(M^2)$, donde M es el número de coeficientes ajustables en el algoritmo. En el LMS es $O(M)$. Cuando M es grande, la complejidad $O(M^2)$ puede ser excesiva para una aplicación determinada, entonces motivación para desarrollar RLS de $O(M)$. Alcanzable usando la **estructura Toeplitz** de la matriz de datos de entrada y también usando **predicción lineal de cuadrados mínimos hacia adelante y hacia atrás** (forward y backward). DOS RLS de $O(M)$:

- **Filtros adaptivos recursivos en orden**, basados en una estructura tipo lattice para realizar las predicciones forward y backward.
- **Filtros transversales rápidos**, donde las predicciones forward y backward se realizan con filtros transversales separados.

No todas las realizaciones de filtros adaptivos recursivos en orden son numericament e est ables.



Características de seguimiento

- los algoritmos de tipo gradiente tal como el LMS son **independientes del modelo**, genericamente es posible esperar un buen comportamiento en seguimiento.
- los algoritmos RLS son **dependientes del modelo**, lo que significa que sus comportamientos en seguimiento pueden ser inferiores al de algún miembro de la familia de gradientes estocásticos.



1.5 Filtros adaptivos en forma real y compleja

- En aplicaciones de comunicaciones, radar, sonar y de transporte de información la señal en el receptor típicamente consiste en una señal de mensaje **no modulada** en una señal portadora.
- El ancho de banda de la señal de mensaje usualmente es pequeño comparado con la portadora, lo cual significa que la señal modulada es de **banda estrecha**.
- Para obtener la representación **bandabase** de una señal de banda estrecha se traslada la señal en frecuencia hasta que el efecto de la portadora sea removido, de forma que la señal de mensaje se mantenga inalterada. La señal de bandabase así obtenida es en general compleja. En otras palabras, $U(n)$ puede ser escrita como

$$\mathbf{u}(n) = u_I(n) + ju_Q(n)$$

donde $u_I(n)$ es la **componente en fase** y $u_Q(n)$ es la **componente en cuadratura**. En forma equivalente es posible expresar $\mathbf{u}(n)$ como

$$\mathbf{u}(n) = |u(n)|e^{j\phi(n)}$$

donde $|u(n)|$ es la **envolvente** y $\phi(n)$ es la **fase**.

- Un algoritmo de filtrado adaptivo desarrollado de esta forma se dice en **forma compleja**. La característica importante de filtros adaptivos complejos es que mantienen la formulación matemática y estructura de las aplicaciones mencionadas.



1.6 Aplicaciones

- La habilidad de un filtro adaptivo para operar satisfactoriamente en un contexto desconocido y seguir variaciones en el tiempo de la estadística de la entrada hacen al filtrado adaptivo una herramienta poderosa para varias aplicaciones de procesamiento de señal y control.
- Han sido exitosamente aplicados en campos tan diversos como comunicaciones, radar, sonar, sismología e ingeniería biomédica.
- A pesar que esas aplicaciones son bien diferentes en naturaleza tienen una base común: el vector de entrada y la respuesta deseada se utilizan para obtener el error de estimación, el cual se usa para controlar los valores de un conjunto de coeficientes ajustables asociados al filtro.
- Los coeficientes ajustables pueden tener la forma de parámetros de reflexión, parámetros de rotación, etc., dependiendo de la estructura del filtro adaptivo utilizado.
- La diferencia esencial entre las aplicaciones reside en la forma en que se obtiene la respuesta deseada.

- Es posible distinguir cuatro clases de aplicaciones de filtrado adaptivo, donde: u : es la entrada aplicada al filtro, y : es la salida del filtro, d es la respuesta deseada y $m = d - y$ es el error de estimación.

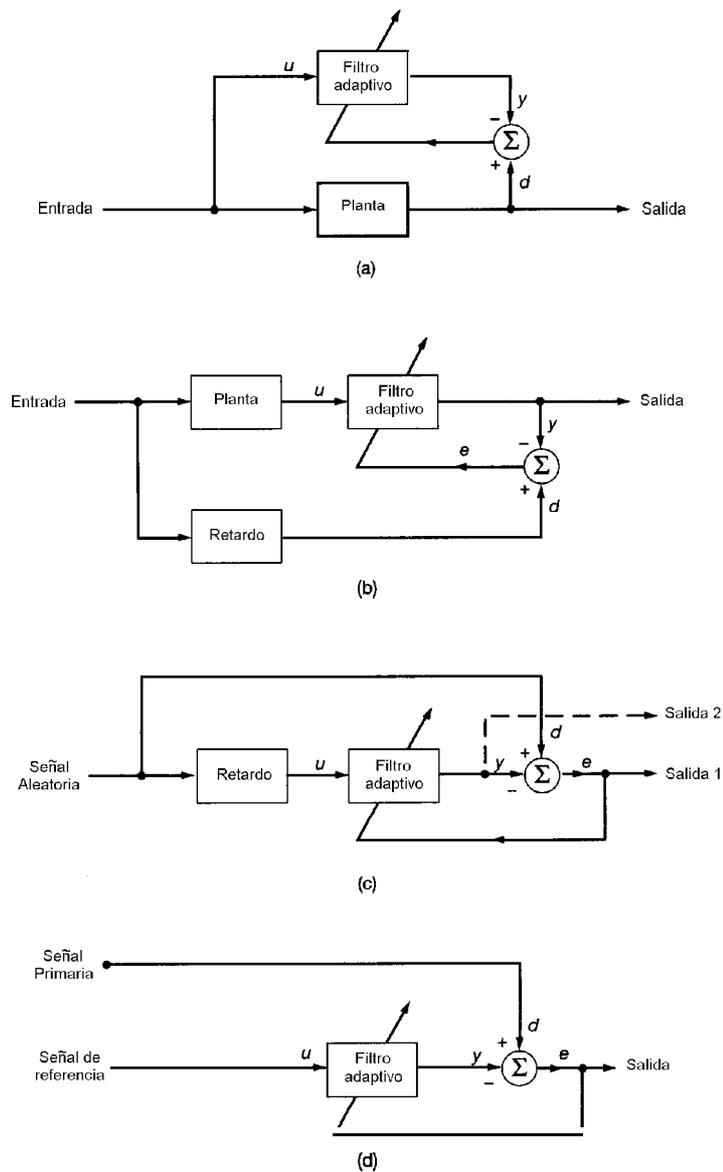


Figura 3: Clases de aplicaciones de filtrado adaptivo: a) identificación, b) modelado inverso, c) predicción, d) cancelamiento de interferencias.