

108  
2 ej



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

FACULTAD DE INGENIERIA

ESTUDIO COMPARATIVO DE ALGORITMOS  
PARA LA DETECCIÓN DE CAMBIOS ABRUPTOS  
Y LA SEGMENTACION DE SEÑALES UTILIZADOS  
EN SISTEMAS DE RECONOCIMIENTO Y  
CLASIFICACION

TESIS CON  
FALLA DE ORIGEN

T E S I S

QUE PARA OBTENER EL TITULO DE:

INGENIERO MECANICO ELECTRICISTA

P R E S E N T A :

JESUS SANTIAGO ONTAÑON ALVAREZ

DIRECTOR DE TESIS,

DR. ROGELIO ALCANTARA SILVA



México, D. F.

1991



Universidad Nacional  
Autónoma de México



## **UNAM – Dirección General de Bibliotecas Tesis Digitales Restricciones de uso**

### **DERECHOS RESERVADOS © PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL**

Todo el material contenido en esta tesis está protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

# INDICE

Introducción.....	1
1. Conceptos Básicos del Procesamiento Digital de Señales.....	4
1.1. Sistemas y Señales.....	4
1.2. Espacios de Representación.....	6
1.3. Función de Autocorrelación.....	6
1.4. Función de Covariancia.....	8
1.5. Análisis de Fourier.....	8
1.6. Modelos Paramétricos.....	12
1.7. Sistemas de Reconocimiento y Clasificación.....	14
2. Estimación Paramétrica.....	16
2.1. Fundamentos de Probabilidad.....	16
2.2. Principios de la Detección y de la Estimación.....	19
2.3. Estimación por Máxima Verosimilitud.....	22

2.4.	Estimación por Mínimos Cuadrados.....	25
2.4.1.	Algoritmos Globales.....	26
2.4.2.	Algoritmos Recursivos en Tiempo.....	27
3.	Detección de Cambios y Segmentación de una Señal.....	31
3.1.	Descripción del Problema.....	31
3.2.	Metodología de Diseño de un Método de Segmentación.....	33
4.	Estudio Comparativo de Algunos Métodos de Segmentación.....	37
4.1.	Método de la Función de AutoCorrelación (FAC).....	37
4.1.1.	Prueba para Encontrar Porciones No Estacionarias.....	37
4.1.2.	Estimación de la Posición de las Fronteras.....	42
4.2.	Método de la Medida de Error eSpectral (MES).....	43
4.2.1.	Prueba para Encontrar Porciones No Estacionarias.....	43
4.3.	Método de la Razon Generalizada de Verosimilitud (RCV).....	45
4.3.1.	Prueba para Encontrar Porciones No Estacionarias.....	46
4.3.2.	Estimación de la Posición de las Fronteras.....	48
4.4.	Simulaciones en Computadora.....	50
4.4.1.	Implantación de los Algoritmos.....	50
4.5.	Pruebas y Criterios.....	53
4.5.1.	Definición de las Señales de Prueba.....	54
4.5.2.	Parametros de Analisis.....	62
4.6.	Comparación de los Diferentes Métodos.....	67
4.7.	Resultados.....	90
5.	Aplicaciones de la Segmentación.....	97
5.1.	Sistema de Clasificación y Reconocimiento de EEG.....	97
5.2.	Reconocimiento de Voz.....	100

<b>6. Conclusiones y Perspectivas.....</b>	<b>103</b>
<b>6.1. Conclusiones.....</b>	<b>103</b>
<b>6.2. Perspectivas.....</b>	<b>104</b>
<b>Bibliografía.....</b>	<b>108</b>
<b>Apéndices.....</b>	<b>109</b>
<b>Apéndice 1. Sistema de Simulación en Microcomputadora.....</b>	<b>109</b>
<b>Apéndice 2. Listado de Programas en TURBO PASCAL.....</b>	<b>122</b>

## INTRODUCCION

A partir del desarrollo de la microelectrónica a niveles nunca imaginados, cada día surgen aplicaciones nuevas para los sistemas digitales. Estas aplicaciones antes no eran posibles debido principalmente a limitaciones de velocidad y capacidad de almacenamiento. Gracias a las nuevas tecnologías, el procesamiento digital de señales ha venido a tomar el lugar de muchos procesos que anteriormente se hacían de manera analógica. Actualmente existen sistemas completos en los cuales el procesamiento digital forma parte primordial por encima de las técnicas analógicas.

El procesamiento digital de señales se utiliza con mucha frecuencia en sistemas de comunicación y toma cada vez más fuerza en aplicaciones de reconocimiento y clasificación de señales. En la interminable búsqueda del hombre por automatizar acciones propias de la inteligencia humana, se han propuesto a lo largo de la historia máquinas que emulen cierta acción humana.

Existen en la actualidad diferentes dispositivos que reproducen de alguna u otra manera la voz humana, y sistemas que pueden identificar y reconocer comandos hablados. La mayoría de estos sistemas procesan la información con criterios preestablecidos de duración de un sonido. Sin embargo, en situaciones reales estas duraciones dependen de factores propios de cada parlante.

El tedioso trabajo de analizar toda una noche de registro electroencefalográfico se puede hacer ahora por medio de sistemas automáticos que clasifiquen las señales y extraigan sólo la información necesaria para que el especialista pueda hacer un diagnóstico. Muchos de estos sistemas clasifican pedazos de señal de tamaño estándar (treinta segundos por lo general), lo que muchas veces lleva a que se pierdan segmentos pequeños que pueden tener importancia o a que se repita varias

veces el análisis sobre un segmento muy largo.

Cuando se tiene una situación en la cual las características cambiantes de una señal dan la pauta a seguir en el comportamiento de cierto proceso (como los dos antes mencionados), surge la inquietud de encontrar métodos matemáticos que, aplicados por medio de dispositivos electrónicos de cálculo, nos ayuden en el proceso de control y procesamiento de fenómenos cambiantes.

A estos métodos antes mencionados se les conoce, dependiendo del caso, como algoritmos de detección de cambios abruptos o bien como algoritmos de segmentación. Más adelante en el capítulo 3, se insistirá en la diferencia que existe entre ambos. A lo largo de este trabajo se verá lo útil que es poder conocer el momento en que se producen cambios en las señales de algún proceso, para así tener un mejor control de las variables con las que se está trabajando.

Los algoritmos de detección de cambios y de segmentación han encontrado aplicaciones dentro de sistemas en los cuales se trabaja con señales no estacionarias, como sería el caso de las señales de voz antes mencionadas, las señales sísmicas, las imágenes digitales, y las señales bioeléctricas, como los electroencefalogramas (EEG) y los electrocardiogramas (ECG).

En este trabajo se hace el estudio de tres algoritmos de segmentación desarrollados en los últimos veinte años con base en la teoría del procesamiento digital de señales (PDS), y se mencionan sus características y desempeño al ser implantados dentro de un sistema computarizado.

Posteriormente se comparan los rendimientos de ellos al ser aplicados a diferentes tipos de señales sintéticas y reales, y se menciona el futuro acoplamiento de uno de ellos a el Sistema Automático de Clasificación de Señales de EEG en desarrollo en la Sección de Eléctrica de la División de Estudios de Posgrado de la Facultad de Ingeniería de la Universidad Nacional Autónoma de México (DEPFI-UNAM).

Al final se pretende tener una guía práctica para la implantación de alguno de estos algoritmos en diferentes aplicaciones dentro del PDS, desarrollándose una metodología para la selección del algoritmo y de sus variables asociadas, de acuerdo a las diferentes características de las señales a tratar.

Un producto práctico de este trabajo es contar con los algoritmos programados en lenguaje de alto nivel de manera que se puedan hacer simulaciones con las señales reales a las que posteriormente se les aplicarán. El procedimiento de programación de estos algoritmos es descrito de manera que sea sencilla su implantación en cualquier arquitectura de cálculo y en cualquier lenguaje de programación.

En el primer capítulo se da una perspectiva teórica de lo que es el PDS y para ello se introducen algunos conceptos básicos que justifican los

desarrollos posteriores y algunas nociones de temas más avanzados del PDS como sería el reconocimiento y la clasificación y la estimación paramétrica.

A la estimación paramétrica, por ser una de las herramientas del PDS más utilizadas dentro de este trabajo, se le dedica el capítulo 2 de manera que se puedan comprender los algoritmos utilizados posteriormente.

El capítulo 3 describe la evolución de estos algoritmos a través del tiempo y Justifica su creación. Así mismo se enumeran las diferentes características que deben tener los algoritmos para así poder compararlos unos con otros.

En el capítulo 4 se realiza el estudio comparativo de los tres algoritmos más utilizados, por medio de pruebas realizadas con señales sintéticas para las cuales conocemos bien su comportamiento. En este capítulo se describen los tres algoritmos de manera que se comprendan sus implantaciones. El primer método (método FAC) se desarrolla completamente, no dejando ningún punto sin demostrar. Para los otros dos algoritmos se utilizan algunos procedimientos complejos de cálculo sin pretender demostrarlos en este trabajo, pero haciendo referencia a las publicaciones de las cuales se tomaron.

En el capítulo 5 se pretende dar un panorama más amplio sobre los posibles usos de los algoritmos, sin tratar de ser exhaustivos en el número de aplicaciones, sino más bien de describir aquéllas con las que se ha tenido más contacto durante este trabajo.

En el capítulo 6 se presentan las conclusiones a las que se llegaron al final de este trabajo, y se comparten algunas de la experiencias obtenidas durante su desarrollo.

Con este trabajo se busca comprender mejor el funcionamiento de estos algoritmos para poder aplicarlos en diferentes problemas del procesamiento de señales.



# CONCEPTOS BASICOS DEL PROCESAMIENTO DIGITAL DE SEÑALES.

1

## 1.1. Sistemas y Señales.

Los principales elementos del Procesamiento Digital de Señales (PDS) son los sistemas, las señales, y las diferentes maneras en que se relacionan. Una de las maneras más comunes para relacionar a las señales con los sistemas es el uso de modelos matemáticos que nos describan de una manera abstracta el comportamiento de los fenómenos. Un modelo simplificado de un sistema que es afectado por cierta excitación y que produce una respuesta se muestra en la figura 1.1.




Figura 1.1.

Este sistema tendrá asociado cierto modelo matemático que indique una relación entre la señal de entrada y la señal de salida.

En el PDS se utilizan diferentes técnicas y procedimientos mediante los cuales se puede extraer información de una señal para diferentes usos. Algunas veces es interesante conocer a la señal desde el punto de vista de que ésta será alimentada a cierto sistema, y probablemente, se deban hacer algunas modificaciones a sus características para que el sistema trabaje óptimamente. Otras veces el interés consiste en saber qué tipo de señales se obtienen a la salida de un sistema para conocer mejor el comportamiento de éste y poder determinar características inherentes a su desempeño y funcionamiento.

De lo anterior se puede derivar la gran importancia que tienen las señales en el análisis ingenieril de los sistemas dinámicos. Con el crecimiento de la informática y la computación se ha hecho cada vez más fácil el que una computadora analice varias señales y haga decisiones de acuerdo a eventos o sucesos detectados.

Una señal es una función que aporta cierta información acerca de un fenómeno dado, que es caracterizado a su vez por un sistema [Aic89]. Existen diferentes maneras de representar a una señal con respecto a la variable independiente del sistema (generalmente tiempo), tendremos entonces señales en el tiempo continuo y señales en el tiempo discreto. La amplitud de la señal puede también ser continua o discreta. De aquí podemos decir que una señal digital es aquella en la que tanto su amplitud como el tiempo son discretos. Una señal digital es generalmente conocida como una secuencia debido a que consiste de valores discretos organizados de forma secuencial.

Las señales también pueden ser clasificadas de acuerdo al conocimiento que tenemos de ellas en: determinísticas, si conocemos su función y podemos obtener el valor para cualquier tiempo; y en aleatorias o estocásticas, si no podemos conocer la función que las genera pero tenemos información sobre sus promedios estadísticos. Otro tipo de clasificación sería en periódicas y aperiódicas; siendo las periódicas las que se repiten después de cierto periodo.

Generalmente, las señales determinísticas son las más fáciles de procesar, más aún si son periódicas, debido a que su comportamiento está determinado por alguna regla que se repite. Sin embargo, existen ejemplos muy importantes de señales que son o estocásticas o aperiódicas o ambas. Dentro de estos ejemplos encontramos a la mayoría de las señales mencionadas en la introducción.

El principal problema en el análisis de estas señales se debe a que poseen energía infinita, lo cual hace imposible el uso de métodos como los de la transformada  $z$  y de Fourier, las cuales sólo existirán para señales con energía finita. La clave para analizar señales con cierto grado de aleatoriedad es describiéndolas en términos de momentos como podrían ser la media o la varianza estadística. Las secuencias de autocorrelación y de autocovarianza de una señal aleatoria son secuencias a energía finita para las cuales si existirán las transformadas antes mencionadas [Opp83].

En ocasiones, en el PDS es muy útil usar transformaciones que nos lleven de una representación en la cual se nos dificulta el análisis, a otra representación en la cual se disminuye el grado de dificultad. Podrá entonces ser más fácil el análisis de una señal en el espacio de las autocorrelaciones que en el espacio de representación temporal en el que originalmente se encontraba disponible.

## 1.2. Espacios de Representación.

Los seres humanos estamos muy acostumbrados a que nuestra vida transcurra en el tiempo y por lo tanto, el espacio de representación temporal es muy tangible. Existe en la teoría de señales y de sistemas la noción de transportarnos de un tipo de representación hacia otra completamente diferente, que sin embargo nos dé toda la información sobre una señal. Esto se hace generalmente mediante transformadas matemáticas.

Ejemplos de estas transformaciones son el muestreo, que nos lleva del espacio de representación del tiempo continuo al espacio de representación del tiempo discreto; la transformada de Fourier que nos transporta del espacio de representación temporal al espacio de representación frecuencial; las funciones de autocorrelación y covariancia que nos transportan también a espacios en los cuales tenemos la información necesaria como para reconstruir la señal original en el tiempo, etc.

En la figura 1.2 se muestra el esquema de una transformación inversible, para la cual existirá tanto el camino de ida como el de regreso de un espacio a otro. Este tipo de transformaciones son las que nos interesan en el PDS.




Figura 1.2.

## 1.3. Función de Autocorrelación.

La función de autocorrelación de una señal discreta  $s[n]$  se define en su forma general de la siguiente manera (Hak75):

$$R\{l\} = \sum_{n=-\infty}^{\infty} s[n] s[n+l] \quad (1.1)$$

En la práctica, cuando se tiene una señal  $s[n]$  y se desea obtener su función de autocorrelación (FAC), se le multiplica por una ventana  $v[n]$  para obtener una segunda señal  $s'[n]$  la cual es cero fuera del intervalo de la ventana y se representa de la siguiente manera [Mak75]:

$$s'[n] = \begin{cases} s[n] v[n] & 0 \leq n \leq N-1 \\ 0 & \text{otro caso.} \end{cases} \quad (1.2)$$

Donde  $N$  es la longitud del segmento de la señal a la cual se le quiere obtener su función de autocorrelación.

La función de autocorrelación será, a partir de las ecuaciones (1.1) y (1.2) [Mak75]:

$$R\{l\} = \sum_{n=0}^{N-1-l} s'[n] s'[n+l]; \quad l \geq 0 \quad (1.3)$$

A  $l$  se le conoce como el retraso, entonces tendremos valores de  $R$  para diferentes retrasos y adelantos ( $l < 0$ ).  $R\{l\}$  es una función par de  $l$ , es decir,

$$R\{-l\} = R\{l\}. \quad (1.4)$$

A partir de la ecuación (1.3) y tomando en cuenta (1.4) se puede ver que los coeficientes  $R\{l-n\}$  forman lo que se conoce como matriz de autocorrelación. Esta matriz es del tipo Toeplitz simétrica, es decir, que todos los elementos en una diagonal dada son idénticos.

La función de autocorrelación  $R_{xx}(k)$  de un proceso estocástico estacionario en el sentido amplio  $x[n]$  para un retraso  $k$  se define como la esperanza matemática del producto  $x[n+k]$  por  $x^*[k]$ , es decir,

$$R_{xx}(k) = E \left\{ x[n+k] x^*[n] \right\} \quad (1.5)$$

donde se supone que la media de  $x[n]$  es igual a cero,  $*$  implica el complejo conjugado y  $E(\cdot)$  es el operador esperanza.

#### 1.4. Función de Covariancia.

La función de covariancia, a diferencia de la de autocorrelación, se define para un intervalo finito, sea  $0 \leq n \leq N-1$ . Así tendremos que la función de covariancia será [Mak75]:

$$\varphi[l, k] = \sum_{n=0}^{N-1} s[n-1] s^*[n-k] \quad (1.6)$$

donde  $N$  es la longitud del intervalo de interés.

Los coeficientes  $\varphi[l, k]$  forman una matriz llamada de covariancia, la cual es una matriz simétrica ya que  $\varphi[k, l] = \varphi[l, k]$ . En esta matriz a diferencia de la de autocorrelación, los elementos en las diagonales no son necesariamente iguales.

Existe una relación entre las dos funciones, la de covariancia y la de autocorrelación, y es que cuando el intervalo de estudio tiende a infinito, las dos funciones se hacen iguales.

#### 1.5. Análisis de Fourier.

Uno de los espacios de representación más utilizados en el PDS es el de la frecuencia. A la representación en frecuencia de una señal se le conoce comúnmente como su espectro. A continuación se presentan los conceptos básicos del análisis de Fourier sobre todo en su parte conceptual, existen tratados completos sobre las diferentes técnicas para estimar los espectros [Kay81]. Sin embargo, como el objetivo de este trabajo no es el análisis espectral, éste será presentado de manera que se pueda referir a él posteriormente pero sin ahondar en detalles.

Si tenemos una señal  $x(t)$  que por simplicidad la consideramos determinística y continua, se dice que su energía  $\mathcal{E}$  es finita si  $x(t)$  es absolutamente integrable o [Kay81]:

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt < \infty \quad (1.7)$$

Entonces su transformada de Fourier continua existirá, y estará dada por [Kay81]:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (1.8)$$

La ecuación (1.7) es condición suficiente más no necesaria.

Al módulo al cuadrado de la ecuación (1.8) es a lo que estrictamente se le conoce como espectro  $\mathcal{P}(f)$ , de  $x(t)$  [Kay81].

$$\mathcal{P}(f) = |X(f)|^2 \quad (1.9)$$

Existe un teorema de conservación de energía que nos dice que la energía de la señal en su representación temporal es igual a la energía de la transformada en el espacio frecuencial. A este teorema se le denomina Teorema de Parseval [Kay81]:

$$\int_{-\infty}^{\infty} |x(t)|^2 dt = \int_{-\infty}^{\infty} |X(f)|^2 df \quad (1.10)$$

A la función  $\mathcal{P}(f)$  se le conoce también como densidad espectral de energía debido a que representa la distribución de la energía como función de la frecuencia.

Ahora supongamos el caso de una señal discreta que es producto de haber muestreado a  $x(t)$  en intervalos iguales de  $\Delta t$ , de manera que obtenemos la secuencia discreta

$$x[n] = x(n\Delta t) \quad \text{para toda } -\infty < n < \infty. \quad (1.11)$$

Podemos representar a la señal muestreada como el producto de la señal continua original  $x(t)$  por una secuencia infinita de deltas de Dirac  $\delta(t)$  [Kay81].

$$x[n] = \sum_{n=-\infty}^{\infty} x(t) \delta(t-n\Delta t) \Delta t \quad (1.12)$$

A partir de (1.8) y (1.12) podemos representar la transformada de Fourier de la señal discreta [Kay81]:

$$\begin{aligned} X'(f) &= \int_{-\infty}^{\infty} \left[ \sum_{n=-\infty}^{\infty} x(t) \delta(t-n\Delta t) \Delta t \right] e^{-j2\pi ft} dt \\ &= \Delta t \sum_{n=-\infty}^{\infty} x[n] e^{-j2\pi fn\Delta t} \end{aligned} \quad (1.13)$$

Si sólo se conocen los valores de  $x[n]$  para una ventana de tamaño finito  $0 \leq n \leq N-1$  y la transformada es discretizada también para  $N$  valores tomando muestras en frecuencia cada  $f = m\Delta f$  para todo  $m$  tal que  $0 \leq m \leq N-1$  donde  $\Delta f = 1/N\Delta t$ , entonces se define lo que se conoce como la Transformada de Fourier Discreta (TFD) [Kay81]:

$$\begin{aligned} X[m] &= \Delta t \sum_{n=0}^{N-1} x[n] e^{-j2\pi m\Delta f n\Delta t} \\ &= \Delta t \sum_{n=0}^{N-1} x[n] e^{-j2\pi mn/N} \quad \text{para } m = 0, \dots, N-1. \end{aligned} \quad (1.14)$$

La transformada inversa de  $X[m]$  es cíclica con periodo  $N$ , de manera que al utilizar la ecuación (1.14) forzamos una extensión periódica a los datos discretizados dentro de la ventana. Así, la transformada inversa de  $X[m]$  será una repetición de la ventana original de  $x(t)$  y estará dada por [Kay81]:

$$x[n] = \Delta f \sum_{m=0}^{N-1} X[m] e^{+j2\pi mn/N} \quad (1.15)$$

Cuando tenemos el caso, como en casi todas las señales reales, en que  $x(t)$  es un proceso estocástico, estacionario en el sentido amplio en vez de determinístico y a energía finita, debemos de tomar otro camino para lograr su estimación espectral.

Como en los procesos la energía es infinita, la cantidad que nos interesará será la potencia, que representa el promedio de la energía a través del tiempo, y su evolución en la frecuencia.

Para el caso de un proceso estocástico estacionario, es la función de autocorrelación, ecuación (1.5), la que se puede transformar y no en sí el proceso  $x(t)$ .

La densidad espectral de potencia  $\mathcal{P}(f)$  se calcula utilizando el teorema de Wiener-Khinchin [Kay81]:

$$\mathcal{P}(f) = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi f\tau} d\tau \quad (1.16)$$

En problemas prácticos, no siempre es posible conocer la función de autocorrelación estadística, por lo que es necesario hacer la suposición de que el proceso es ergódico en su primero y segundo momentos, esto quiere decir que se pueden sustituir sus promedios estadísticos por promedios sobre las muestras. Para un proceso ergódico, la función de autocorrelación se calcula de la siguiente manera [Kay81]:

$$R_{xx}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T x(t+\tau) x^*(t) dt \quad (1.17)$$

Existe una manera directa para pasar de la representación temporal de un proceso estocástico ergódico a su densidad espectral de potencia, se debe de partir de que para señales determinísticas tenemos [Pap84]:

$$Pr(f) = \frac{1}{2T} \left| \int_{-T}^T x(t) e^{-j2\pi ft} dt \right|^2 \quad (1.18)$$

Si  $x(t)$  es un proceso estocástico [Pap84],

$$E \left\{ \mathcal{P}_T(f) \right\} \xrightarrow{T \rightarrow \infty} \mathcal{P}(f) \quad (1.19)$$

De (1.18) y (1.19) se obtiene finalmente la expresión a la que queríamos llegar:



$$P(f) = \lim_{T \rightarrow \infty} E \left\{ \frac{1}{2T} \left| \int_{-T}^T x(t) e^{-j2\pi ft} dt \right|^2 \right\} \quad (1.20)$$




Figura 1.3.

En la figura 1.3 se muestra un diagrama simplificado de las diferentes maneras que existen para obtener la densidad espectral de potencia de un proceso estocástico y las ecuaciones que se utilizan.

## 1.6. Modelos Paramétricos.

Uno de los intereses primordiales en el análisis de señales es el poder lograr un modelo paramétrico del fenómeno en estudio, así, el modelo puede usarse posteriormente para predicción de valores, control o compresión de datos.

En un modelo paramétrico representamos las variables físicas del sistema por medio de valores parametrizados que afectan una función.

Uno de los modelos más utilizados en la actualidad es el de predicción lineal [Mak75] en el cual el valor de la señal  $s[n]$  depende de valores pasados de sí misma,  $s[n-k]$ , ponderados por ciertos parámetros  $a_k$  y de una cierta entrada desconocida  $u[n]$  ponderada por otros parámetros  $b_j$  y afectada por una cierta ganancia  $G$ . El nombre de predicción lineal se debe

a que el valor  $s[n]$  puede ser predicho a partir de combinaciones lineales de entradas y salidas pasadas.

$$s[n] = - \sum_{k=1}^p \alpha_k s[n-k] + G \sum_{j=0}^q \delta_j u[n-j] \quad , \delta_0 = 1 \quad (1.21)$$

Si obtenemos la función de transferencia del sistema,

$$H(z) = \frac{S(z)}{U(z)} = G \frac{1 + \sum_{j=1}^q \delta_j z^{-j}}{1 + \sum_{k=1}^p \alpha_k z^{-k}} \quad (1.22)$$

las raíces de los polinomios del numerador y del denominador son respectivamente los ceros y los polos del sistema.

Si  $\alpha_k = 0$  para  $1 \leq k \leq p$  tendremos un modelo todo ceros o estadísticamente conocido como modelo de promedio móvil (conocido como MA por su traducción en inglés: *Moving Average*).

$$s[n] = G \sum_{j=0}^q \delta_j u[n-j] \quad , \delta_0 = 1 \quad (1.23)$$

$$H(z) = \frac{S(z)}{U(z)} = G \left\{ 1 + \sum_{j=1}^q \delta_j z^{-j} \right\} \quad (1.24)$$

Si  $\delta_j = 0$  para  $1 \leq j \leq q$  entonces será un modelo todo polos conocido como modelo autorregresivo (AR).

$$s[n] = - \sum_{k=1}^p \alpha_k s[n-k] + G \quad (1.25)$$

$$H(z) = \frac{S(z)}{U(z)} = G \frac{1}{1 + \sum_{k=1}^p a_k z^{-k}} \quad (1.26)$$

Al modelo general de polos y ceros también se le conoce como modelo autorregresivo de promedio móvil (ARMA), ecuaciones (1.21) y (1.22).

Una vez definido el modelo con el que se trabaja, el siguiente problema es la estimación de los parámetros del modelo. Existen muchos criterios para que la estimación sea lo mejor posible. En el siguiente capítulo se hará el desarrollo de estos criterios.

## 1.7. Sistemas de Reconocimiento y Clasificación.

El Procesamiento Digital de Señales es una herramienta que se utiliza para hacer transformaciones a las señales de manera que se pueda, a partir de ellas tomar alguna decisión acerca del proceso que las generó.

La clasificación es uno de los principales fines de un sistema en el cual existen señales reales. Las áreas de ingeniería eléctrica como las comunicaciones, el procesamiento de señales y el control hacen uso de teorías computacionales como el reconocimiento de patrones para hacer reconocimiento y clasificación de las diferentes señales que se pueden obtener.

El fin principal del reconocimiento de patrones es la clasificación de objetos de interés en una de varias categorías llamadas clases. A los objetos de interés se les llama patrones y pueden ser según la aplicación, letras escritas, vocablos, formas de onda, o cualquier cosa que se desee clasificar. Los algoritmos de clasificación y reconocimiento son generalmente implantados en una computadora digital o en un dispositivo de cálculo específico, de manera que se tenga reconocimiento y clasificación automática de los patrones sin intervención humana [The89].

En la figura 1.4 se muestra el esquema de un sistema de reconocimiento y clasificación. La entrada  $E$  es producida por el sistema físico y a través de un sistema de adquisición se transforma en un vector de entrada  $\bar{x}$  al sistema de reconocimiento y clasificación. El vector  $\bar{x}$  es transformado en un vector  $\bar{y}$  y cuyas componentes son llamadas rasgos. Es deseable que exista menor número de rasgos que de observaciones pero es necesario que los rasgos contengan en su conjunto la mayor parte de la información

necesaria para hacer su clasificación. Finalmente el sistema clasificador obtiene una salida  $w$  que corresponde a la clase a la cual pertenece la entrada  $E$ .




Figura 1.4.

Los procedimientos de extracción de rasgos característicos pueden estar basados en la intuición o en consideraciones físicas del problema específico, o simplemente ser técnicas matemáticas que reduzcan la dimensión del espacio de observación.

Al hacer extracción de rasgos, la complejidad computacional del clasificador se reduce al manejar datos en un espacio de dimensión menor. Sin embargo, el desempeño del clasificador dependerá de la cantidad de información que se pierda en el proceso de extracción de rasgos.

## ESTIMACION PARAMETRICA

---

2

---

### 2.1. Fundamentos de Probabilidad.

En el procesamiento de señales aleatorias y en el análisis de procesos estocásticos es indispensable hacer uso de las propiedades estadísticas de las señales a través del uso de valores promedios y, en general, momentos de las señales.

La teoría de la probabilidad tiene que ver con promedios de fenómenos que ocurren, ya sea secuencial o simultáneamente en nuestro mundo. Algunos de estos fenómenos se refieren a problemas de todos los días como podrían ser el número de llamadas diarias en un teléfono, los juegos de azar, las estadísticas de población, la detección de señales, el análisis del ruido, etc. Durante el estudio de los fenómenos antes mencionados, se ha podido observar que algunos promedios tienden a un valor constante a medida que el número de observaciones crece, y también se ha visto que este valor no varía si es obtenido a partir de diferentes conjuntos de experimentos, siempre y cuando pertenezcan al mismo fenómeno. Uno de los propósitos de la teoría de la probabilidad es el de describir y predecir dichos promedios en términos de probabilidades de eventos.

Utilizando la teoría de conjuntos en la teoría de la probabilidad, el espacio total está formado por elementos que son resultados de un experimento. Un experimento es una secuencia de acciones que produce ciertos resultados, desconocidos hasta el momento del experimento. El espacio muestral es el conjunto de todos los posibles resultados de un experimento. Entonces los resultados corresponden a elementos de un conjunto y el espacio muestral corresponde a  $\mathcal{S}$ , el espacio total. Un evento puede ser definido como una colección de resultados. Por tanto, un evento es un conjunto, o subconjunto del espacio muestral  $\mathcal{S}$ . Se dice que un evento  $A$  ocurrió si el resultado del experimento es un elemento del conjunto  $A$ .

La probabilidad de un evento  $A$  es un número  $P(A)$  asignado a tal evento. Este número puede ser interpretado de la siguiente manera: Si el experimento es realizado  $n$  veces y el evento  $A$  ocurre  $n(A)$  veces, entonces, la frecuencia relativa  $n(A)/n$  de ocurrencia de  $A$  es muy cercana a  $P(A)$ ,

$$P(A) \approx \frac{n(A)}{n} \quad (2.1)$$

siempre que  $n$  sea suficientemente grande [Pap84].

La definición anterior aunque carece de precisión, nos da una buena idea del concepto de probabilidad y a la vez nos lleva a la trágica conclusión de que la probabilidad, como cualquier otra teoría física, se relaciona a los fenómenos reales de manera inexacta. Esto no quiere decir que la teoría de la probabilidad sea inexacta, muy al contrario, está basada en axiomas muy bien definidos a partir de los cuales se desarrollan sus diversos conceptos, y siempre con el máximo rigor matemático.

Para definir la probabilidad tenemos que hacer uso de los siguientes conceptos: Existe un espacio probabilístico  $\mathcal{Y}$  llamado evento seguro. El evento seguro ocurre siempre en cada prueba, ya que  $\mathcal{Y}$  contiene a todos los posibles resultados del experimento. Una prueba es la ejecución de un experimento una vez. El evento  $\emptyset$  se llama evento imposible y es aquel que se considera que nunca ocurre. En cada prueba ocurre un resultado  $\zeta(i)$ , llamado evento elemental. Se dice que un evento  $A$  ocurre en una prueba si contiene al evento  $\zeta(i)$ . La unión  $A + B$  de dos eventos  $A$  y  $B$  es el evento que ocurre cuando  $A$  ó  $B$ , o ambos ocurren. La intersección  $AB$  de dos eventos  $A$  y  $B$  es el evento que ocurre cuando  $A$  y  $B$  ocurren. Los eventos  $A$  y  $B$  son mutuamente excluyentes si la ocurrencia de uno excluye la ocurrencia del otro, esto es  $AB = \emptyset$ . Existe un evento  $\bar{A}$ , llamado el complemento de  $A$  que ocurrirá siempre que  $A$  no ocurra. [Pap84]

La teoría de la probabilidad se basa únicamente en los siguientes tres axiomas:

$$I) \quad P(A) \geq 0 \quad (2.2)$$

$$II) \quad P(\mathcal{Y}) = 1 \quad (2.3)$$

$$III) \quad \text{Si } AB = \emptyset,$$

$$P(A + B) = P(A) + P(B) \quad (2.4)$$

En el desarrollo de la teoría de la probabilidad, todas las conclusiones están basadas directa o indirectamente en estos axiomas y únicamente en ellos. Algunos corolarios son los siguientes:

$$P(\emptyset) = 0 \quad (2.5)$$

$$P(A) = 1 - P(\bar{A}) \quad (2.6)$$

$$P(A + B) = P(A) + P(B) - P(AB) \leq P(A) + P(B) \quad (2.7)$$

La probabilidad de que ocurra un evento  $A$ , dado que ocurrió un evento  $B$  se conoce como la probabilidad condicional de  $A$  dado  $B$  y se define como,

$$P(A|B) = \frac{P(AB)}{P(B)} \quad (2.8)$$

suponiendo que  $P(B) > 0$ .

La probabilidad de la intersección de dos eventos se deriva de la ecuación (2.8) y es de la siguiente forma,

$$P(AB) = P(A|B)P(B) \quad (2.9)$$

Si los eventos  $A_1, A_2, \dots, A_n$  son mutuamente excluyentes y además  $A_1 + A_2 + \dots + A_n = S$ , entonces

$$P(S) = P(SA_1) + P(SA_2) + \dots + P(SA_n) \quad (2.10)$$

Aplicando la ecuación (2.9) tenemos que,

$$P(S) = P(S|A_1)P(A_1) + P(S|A_2)P(A_2) + \dots + P(S|A_n)P(A_n) \quad (2.11)$$

llamado teorema de probabilidad total.

Utilizando las ecuaciones (2.8) y (2.9) se observa que

$$P(A_1|S) = P(S|A_1) \frac{P(A_1)}{P(S)} \quad (2.12)$$

Sustituyendo la ecuación (2.11) en (2.12) obtenemos el Teorema de Bayes:

$$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \dots + P(B|A_n)P(A_n)} \quad (2.13)$$

Con estos conceptos de la teoría de la probabilidad, podemos introducir las nociones de la teoría de la detección y la estimación.

## 2.2. Teoría de la Detección y de la Estimación.

Para comprender la teoría de la detección y de la estimación, asociaremos directamente un problema de comunicaciones en el cual se puedan observar de manera real los componentes de un problema de detección y estimación cualquiera: En el ejemplo de la figura 2.1, donde se tiene una fuente que genera dígitos cada  $T$  segundos y se requiere transmitir esa información a algún lugar a través de un canal apropiado, tendremos el problema de decidir, una vez recibida cierta señal, cuál de los posibles dígitos fue el generado.

Los problemas de teoría de la detección se caracterizan por el hecho de que se debe de decidir cuál de varias alternativas, es la verdadera. Cuando existen sólo dos alternativas (0 ó 1) se tiene un problema de detección binaria. Por supuesto, si existen  $M$  alternativas, se tratará de un problema de detección  $M$ -aria.




Figura 2.1.

El área de la teoría de la estimación es paralela a la de la detección. Siguiendo con el ejemplo antes mencionado, ahora en la figura 2.2, la fuente produce un mensaje analógico  $a(t)$ . Para que el mensaje sea transmitido, primero es pasado a través de un muestreador. Cada  $T$  segundos se transmitirá una señal que tendrá algún parámetro relacionado a la muestra más reciente. Durante cada intervalo, el receptor tratará de estimar  $A_n$  (la amplitud de la muestra  $n$ ).






Figura 2.2.

Como puede verse, la diferencia esencial entre detección y estimación es que en la detección los valores sugeridos por el receptor son finitos, y éste puede "acertar" o "equivocar", mientras que en la estimación, habiendo un número infinito de valores posibles, será en muy pocas ocasiones cuando el receptor esté exactamente correcto, pero tratará la mayoría del tiempo de estar muy cerca.

Cuando se tiene un problema en el cual se requiere estimación continua (sin muestreo), se trata de la teoría de la modulación, aunque algunos autores prefieren llamarla "Estimación de onda continua" para hacer una analogía con los conceptos de detección y estimación. [Van68]

Los componentes básicos de un problema de decisión se pueden encontrar en la figura 2.3.

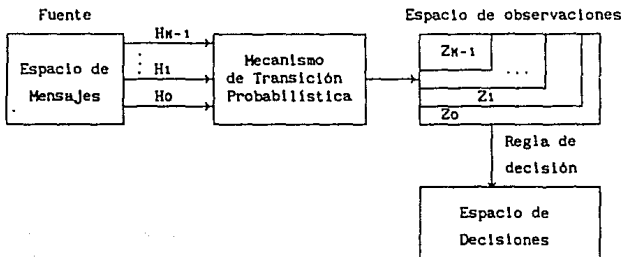


Figura 2.3.

La fuente es la generadora de alguna de las opciones contenidas dentro del espacio de mensajes. A estos mensajes se les conoce como hipótesis y en el caso general existen  $M$  opciones, y se les denomina  $H_0, H_1, \dots, H_{M-1}$ . Generalmente, se desconoce cuál de las hipótesis es la verdadera.

El mecanismo de transición probabilística conoce la hipótesis correcta y genera un punto dentro del espacio de observaciones de acuerdo con cierta ley de probabilidad. Un ejemplo de un mecanismo de transición probabilística sería un canal que agrega ruido, con cierta densidad  $p(n)$ , a la señal transmitida.

En problemas de detección clásicos, las observaciones vectoriales que consisten en una encaja, pueden ser representadas puntualmente en un espacio  $N$ -dimensional. Después de observar el resultado en el espacio de observaciones, con particiones  $Z_i$ , se debe decidir qué hipótesis es la verdadera. Para esto, se desarrolla una regla de decisión que asocia a cada punto  $r$  del espacio de observaciones, con una de las hipótesis.

Consideremos el problema binario en el que cada una de las dos salidas de la fuente corresponde a una hipótesis, y cada hipótesis se mapea en un punto del espacio de observaciones. Si consideramos que las observaciones consistirán de un conjunto de  $N$  números, cada conjunto puede ser representado como un punto  $r$  en un espacio  $N$ -dimensional y se denota vectorialmente como:

$$r = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_N \end{bmatrix} \quad (2.14)$$

El mecanismo de transición probabilística genera puntos de acuerdo con las densidades de probabilidad condicional  $p(r|H_1)$  y  $p(r|H_0)$ .

Para elaborar un criterio de decisión se debe primero enumerar los posibles resultados de la toma de decisión. Para el caso binario, cuatro cosas pueden suceder:

1. Que  $H_0$  sea verdadera y se escoja  $H_0$ .
2. Que  $H_0$  sea verdadera y se escoja  $H_1$ .
3. Que  $H_1$  sea verdadera y se escoja  $H_1$ .
4. Que  $H_1$  sea verdadera y se escoja  $H_0$ .

En este caso, la primera y tercera alternativa corresponden a un acierto, mientras que la segunda y la cuarta se tratan de un error. El propósito de un criterio de decisión es poder dar cierto peso a cada uno de las alternativas.

### 2.3. Estimación por Máxima Verosimilitud.

El criterio que utilizaremos para desarrollar el estimador de máxima verosimilitud es el Criterio de Bayes, y se basa en dos suposiciones. La primera dice que la fuente generadora está gobernada por una ley de probabilidad tal que  $H_0$  tiene una probabilidad de ocurrencia  $P_0$  y  $H_1$  una probabilidad  $P_1$ . Tratándose de un problema binario  $P_0 + P_1 = 1$ .  $P_0$  y  $P_1$  se conocen como las probabilidades a priori y se obtienen de un estudio de la fuente generadora. La segunda suposición indica que un costo se asigna a cada una de las opciones. El costo  $C_{ij}$  corresponde a la elección de la opción  $i$  a partir de que  $j$  es la verdadera. Cada vez que se hace una observación, se evalúa el costo.

El objetivo es diseñar una regla de decisión que mantenga el costo promedio lo más bajo posible. El valor esperado del costo se conoce como riesgo ( $R$ ) y se define en el caso binario como:

$$\begin{aligned}
 R = & C_{00} P_0 \Pr(\text{escoger } H_0 \mid H_0 \text{ verdadera}) \\
 & + C_{10} P_0 \Pr(\text{escoger } H_1 \mid H_0 \text{ verdadera}) \\
 & + C_{11} P_1 \Pr(\text{escoger } H_1 \mid H_1 \text{ verdadera}) \\
 & + C_{01} P_1 \Pr(\text{escoger } H_0 \mid H_1 \text{ verdadera}).
 \end{aligned}
 \tag{2.15}$$




Figura 2.4.

Se toma en cuenta la configuración de la figura 2.4. Si se expresan las probabilidades en función del mecanismo de transición, y teniendo en cuenta que se debe elegir  $Z_0$  y  $Z_1$  de manera que siempre exista una decisión. Se debe asignar cada punto  $r$  al espacio de observaciones  $Z$  ya sea en  $Z_0$  o en  $Z_1$ . Se tiene entonces que:

$$Z = Z_0 + Z_1 = Z_0 \cup Z_1 \tag{2.16}$$

Además es lógico asumir que el costo de un acierto es menor al costo de un error, así se puede suponer que:

$$\begin{aligned} C_{10} &> C_{00} \\ C_{01} &> C_{11} \end{aligned} \quad (2.17)$$

Todo esto nos proporciona una manera sencilla de expresar el riesgo en función de las probabilidades de transición y de una sola de las regiones,

$$\begin{aligned} R = & P_0 C_{10} + P_1 C_{11} \\ & + \int_{Z_0} \left\{ P_1 (C_{01} - C_{11}) p(r|H_1) \right. \\ & \left. - \left[ P_0 (C_{10} - C_{00}) p(r|H_0) \right] \right\} dr \end{aligned} \quad (2.18)$$

donde  $P_0 C_{10} + P_1 C_{11}$  no es función de  $Z_0$  y por lo tanto no se incluyen en la minimización de  $R$ , y la integral representa el costo controlado por aquellos puntos  $r$  que se asignan a  $Z_0$ .

Las condiciones (2.17) hacen que los dos términos de la integral de la ecuación (2.18) sean positivos. Si analizamos esta integral, observamos que: (a) Los valores de  $R$  para los que el segundo término de la integral es mayor al primero, deben ser asignados a  $Z_0$  ya que hacen un término negativo más negativo y por lo tanto se reduce el costo. (b) A los valores de  $r$  que hacen que el primer término sea mayor al segundo es necesario excluirlos de  $Z_0$  para que el costo se minimice.

En resumen, si

$$P_1 (C_{01} - C_{11}) p(r|H_1) > P_0 (C_{10} - C_{00}) p(r|H_0) \quad (2.19)$$

se asigna  $r$  a  $Z_1$  y por lo tanto, la hipótesis  $H_1$  es la verdadera, en caso contrario  $H_0$  será la verdadera.

Reescribiendo (2.19) y tomando en cuenta lo anterior,

$$\frac{p(r|H_1)}{p(r|H_0)} \begin{matrix} H_1 \\ > \\ < \\ H_0 \end{matrix} > \frac{P_0 (C_{10} - C_{00})}{P_1 (C_{01} - C_{11})} \quad (2.20)$$

Razón de verosimilitud  $\Lambda(r)$                       umbral  $\eta$

A partir de lo anterior tenemos lo que se conoce como la prueba de la razón de verosimilitud.

$$\begin{array}{l}
 H_1 \\
 A(r) > \eta \\
 < \eta \\
 H_0
 \end{array}
 \quad (2.21)$$

La expresión (2.21) nos da bastante flexibilidad para dejar variables los costos a priori ya que como se observa, el umbral  $\eta$  se involucra sólo en la decisión final y no en el cálculo de  $A(r)$ , por lo que se puede fijar arbitrariamente hasta el momento final.

Una prueba equivalente se obtiene tomando logaritmo natural por ambos lados (es posible debido a que ambos lados son positivos), la prueba será:

$$\begin{array}{l}
 H_1 \\
 \ln A(r) > \ln \eta \\
 < \ln \eta \\
 H_0
 \end{array}
 \quad (2.22)$$

Para generalizar este estimador a un problema de hipótesis compuestas, en el cual el valor del parámetro que caracteriza a la hipótesis puede tener valores dentro de un rango, planteamos el esquema de la figura 2.5 para el nuevo problema.

La fuente genera un conjunto de parámetros, el cual es visto como un punto en el espacio  $\chi$  y se denota como  $\theta$ . Las hipótesis son subespacios de  $\chi$ . La densidad de probabilidad que gobierna el mapeo del espacio de parámetros al espacio de observaciones se denomina  $p(r|\theta)$  y se asume conocida para todos los valores de  $\theta$  en  $\chi$ .




Figura 2.5.

Un procedimiento recomendado por Van Trees [Van68] es estimar  $\theta$  asumiendo que  $H_1$  es verdadera, y después estimar  $\theta$  asumiendo que  $H_0$  es verdadera, y usar estas estimaciones en una prueba de la razón de verosimilitud como si fueran correctas. Si se utiliza el estimador de máxima verosimilitud, el resultado se conoce como prueba de la Razón Generalizada de Verosimilitud (RGV), y es de la siguiente manera,

$$\Lambda_0(r) = \frac{\max_{\theta_1} p(r|\theta_1)}{\max_{\theta_0} p(r|\theta_0)} \quad \begin{array}{l} H_1 \\ > \\ < \\ H_0 \end{array} \quad \gamma \quad (2.23)$$

donde  $\theta_1$  varía sobre todas las  $\theta$  en  $H_1$  y  $\theta_0$  varía sobre todas las  $\theta$  en  $H_0$ . Lo que se hace en la ecuación (2.23) es hacer una estimación de máxima verosimilitud de  $\theta_1$ , asumiendo que  $H_1$  es verdadera, y entonces se evalúa  $p(r|\theta_1)$  para  $\theta_1 = \hat{\theta}_1$  y se usa su valor en el numerador. El denominador es calculado de una manera similar. El umbral  $\gamma$  es un valor arbitrario que se fija de acuerdo con los costos a priori.

#### 2.4. Estimación por Mínimos Cuadrados.

En este método se tiene la suposición de que la entrada es completamente desconocida y por tanto la predicción de la señal  $s[n]$  se hace únicamente a partir de la sumatoria de valores pasados ponderados, esta aproximación será  $\tilde{s}[n]$  donde

$$\tilde{s}[n] = - \sum_{k=1}^p \alpha_k s[n-k] \quad (2.24)$$

El error de predicción  $e[n]$  estará dado por

$$e[n] = s[n] - \tilde{s}[n] = s[n] + \sum_{k=1}^p \alpha_k s[n-k] \quad (2.25)$$

En el método de los mínimos cuadrados los parámetros  $\alpha_k$  se obtienen al minimizar la media del error total al cuadrado con respecto a cada uno de los parámetros. Para una explicación más detallada referirse a [Mak75].

El procedimiento anterior nos lleva a las ecuaciones normalizadas para los coeficientes del predictor,

$$\sum_{k=1}^p \alpha_k R(i-k) = -R(i), \quad i = 1, \dots, p \quad (2.26)$$

En forma matricial (por facilidad  $R(1) = R_1$ ),

$$\begin{bmatrix} R_0 & R_1 & R_2 & \dots & R_{p-1} \\ R_1 & R_0 & R_1 & \dots & R_{p-2} \\ R_2 & R_1 & R_0 & \dots & R_{p-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ R_{p-1} & R_{p-2} & R_{p-3} & \dots & R_0 \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \alpha_3 \\ \vdots \\ \alpha_p \end{bmatrix} = - \begin{bmatrix} R_1 \\ R_2 \\ R_3 \\ \vdots \\ R_p \end{bmatrix} \quad (2.27)$$

A partir de aquí sólo se requiere obtener la solución de  $\alpha_k$ , la cual se puede obtener de diferentes maneras que serán mencionadas en las siguientes secciones. Una guía bastante completa de las diferentes soluciones (recursivas en orden y en tiempo) de estas ecuaciones, se encuentra en [Fri82] y [Aic86].

#### 2.4.1 Algoritmos Globales

En los algoritmos globales se parte del hecho de que se van a procesar todos los datos fuera de línea, es decir no hay problemas de tiempo real. Los valores de la señal se conocen para todo tiempo en cualquier momento del análisis ya que se tienen almacenados en alguna memoria.

Los parámetros  $\alpha_k$  se pueden obtener resolviendo  $p$  ecuaciones con  $p$  incógnitas (Ecuaciones de Yule-Walker), sin embargo existen métodos que facilitan el cálculo de los parámetros  $\alpha_k$  del predictor, que se basan en las características del la matriz de coeficientes, la cual es del tipo Toeplitz, es decir, es simétrica y los elementos en cualquier diagonal son idénticos. Existe un algoritmo basado en los trabajos de Levinson y Durbin para llegar a una solución rápida, en la tabla 2.1. se describe. Este algoritmo es recursivo en orden ya que los parámetros para un orden  $i$  se obtienen a partir de los parámetros para un orden  $i-1$ .

De esta manera se tendrán los parámetros del predictor para todos los ordenes inferiores a  $p$  y se tendrá el valor del error de predicción también para ordenes  $p$  e inferiores.

Este algoritmo se encuentra programado y su listado se proporciona en el apéndice 2.

Tabla 2.1. : Algoritmo de Levinson-Durbin

$$\begin{aligned}
 (1) \quad E_0 &= R(0) \\
 (2) \quad K_i &= - \frac{R(1) + \sum_{j=1}^{i-1} a_j^{(i-1)} R(1-j)}{E_{i-1}} \\
 (3) \quad a_1^{(i)} &= K_i \\
 a_j^{(i)} &= a_j^{(i-1)} + K_i a_{i-j}^{(i-1)}, \quad 1 \leq j \leq i-1 \\
 (4) \quad E_i &= (1 - K_i^2) E_{i-1} \\
 (5) \quad &\text{Repetir (2), (3) y (4) para } i = 1, 2, \dots, p. \\
 (6) \quad &\text{La solución será } a_j = a_j^{(p)}, \quad 1 \leq j \leq p.
 \end{aligned}$$

#### 2.4.2. Algoritmos Recursivos en Tiempo.

Los algoritmos recursivos en tiempo se utilizan en aplicaciones en línea donde el tiempo real es una de las principales preocupaciones. Los valores de la señal se conocen sólo para el tiempo actual y para el pasado, pero generalmente los valores pasados no se guardan, es preferible guardar el valor de los parámetros para los tiempos pasados, y de esa manera llegar a algoritmos que nos determinen el valor de los parámetros para un tiempo  $t$  a partir de los valores de los parámetros para un tiempo  $t-1$ . En [Alc86] se presenta una guía práctica del uso de este tipo de algoritmos y de su implantación en arquitecturas de cálculo.

En este trabajo se utilizan principalmente dos algoritmos de este tipo que fueron desarrollados en su versión desnormalizada, es decir que los parámetros no se encuentran en un rango de  $-1$  a  $1$ , por A. v. Brandt [Bra83].

Al primero se le conoce como Algoritmo de Covarianza en Escalera (Ladder) con Memoria Deslizante y al segundo como Algoritmo de Covarianza en Escalera con Memoria Creciente. Mientras que el de memoria creciente utiliza en cualquier tiempo  $t$  información sobre todos los valores pasados  $\{y_1, \dots, y_t\}$ , el de memoria deslizante sólo toma en cuenta para su



predicción, valores dentro de una ventana de valor fijo  $L$  que se desliza a través de la señal  $(y_{t-L-p+1}, \dots, y_t)$ .

Estos algoritmos aportan soluciones recursivas para las ecuaciones de covariancia para predicción lineal y fueron desarrollados en su forma normalizada por B. Porat et al. [Por82], sin embargo por razones del método de segmentación en el que se utilizarán (ver capítulo 4) se requiere que estos algoritmos proporcionen la energía de predicción residual, cosa que sucede en los no normalizados. En los algoritmos normalizados se puede obtener este tipo de parámetros, solo que se requiere un proceso de desnormalización. Los algoritmos normalizados tienen la ventaja de tener una dinámica entre menos uno y uno, lo que facilita su implantación en arquitecturas de cálculo con operaciones en punto fijo. Se recomienda hacer referencia a [Fri82] para una descripción muy completa de los algoritmos con estructuras Lattice en su parte de filtrado y de predicción.

En la tabla 2.2. se describe el algoritmo de memoria deslizante, para que este algoritmo converga, se requiere definir  $1/x = 0$  para  $x$  muy pequeñas [Bra83].

El algoritmo de memoria creciente, mostrado en la tabla 2.3., es generalmente usado en conjunto con el de memoria deslizante por lo que en su inicialización se requieren parámetros calculados por el primero.

Tabla 2.2.: Algoritmo de memoria deslizante

Inicialización en  $t = 0$ ;

$$\begin{cases} r_{n,t} = q_{n,t} = E'_{n,t} = R'_{n,t} = C'_{n,t} = 0 \\ \sigma_{n,t} = \pi_{n,t} = 1 \text{ para } n = 0, 1, \dots, p-1, p. \\ y_k = 0 \text{ para } k = -L+1, \dots, 0. \end{cases}$$

Para  $t = 1, 2, \dots, t_{\max}$ :

$$\begin{cases} e_{0,t} = r_{0,t} = y_t \\ d_{0,t} = q_{0,t} = y_{t-L} \\ \sigma_{0,t} = \pi_{0,t} = 1 \end{cases}$$

Para  $n = 0, \dots, p$ :

$$\begin{cases} E_{n,t} = E'_{n,t-1} + e_{n,t}^2 / \sigma_{n,t-1} \\ E'_{n,t} = E_{n,t} - d_{n,t}^2 / \pi_{n,t-1} \\ R_{n,t} = R'_{n,t-1} + r_{n,t}^2 / \sigma_{n,t-1} \\ R'_{n,t} = R_{n,t} - q_{n,t}^2 / \pi_{n,t-1} \\ C_{n,t} = C'_{n,t-1} + e_{n,t} r_{n,t-1} / \sigma_{n,t-1} \\ C'_{n,t} = C_{n,t} - d_{n,t} q_{n,t-1} / \pi_{n,t-1} \\ e_{n+1,t} = e_{n,t} - r_{n,t-1} C_{n,t} / R_{n,t} \\ d_{n+1,t} = d_{n,t} - q_{n,t-1} C_{n,t} / R_{n,t} \\ r_{n+1,t} = r_{n,t-1} - e_{n,t} C_{n,t} / E_{n,t} \\ q_{n+1,t} = q_{n,t-1} - d_{n,t} C_{n,t} / E_{n,t} \\ \sigma_{n+1,t} = \sigma_{n,t-1} - e_{n,t}^2 / E_{n,t} \\ \pi_{n+1,t} = \pi_{n,t-1} - d_{n,t}^2 / E_{n,t} \end{cases}$$

Tabla 2.3.: Algoritmo de memoria creciente

```

Para t = 1, 2, ..., tmax :
  SI Lt ≤ L entonces Fin
  SI Lt ≤ L+p+1 entonces:
    [
      n = Lt - L - 1
      SI n = 0 tómesese r0,t-1 del algoritmo de
        memoria deslizando y σ0,t-1 = π0,t-1 = 1
        y h0,t-1 = 0

      Tómesese En,t-1, R'n,t-1, C'n,t-1 y dn,t-1
        del algoritmo de memoria deslizando

      e0,t = r0,t = yt
      σ0,t = π0,t = 1
      h0,t = 0
      Para n = 0, ..., min(p, Lt - L)
        [
          En,t = En,t-1 + en,t2 / σn,t-1
          dn,t = dn,t-1 + en,thn,t-1 / σn,t-1
          e'n,t = en,t - dn,thn,t-1 / πn,t-1
          E'n,t = En,t - dn,t2 / πn,t-1
          σ'n,t = σn,t-1 - hn,t-12 / πn,t-1
          R'n,t = R'n,t-1 + rn,t-12 / σ'n,t
          C'n,t = C'n,t-1 + e'n,trn,t-1 / σ'n,t
          en+1,t = e'n,t - rn,t-1C'n,t / R'n,t
          rn+1,t = rn,t-1 - e'n,tC'n,t / E'n,t
          σn+1,t = σn,t-1 - en,t2 / En,t
          πn+1,t = πn,t-1 - dn,t2 / En,t
          hn+1,t = hn,t-1 - dn,ten,t / En,t
        ]
      Fin
    ]
  
```

## METODOS DE DETECCION DE CAMBIOS Y SEGMENTACION DE UNA SEÑAL

3

### 3.1. Descripción del Problema.

El interés por el problema de la detección de cambios, principalmente los que son abruptos, en las propiedades dinámicas de sistemas y señales ha ido creciendo de una manera importante en los últimos años.

Este tipo de detección es encontrado como complemento de técnicas adaptables en las que los sistemas contienen una estructura de procesamiento con ponderaciones o pesos variables, los cuales son ajustados frecuentemente para compensar cambios en las características de las señales. Tradicionalmente el ajuste se hace en intervalos regulares, de acuerdo a cierto algoritmo adaptable, con la desventaja de sólo tomar en cuenta las variaciones lentas de las señales.

Es importante conocer de antemano la dinámica de la señal para entender sus variaciones y cuantificarlas de una manera que permita tomar decisiones adecuadas a la magnitud del cambio. Es de gran utilidad caracterizar la señal de manera que se conozcan sus valores máximos y mínimos de amplitud y frecuencia, y también puede ser necesario hacer un estudio de las longitudes máximas y mínimas de los segmentos de interés.

En el análisis de señales no estacionarias, podemos utilizar métodos basados en modelos paramétricos estadísticos en los cuales uno o varios parámetros pueden cambiar abruptamente. Esto se hace bajo la suposición de que los parámetros del proceso se mantienen constantes por intervalos o segmentos de longitud arbitraria, y cuando alcanzan la frontera de dicho segmento cambian bruscamente.

En la figura 3.1 se puede ejemplificar el comportamiento típico de una señal que es estacionaria por segmentos. Como se puede observar, la señal observa un comportamiento durante las primeras 150 muestras que se

### Señal no estacionaria




Figura 3.1.

caracteriza por medio de un conjunto de parámetros  $\theta_1$ . En la muestra 150 existe un cambio de modelo y ahora la señal será caracterizada por un conjunto de parámetros  $\theta_2$  durante 200 muestras hasta llegar a la muestra 350 en donde vuelve a presentarse el modelo caracterizado por el conjunto de parámetros  $\theta_1$ . Como es posible observar a partir de la figura 3.1, las duraciones de un modelo son completamente arbitrarias y no siempre tienen la misma longitud en muestras.

Los problemas que se presentan en sistemas de control y de procesamiento de estas señales varían en enfoque pero esencialmente son [Bas88]:

(a).- En el caso de un sistema de reconocimiento o monitoreo de señales o imágenes, el interés primordial es detectar los cambios y localizar su posición en espacio o tiempo.

(b).- En detección de fallas en sistemas de control, el interés principal será poder actuar en el menor tiempo posible para cambiar la ley de control.

(c).- En la actualización de los pesos de un algoritmo adaptable, se deben localizar las variaciones abruptas en las características del sistema en análisis además de cuantificar la magnitud del cambio.

### 3.2. Metodología de Diseño de un Método de Segmentación.

En el diseño de algoritmos de detección y estimación de cambios, es necesario separar dos pasos muy importantes. El primer paso para el diseño de un algoritmo de segmentación es proponer una transformación en la señal a través de diversos filtros, de manera que se generen señales indicadoras de cambio, a veces conocidas como "residuales", en las cuales los cambios se hacen más obvios que en las señales originales. Generalmente se busca que en estas señales "artificiales", el valor promedio o sus propiedades espectrales, cambien cuando el sistema esté también cambiando. El segundo paso es el de proponer una regla de decisión basada en las señales residuales. Este problema consiste en diseñar el detector adecuado que monitoree los cambios reflejados por las señales residuales. En la figura 3.2 se esboza un diagrama a bloques de un algoritmo de detección de cambio de modelo en una señal.




Figura 3.2.

Al diseñar algoritmos de segmentación se debe de tomar en cuenta que las señales a las cuales serán aplicados tendrán las siguientes características: Las señales son altamente no estacionarias, de manera que algunas veces la señal tendrá variaciones lentas y suaves, pero otras veces el comportamiento será muy ruidoso. Algunos de los saltos que deberán de ser detectados, son de una magnitud muy por debajo de la amplitud de las variaciones de la señal en las partes ruidosas.

Dependiendo de la aplicación, a veces interesa que el procesamiento sea en línea (figura 3.3), mientras las nuevas muestras de la señal van entrando, o bien, si el tiempo real no es importante, el algoritmo puede trabajar en tandas o grupos de muestras fuera de línea (figura 3.4). Tomando en cuenta estas dos filosofías, se definen criterios de rendimiento de un algoritmo:

El primero de estos criterios sólo se puede aplicar al caso en que se trabaje en línea. Consiste en calificar que tan rápido detecta el algoritmo un cambio una vez que éste ha ocurrido, lo cual es muy importante en aplicaciones de detección de fallas en donde se debe de actuar inmediatamente. El que un algoritmo

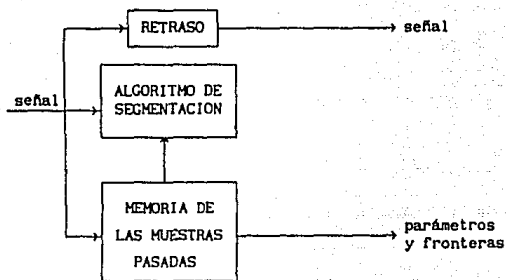


Figura 3.3.

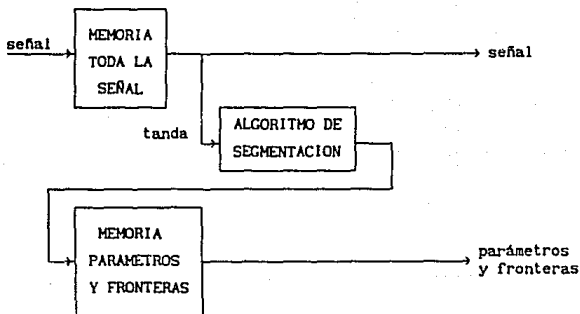


Figura 3.4.

cuenta con detección inmediata, puede conducir a que sea muy sensible a las falsas alarmas debido al poco tiempo que tiene para evaluar los valores de los parámetros.

El segundo criterio es precisamente el que indica la factibilidad que tiene un algoritmo a caer en una falsa alarma. Si la aplicación no demanda una gran rapidez en la detección de las fronteras, se puede conseguir entonces una baja incidencia de

falsas alarmas . Debido a que es imposible eliminar la posibilidad de una falsa alarma, al menos con intervalos de observación finitos, para analizar el rendimiento de un algoritmo con respecto a este criterio se debe de fijar un límite superior para la razón de falsas alarmas. Es también muy importante el que los segmentos cortos no pasen desapercibidos para el algoritmo, ya que se podría perder información (en aplicaciones de compresión de datos por medio de eliminación de redundancia).

El tercer criterio utilizado para evaluar estos algoritmos consiste en determinar la precisión con la cual se hace el ajuste entre el momento de la detección del cambio y la determinación del punto exacto en el tiempo en el que sucedió. En aplicaciones de procesamiento en línea este ajuste sólo puede ocurrir si se permite un retraso entre la detección y la decisión final sobre la localización del cambio. Este criterio es sumamente importante en aplicaciones en las cuales se requiere gran exactitud en la determinación de los segmentos como podría ser el reconocimiento de patrones.

Los algoritmos secuenciales de segmentación de señales, generalmente se basan en la comparación entre los parámetros de la señal dentro de una ventana fija, contra los parámetros de la misma señal dentro de otra ventana que va recorriendo la señal (figura 3.6), o creciendo en tamaño (figura 3.7). El desempeño de estos algoritmos dependerá, en gran manera, de la selección apropiada de las medidas de decisión, como también de una buena selección de ventanas que permita extraer el máximo de información de la señal. La robustez del algoritmo dependerá de si es capaz de realizar el análisis a un gran número de muestras con alta variabilidad, sin tener que cambiar los valores de los parámetros fijos (tamaño de la ventana, medidas de decisión).




Figura 3.6.






Figura 3.7.

Es importante también el hecho de que un algoritmo no se limite a detectar las fronteras de los segmentos basándose en tamaños predefinidos, sino que la detección de una frontera pueda ocurrir en posiciones arbitrarias que dependan únicamente del cambio en las estadísticas de la señal.

En el siguiente capítulo se presentan algunos de los métodos de segmentación más populares en sistemas de reconocimiento y clasificación y se pretende compararlos de acuerdo con las características antes mencionados.

# ESTUDIO COMPARATIVO DE ALGUNOS METODOS DE SEGMENTACION

4

## 4.1. Método de la Función de AutoCorrelación (FAC).

El método consiste en observar la señal  $s[n]$  a través de una ventana deslizante  $v[n]$  (ver figura 3.6). Cada vez que se empieza la búsqueda de un cambio, se coloca al principio de la señal una ventana fija. Si la diferencia entre la señal vista en la ventana fija, y la vista a través de la ventana deslizante es lo suficientemente grande, de acuerdo con un umbral preestablecido, entonces se traza una línea divisoria de segmentos y se coloca una nueva ventana fija al principio del nuevo segmento, repitiéndose el proceso a partir de aquí.

### 4.1.1. Prueba para Encontrar Porciones No Estacionarias.

Se utiliza una medida de diferencia que involucra una suma lineal del cambio porcentual en amplitud, más el cambio porcentual en frecuencia.

Tanto los cambios en amplitud como en frecuencia, son estimados a partir de las funciones de autocorrelación de referencia (FAC-REF) y de prueba (FAC-PRU).

La energía de la señal discreta  $s'[n]$  (ecuación (1.2)) se calcula haciendo uso de la ecuación (1.7), pero modificada para el caso de una señal discreta, de tal forma que:

$$E_{s'} = \sum_{n=0}^{N-1} (s'[n])^2 \quad (4.1)$$

Por otro lado, si calculamos el valor de la autocorrelación utilizando la ecuación (1.3), para un retraso de 0,  $R[0]$ , de la misma

señal  $s' [n]$  tendremos:

$$R [0] = \sum_{n=0}^{N-1} s' [n] s' [n+0] = \sum_{n=0}^{N-1} (s' [n] s' [n]) = \sum_{n=0}^{N-1} (s' [n])^2 \quad (4.2)$$

Comparando las ecuaciones (4.1) y (4.2) obtenemos que,

$$E_s' = R [0] \quad (4.3)$$

Como la energía es de cierta manera una medida de amplitud al cuadrado, podemos definir una medida de amplitud basada en la diferencia porcentual de la raíz cuadrada de la energía de la señal de referencia y la de prueba.

Las energías correspondientes de estas dos ventanas serán:

$$E_{Ref} = R_R [0] \quad (4.4)$$

$$E_{Pru} = R_P [0] \quad (4.5)$$

La distancia porcentual de amplitud (DPA) se define como:

$$DPA = \frac{\left| \sqrt{R_R [0]} - \sqrt{R_P [0]} \right|}{\min \left\{ \sqrt{R_R [0]}, \sqrt{R_P [0]} \right\}} \quad (4.6)$$

Donde:

$$\min \left\{ \sqrt{R_R [0]}, \sqrt{R_P [0]} \right\} = \begin{cases} \sqrt{R_R [0]} & ; \text{ si } R_R [0] \leq R_P [0] \\ \sqrt{R_P [0]} & ; \text{ si } R_P [0] < R_R [0] \end{cases} \quad (4.7)$$

La función de autocorrelación da cierta información acerca del contenido frecuencial de la señal, al observar la rapidez con la que  $R [l]$  cae de un valor máximo hasta su primer cruce con cero. Esta caída no es en línea recta, es por ésto que el valor de la pendiente no se utiliza, y en

su lugar, una medida de área bajo la curva normalizada es introducida como comparación frecuencial.

Si se tienen las siguientes funciones de autocorrelación normalizadas para las ventanas de referencia (figura 4.1) y de prueba (figura 4.2), donde la normalización se hace de la siguiente manera:

$$r [i] = \frac{R [i]}{R [0]} \quad (4.8)$$




Figura 4.1.




Figura 4.2.

Para estimar la diferencia porcentual de frecuencia (DPF) se puede comparar la diferencia de áreas contra el área común.

$r^A [0]$  y  $r^P [0]$  son funciones discretas, su equivalente cortado hasta el primer cruce con cero se denomina  $r^A [1]$  y  $r^P [0]$  respectivamente, siendo  $q_A$  y  $q_P$  el valor de  $i$  para cada cruce,  $q$  será la mayor. El área bajo este tipo de curva discreta se calcula de la siguiente forma:




Figura 4.3.

Cada una de las áreas  $a_j$  de la figura 4.3 se calcula sumando un rectángulo de base 1 con un triángulo de la misma base.

$$\begin{aligned}
 a_1 &= Y[1] + \frac{Y[0] - Y[1]}{2} \\
 a_2 &= Y[2] + \frac{Y[1] - Y[2]}{2} \\
 a_{q-1} &= Y[q-1] + \frac{Y[q-2] - Y[q-1]}{2} \\
 a_q &= Y[q] + \frac{Y[q-1] - Y[q]}{2}
 \end{aligned} \tag{4.9}$$

El área total es la suma de las ecuaciones (4.9),

$$\text{Area} = \sum_{j=1}^q a_j = \sum_{j=1}^q Y[j] + \frac{Y[0] - Y[q]}{2} \tag{4.10}$$

Para este caso  $Y[0] = 1$  y  $Y[q] = 0$ , entonces la ecuación (4.10) se convierte en:

$$\text{Area} = \sum_{j=1}^q Y [j] + 0.5 \quad (4.11)$$

$B$  es igual a la diferencia positiva de áreas, es decir  $\text{Area}_R$  menos  $\text{Area}_P$ , es evidente, tomando en cuenta la figura 4.4 que:




Figura 4.4.

$$B = \sum_{j=1}^q \left| r^{\circ R} [j] - r^{\circ P} [j] \right| \quad (4.12)$$

$C$  es el área común (figura 4.5), y puede calcularse como el área bajo la curva formada por los valores mínimos de cada  $l$ .




Figura 4.5.

$$C = \sum_{j=1}^q \min \left\{ r^{\circ R} [j], r^{\circ P} [j] \right\} + 0.5 \quad (4.13)$$

De esta manera se tiene que,

$$DPF = \frac{B}{C} \quad (4.14)$$

Los niveles críticos de amplitud (NCA) y frecuencia (NCF) se fijan independientemente, sin embargo, son generalmente iguales para obtener mejores resultados. [Mic79]

Podemos definir la diferencia total (DT) entre las señales de prueba y de referencia como:

$$DT = \frac{DPA}{NCA} + \frac{DPF}{NCF} \quad (4.15)$$

Esta diferencia es significativa en el momento en que es mayor al valor de umbral normalizado (generalmente igual a uno).

#### 4.1.2. Estimación de la Posición de las Fronteras.

El punto en el tiempo ( $t$ ) en el cual el valor de umbral se sobrepasa es únicamente un valor de referencia, y está desplazado de la frontera real. Aún cuando los cambios son muy bruscos, el desplazamiento  $D(t)$  puede variar entre cero y toda una longitud de ventana  $N$ .

Conforme desplazamos la ventana en la vecindad de  $t$  se debe tomar la diferencia que existe entre las áreas de las funciones no normalizadas (de esta manera el área da información tanto de amplitud como de frecuencia) de referencia y una auxiliar que se mueve más allá que la de prueba.

$$A(x) = \text{Area } R - \text{Area } Aux \quad (4.16)$$

$$A(x) = \sum_{n=0}^{N-1} \left| R_n [n] - R_{Aux} [n] \right| \quad (4.17)$$

donde  $N$  es el tamaño de la ventana.

Haciendo una interpolación lineal encontramos el desplazamiento  $D(t)$  que existe entre el punto de detección y la posición estimada de la frontera.

$$D(t) = \frac{M \times A(t)}{\max\{A(x)\}} \quad x \in [t, t+M] \quad (4.18)$$

Así obtenemos la posición del nuevo segmento relativa al punto de referencia  $t$ .

#### 4.2. Método de la Medida de Error eSpectral (MES).

El método está basado en la observación del comportamiento de un modelo autoregresivo asociado a la señal. Se utiliza una ventana fija de longitud constante como referencia para calcular los parámetros AR. Con estos parámetros se define un filtro MA con el cual, al ser aplicada la señal, se determina el error de predicción. Si la señal aplicada al filtro es de la misma naturaleza paramétrica que la señal con que se calcularon los parámetros, el error de predicción será un ruido blanco. Si por el contrario, el error de predicción pierde "blancura", será un síntoma de que existe un cambio de modelo AR.

A continuación, se define una ventana deslizante del tipo de la descrita en la figura 3.6 pero con la diferencia que la ventana fija de prueba se sitúa en la señal  $s[n]$  mientras que la deslizante recorre la señal de error de predicción. Al contenido de la ventana deslizante se le aplica una prueba de "blancura" que consiste en obtener una medida de error espectral a partir de los valores de la autocorrelación de la ventana deslizante. Una frontera será hallada cuando se sobrepase un cierto umbral prefijado del valor de la medida de error espectral, y a partir de esta frontera se repetirá el procedimiento.

##### 4.2.1. Prueba para Encontrar Porciones No Estacionarias.

A partir de la ventana fija en la señal se calculan la FAC de orden  $p$ , usando el algoritmo de Levinson-Durbin (Tabla 3.1.) se calcula el filtro de predicción lineal correspondiente, también de orden  $p$ . Así se tendrán los parámetros estimados de la ventana de referencia:

$$\theta^T = [a_0, a_1, \dots, a_p] \quad (4.19)$$



A partir de los valores de la señal se calcula el error de predicción (EP) de la siguiente manera:

$$e(t) = \sum_{k=0}^p a_k s(t-k) \quad (4.20)$$

Una vez que se tiene el error de predicción de la señal se define una ventana deslizante de prueba que se movera a través de los valores del error y no de la señal como en el método FAC. Aquí los valores del error son los residuales de los que hablamos en el capítulo 3.

A los valores del error de predicción que entren dentro de la ventana deslizante se les extrae su función de autocorrelación de acuerdo con la siguiente expresión [Bod77].

$$r(n,m) = \frac{1}{2N+1} \sum_{k=0}^{N-m} e(n+k) e(n+k+m) \quad (4.21)$$

para que a partir de ella se tome una medida de error espectral al comparar esta FAC a la asociada a la primera ventana de referencia.

Una vez calculada la FAC del error para la primera ventana de referencia, se pueden calcular la siguientes de manera recursiva siempre y cuando la ventana se deslice de una en una muestra. La expresión es la siguiente:

$$r(n,m) = r(n-1,m) + e(n+N) e(n+N-m) - e(n-N-1) e(n+m-N-1) \quad (4.22)$$

La MES (Medida de Error eSpectral) se obtiene de la siguiente forma [App84] y [Bod77]:

$$MES_n = \left[ \frac{r(0;0)}{r(n;0)} - 1 \right]^2 + 2 \sum_{k=1}^K \left[ \frac{r(n;k)}{r(n;0)} \right]^2 \quad (4.23)$$

donde  $n$  es el momento en el tiempo en que se sitúa la ventana móvil con respecto a la de referencia y  $k$  es el índice de la FAC.

El primer término de la MES representa los cambios en la potencia total del EP y el segundo término depende del cambio del contorno espectral.

Una vez que la MES sobrepasa un cierto valor de umbral de segmentación (US) predefinido, se considera que existe un cambio en la mitad de la ventana deslizante, y se inicia el análisis a partir de este punto.

### 4.3. Método de la Razón Generalizada de Verosimilitud (RGV).

Este método tiene algunas diferencias significativas con respecto a los dos anteriormente descritos. El algoritmo consiste en una ventana de referencia que crece al ritmo en que nuevas muestras entran al sistema, mientras no exista detección de un cambio.

La ventana de prueba es de tamaño fijo y se desliza inmediatamente después de la de referencia. Este esquema es muy parecido al de la figura 3.7 sólo que se invierten las posiciones de la ventana que crece con respecto a la que no crece, y al estar la ventana que no crece después de la que crece. La primera se desliza a través de la señal. Este esquema se muestra en la figura 4.6.




Figura 4.6.

La ventaja de este esquema es el hecho de que la ventana de referencia al crecer, contiene el máximo de información disponible de el segmento que se toma como referencia. Esto hace que la estimación de los parámetros de referencia se haga con la mínima variación posible.

A partir de la ventana de referencia, la ventana de prueba deslizante y una tercera ventana formada por la suma de las dos anteriores, se forman tres señales para las cuales sus parámetros  $AR$  pueden ser calculados recursivamente por medio de los algoritmos Ladder descritos en el capítulo 2. Como resultado de los algoritmos Ladder obtendremos tres diferentes cantidades correspondientes a los errores de predicción de cada caso.

Una vez que se tienen las tres medidas de error de predicción, se deriva una medida de distancia  $d(n)$  que según [Bra84] es equivalente a una prueba de razón de verosimilitud logarítmica (ecuación (2.22)) siempre y cuando se haga la suposición de que las distribuciones de probabilidad

de los errores de predicción sean gaussianas. Esta distancia es utilizada para la detección de fronteras así como para la determinación exacta de ellas.

#### 4.3.1. Prueba para Encontrar Porciones No Estacionarias.

El modelo estadístico de la señal puede ser determinado a partir de la ecuación (2.25) despejando  $s[n]$ ,

$$s[n] = \sum_{k=1}^p \alpha_k s[n-k] + e[n] \quad (4.24)$$

donde el error de predicción  $e[n]$  es una secuencia gaussiana con media igual a cero y su variancia es,

$$\text{var}(e[n]) = \sigma^2 \quad (4.25)$$

un valor constante dentro del mismo segmento.

El modelo representado por las ecuaciones (4.24) y (4.25) está parametrizado por medio del vector  $\theta$  definido por:

$$\theta = (\theta^T, \varphi^T) \quad (4.26)$$

donde  $\theta^T$  está definido por la ecuación (4.19) y  $\varphi$  es un vector de parámetros que caracteriza a la secuencia  $\sigma^2[n]$ . Para este caso  $\varphi = \sigma^2$ .

Al observar la señal  $\{y_1, y_2, \dots, y_n\}$  se debe hacer una decisión entre las siguientes dos hipótesis (Hacer referencia a la figura 4.7):

$H_0$  :  $\theta = \theta_0$  para  $1 \leq k \leq n$  (No hay cambio)

$H_1$  : Existe un  $r$  tal que  $\theta = \theta_1$  para  $1 \leq k \leq r$ , (Si hay cambio)

y  $\theta = \theta_2$  para  $r < k \leq n$ .

De acuerdo con la estimación por máxima verosimilitud, la decisión depende de la razón de verosimilitud entre estas dos hipótesis, en donde el instante  $r$  y  $\theta_1$  son reemplazados por sus estimaciones. Entonces se forma una prueba de razón generalizada de verosimilitud,




Figura 4.7.

$$A_g(n) = \max_r \frac{\max_{\theta_1 \theta_2} P(y_1, \dots, y_n | H_1)}{\max_{\theta_0} P(y_1, \dots, y_n | H_0)} \begin{matrix} H_1 \\ \geq \\ < \\ H_0 \end{matrix} \gamma \quad (4.27)$$

Si tomamos logaritmo de ambos lados de la ecuación (4.27) y tenemos en cuenta que la hipótesis \$H\_1\$ significa un cambio de modelo, tendremos una medida para detectar un cambio [And88],

$$d(n) = \max_r \max_{\theta_1 \theta_2} \min_{\theta_0} \log \frac{P(y_1, \dots, y_n | H_1)}{P(y_1, \dots, y_n | H_0)} \geq \lambda \quad (4.28)$$

donde,

$$\lambda = \log \gamma \quad (4.29)$$

De acuerdo con [Bra83] la prueba logarítmica de razón generalizada de verosimilitud de la ecuación (4.28) se convierte en:

$$d(n) = (N_R + N_P) \log \sigma_T^2 - (N_R \log \sigma_R^2 + N_P \log \sigma_P^2) \quad (4.30)$$

La ecuación (4.30) es para dos secuencias, una de prueba  $x_p$  y una de referencia  $x_r$ , y la secuencia combinada  $x_t$  (ver figura 4.7) donde  $N_r$  y  $N_p$  son las longitudes de las secuencias  $x_r$  y  $x_p$  respectivamente y  $\sigma_r$ ,  $\sigma_p$  y  $\sigma_t$  son las estimaciones de la desviación estándar de las secuencias antes mencionadas.

Este procedimiento busca un cambio en la señal haciendo la prueba de la ecuación (4.30) en las últimas  $L$  muestras para detectar si son significativamente diferentes a las anteriores o no. En [App83] se demuestra que la expresión (4.30) se reduce de la siguiente manera:

$$d(n) = H_C(n) - (H_D(n) - H_C(n-L)) \quad (4.31)$$

donde el subíndice  $C$  se refiere al algoritmo de memoria creciente y el subíndice  $D$  al algoritmo de memoria deslizando mencionados en el capítulo 2 y,

$$H_C(n) = L_n \log \frac{E_{p,n}^{(C)}}{L_n} \quad (4.32)$$

y

$$H_D(n) = L \log \frac{E_{p,n}^{(D)}}{L} \quad (4.33)$$

Las cantidades  $E_{p,n}^{(C)}$  y  $E_{p,n}^{(D)}$  son las energías residuales al orden  $p$ , obtenidas de los algoritmos de memoria creciente (Tabla 2.2.) y deslizando (Tabla 2.3.) respectivamente.  $L_n$  representa el tiempo transcurrido desde el último cambio detectado. Si  $d(n)$  sobrepasa cierto umbral prefijado, se supone que ha ocurrido un salto abrupto en los parámetros del modelo de la señal y el momento en que ésto ocurre se conoce como tiempo de detección y se denomina  $m_D$ .

#### 4.3.2. Estimación de la Posición de las Fronteras.

El procedimiento de optimización que se utiliza para encontrar el mejor punto de localización de la frontera en el rango  $\{m_D-L+1, \dots, m_D\}$  una vez detectado un cambio, se basa también en una serie de pruebas de razón generalizada de verosimilitud. El procedimiento consiste en aplicar una búsqueda recursiva máxima de distancias en diferentes secuencias de prueba y de referencia.

Si como dijimos anteriormente, el momento de la detección de cambio es denominado  $m_D$ , entonces es razonable pensar que el verdadero instante del cambio  $r'$  es tal que  $m_D - L \leq r' < m_D$ . Tomando como referencia la

Figura 4.8 se definen las hipótesis para la nueva prueba RGV.

$H_0'$ : Existe una  $r$  tal que  $\theta = \theta_0$  para  $1 \leq k \leq r$ ,

y  $\theta = \theta_0'$  para  $r < k \leq n$ ,

$H_1$  :  $\theta = \theta_1$  para  $1 \leq k \leq n-L$ ,

y  $\theta = \theta_2$  para  $n-L < k \leq n$ .




Figura 4.8.

Tenemos ahora la distancia:

$$Ad(r) = r \log \sigma_0 + (n-r) \log \sigma_0' - (n-L) \log \sigma_1 - L \log \sigma_2 \quad (4.34)$$

Escribiendo la ecuación (4.34) de manera similar a (4.31),

$$Ad(n) = H_c(n) + H_c(n-L_n) - (H_D(n) + H_c(n-L)) \quad (4.35)$$

Esta prueba se efectúa para  $nb \leq n < nb + L$  y  $r$  es actualizada de acuerdo a la siguiente regla:

Condiciones iniciales :  $r = nb - L$

$n = nb$

Si  $Ad(n) \leq 0$  : Se mantiene  $r$  sin cambio

Si  $Ad(n) > 0$  : Actualizar  $r$  con el valor de  $n - L$ .

Al final el valor buscado  $r'$  estará dado por el último valor tomado por  $r$  en el instante  $n = nb + L$ . El procedimiento se vuelve a repetir pero ahora se empieza desde  $r'$  como punto de inicio.

#### 4.4. Simulaciones en Computadora.

En este trabajo se desarrollaron programas de computadora para hacer simulaciones con los algoritmos de segmentación descritos en las primeras secciones de este capítulo. Lo interesante de estos programas no es la manera como están programados, ya que esta no es una tesis de ingeniería de computación, sino cómo estos programas nos ayudan a conocer mejor a los algoritmos mediante las diferentes pruebas que se les aplicarán más adelante en el trabajo. Con el fin de que estos algoritmos puedan ser programados en cualquier arquitectura de cálculo se presentan de manera simplificada sus diagramas de flujo.

##### 4.4.1. Implantación de los Algoritmos.

La implantación de los algoritmos hizo en lenguaje TURBO PASCAL 5.5 en una computadora DELL Sistema 310, con procesador 80386 y coprocesador matemático 80387.

El desarrollo del algoritmo del método FAC se hizo bajo el esquema de procesamiento en bloques, es decir, fuera de línea. En la figura 4.9 se presenta el diagrama de flujo del método FAC por bloques.

El algoritmo del método MES también es presentado en este trabajo bajo el esquema de procesamiento por bloques fuera de línea. En la figura 4.10 se esboza el diagrama de flujo utilizado para la elaboración del programa de simulación.

El algoritmo del método RGV fue implantado siguiendo las estructuras presentadas en [Bra83]. En la figura 4.11 se hace un ligero esbozo de el diagrama de flujo definitivo que se usó en este trabajo, para una descripción más detallada se recomienda hacer referencia al artículo citado. La implantación de este método fue hecha por medio de un esquema de procesamiento en línea, lo que permite tener señales de tamaño cualquiera, las cuales entran al programa y son procesadas y segmentadas en ese momento.

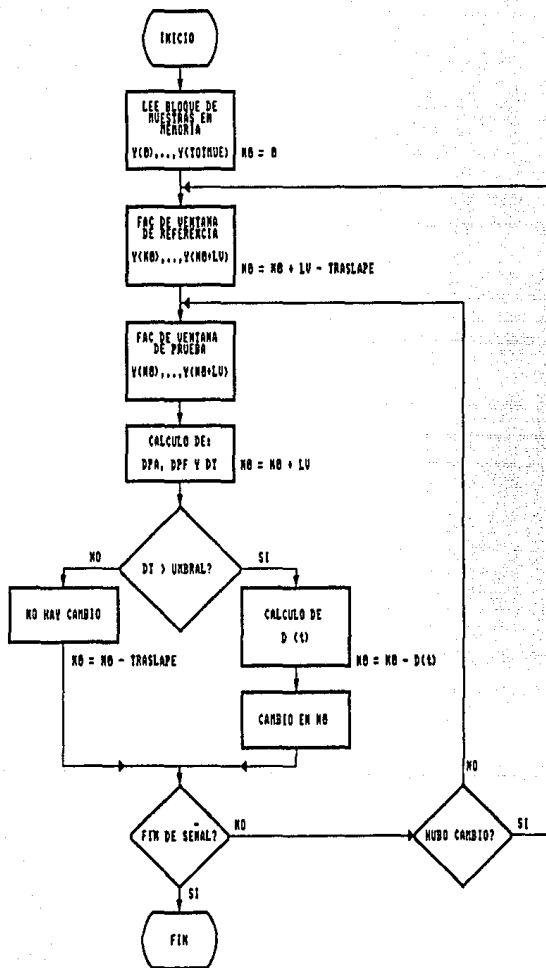


Figura 4.9.



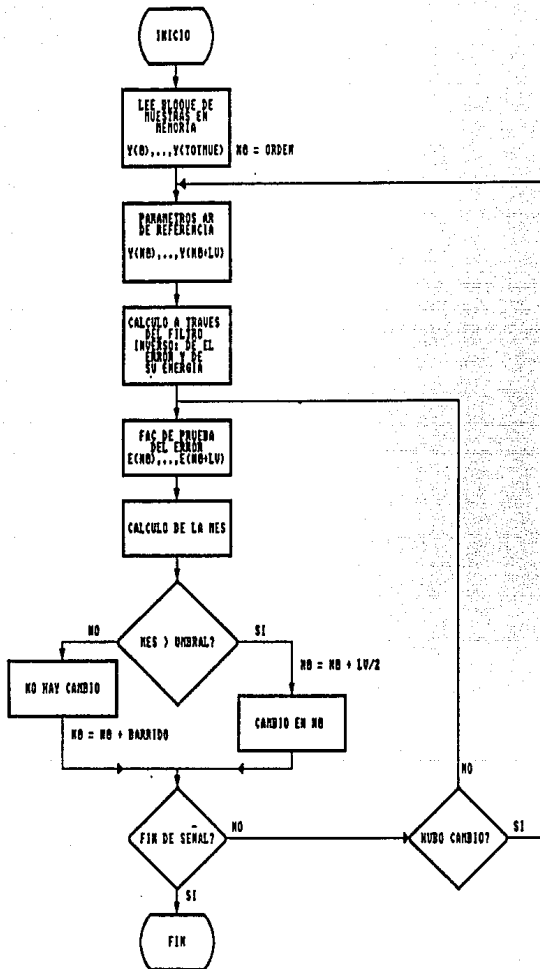


Figura 4.10.




Figura 4.11.

#### 4.5. Pruebas y Criterios.

En esta parte del trabajo se describen las pruebas que sentimos fueron necesarias para conocer el comportamiento de los algoritmos. Sería inútil el tratar de segmentar señales reales sin antes hacer un estudio de los algoritmos con señales hechas a nuestro gusto. Se debe hacer este tipo de

pruebas para saber cómo escoger los parámetros de análisis de los diferentes métodos y para las diferentes señales para las que serán utilizados.

#### 4.5.1. Definición de las Señales de Prueba.

Estas señales fueron generadas con diferentes modelos y criterios. Se generaron secuencias de muestras dentro de las cuales se encuentran señales sinusoidales puras de acuerdo con el modelo de la ecuación (4.36),

$$y[n] = A \cos(2\pi f_n n) \quad (4.36)$$

donde  $A$  es la amplitud máxima y  $f_n$  es el valor de la frecuencia normalizada y su relación con el periodo de la señal está determinado por la ecuación (4.37).

$$f_n = 1 / \text{periodo en muestras} = 1 / T \quad (4.37)$$

El otro tipo de señales de prueba, fueron generadas con modelos *ARMA*, a partir de la localización de los polos y los ceros del sistema. Utilizando las ecuaciones (1.21) y (1.22) se genera una señal a partir de sus polos y sus ceros.

En primer lugar se generaron secuencias largas conteniendo el mismo modelo de manera que se pudiera detectar la incidencia de falsas alarmas. Las señales generadas para estudiar las falsas alarmas son las siguientes:

a) Señal sinusoidal con frecuencia normalizada de 0.05, equivalente a un periodo de 20 muestras, con amplitud máxima de diez. Se generaron 500 muestras que se pueden observar en la figura 4.12. El comportamiento frecuencial de esta señal se muestra en la figura 4.13. En lo subsecuente se hará referencia a esta señal por medio del nombre *cos 0.05*.

b) Señal con modelo *AR* de segundo orden con polos complejos conjugados de magnitud 0.9 y ángulo de 30°. Las 500 muestras generadas se encuentran en la figura 4.14 y su espectro en la figura 4.15. A esta señal le pondremos el nombre *AR 0.9 30°* para referencia posterior.

c) Señal con modelo *AR* de octavo orden con polos complejos conjugados localizados de la siguiente manera: El primer par con magnitud 0.6 y ángulo de 30°, el segundo par con magnitud 0.9 y ángulo de 60°, el tercer par con magnitud 0.6 y ángulo de 90° y el último par con magnitud de 0.9 y ángulo de 120°. En la figura 4.16 y 4.17 se muestran respectivamente la señal y su espectro. A esta señal la llamaremos por facilidad *AR orden 8* en referencias próximas.

En las siguientes secciones se discutirán las pruebas efectuadas con estas señales y entonces se podrá ver su utilidad.

Señal de prueba Cos 0.05




Figura 4.12.

Espectro de la señal cos 0.05




Figura 4.13.

### Señal de prueba AR orden 2

Magnitud = 0.8 Angulo = 30°




Figura 4.14.

### Espectro de la señal AR 0.9 30°






Figura 4.15.

*Señal de prueba AR orden 8*



*Figura 4.16.*

*Espectro de la señal AR orden 8*



*Figura 4.17.*

A continuación, se unieron señales dentro de una misma secuencia con el fin de obtener una señal que tuviese cambios de modelo en puntos conocidos. Al generar las secuencias compuestas de varios tipos de modelos se debe tener en cuenta que deben existir cambios en ambos sentidos. Se debe por ejemplo, probar con un cambio en amplitud tanto en sentido creciente como decreciente.

En [App84] se propone el uso de señales generadas a partir de un modelo *AR* para llevar a cabo las pruebas. La manera más fácil de definir este tipo de modelos es por medio de la localización de sus polos. Se sugiere, también en [App84], el uso de modelos de segundo orden los cuales mantendrán bajo el número de parámetros. El segundo orden da bastante flexibilidad ya que con sólo variar el ángulo de localización de los polos, se varía la frecuencia central de la señal, y al variar la magnitud de los polos modificaremos el ancho de banda.

Una consideración que se debe hacer al generar señales de prueba es el hecho que las señales reales (EEG y voz) generalmente estarán sobremuestreadas y por tanto las frecuencias de estas señales sintéticas no deben sobrepasar  $1/8$  de la frecuencia de muestreo [App84].

Las señales generadas para estudiar el comportamiento en cambios conocidos fueron las siguientes:

a) En la figura 4.18 se tiene el comportamiento de una señal con cambios en amplitud sinusoidal, a la cual llamaremos en adelante señal *CAS*. Las primeras y las últimas 200 muestras corresponden a un coseno con amplitud máxima de cuatro y con frecuencia normalizada de 0.125. Las 200 muestras de en medio corresponden a un coseno con la misma frecuencia, pero con amplitud máxima de dos. En la figura 4.19 se observa el cambio en el dominio de la frecuencia. El espectro de la señal con mayor amplitud corresponde a aquel que se encuentra 3 dB por encima del otro.

b) En la figura 4.20 se observa una señal con cambios en frecuencia sinusoidal (*CFS*). Esta señal está compuesta por un cambio ascendente en frecuencia en la muestra 200 en donde se pasa de un coseno con amplitud máxima de diez y frecuencia normalizada 0.025 a un coseno con la misma amplitud máxima pero con frecuencia normalizada duplicada, es decir 0.05. A partir de la muestra 400 se vuelve a presentar la frecuencia del principio. En la figura 4.21 se muestran los espectros de la señal *CFS* y se puede notar que la diferencia es únicamente de tipo frecuencial, ya que la energía (área bajo la curva) permanece constante.

c) La siguiente señal de prueba corresponde a cambios en la magnitud de los polos de un modelo *AR* de segundo orden (*CHAR*). En la figura 4.22 se observa el comportamiento temporal y se distinguen los cambios de modelo en las muestras 200 y 400. Las primeras y últimas 200 muestras corresponden a un modelo *AR* de segundo orden con polos complejos conjugados de magnitud 0.45 y ángulo de  $20^\circ$ . Las 200 muestras intermedias pertenecen a un modelo *AR* de segundo orden con polos complejos conjugados de magnitud 0.9 y ángulo de  $20^\circ$ . En la figura 4.23 se observan los espectros asociados a ambos

*Cambio de amplitud  
en una señal senoidal*




Figura 4.18.

*Espectros de la señal CAS*




Figura 4.19.



### Cambio de frecuencia en una señal senoidal




Figura 4.20.

### Espectros de la señal CFS




Figura 4.21.

### Cambio de Magnitud

en los polos de un modelo AR




Figura 4.22.

### Espectros de la señal CMAR




Figura 4.23.

modelos siendo el más alto el que corresponde a una magnitud mayor (0.9) y por lo tanto tiene un menor ancho de banda.

d) En la figura 4.24 tenemos una señal con cambios en el ángulo de los polos de un modelo AR de segundo orden (CAAR). A partir de la muestra 200 deja de presentarse el modelo AR de segundo orden con polos complejos conjugados de magnitud 0.9 y ángulo  $30^\circ$  y comienza a presentarse otro modelo similar al anterior pero con ángulo de  $60^\circ$  en sus polos. En la muestra 400 se da el cambio contrario, es decir, se regresa al primer modelo. En la figura 4.25 se muestra el comportamiento frecuencial de este cambio, y es muy claro en esta gráfica cómo el ángulo de los polos de un modelo AR de segundo orden determina la frecuencia fundamental de la señal. De esta manera, el espectro que tiene su máximo alrededor de  $30^\circ/360^\circ=0.083$  de frecuencia normalizada corresponde al modelo con ángulo de  $30^\circ$ , y aquel que tiene su máximo alrededor de 0.16 de frecuencia normalizada corresponderá al modelo con ángulo de  $60^\circ$ .

e) La señal de la figura 4.26 presenta cambios en el orden de un modelo AR (COAR). En las primeras 200 muestras se tiene una señal caracterizada por un modelo AR de cuarto orden con polos complejos conjugados de magnitud 0.9 y ángulo  $30^\circ$  y de magnitud 0.9 y ángulo  $75^\circ$ . A partir de la muestra 200 se eliminan los polos con ángulo de  $75^\circ$  y queda un modelo AR de segundo orden que vuelve a cambiar a partir de la muestra 400 de nuevo al modelo de un principio. En la figura 4.27 se observan los espectros de los modelos de cuarto y segundo orden antes descritos. El orden corresponde al número de máximos en el espectro.

#### 4.5.2. Parámetros de Análisis.

Los parámetros de análisis más significativos de los métodos de segmentación serán descritos en esta sección. En el método FAC los parámetros más importantes serán el tamaño de las ventanas, el número de coeficientes FAC asociados a cada ventana, el valor de los umbrales de amplitud y frecuencia, y el traslape que exista entre las ventanas. Para el método MES, será de gran importancia la adecuada selección de parámetros como el tamaño de las ventanas, el orden de la predicción, el número de coeficientes FAC asociados a la ventana del error de predicción, el umbral de segmentación, y el barrido que existe en la ventana del error. Para el método RGV sólo tres parámetros deben ser ajustados para variar el rendimiento, el orden del modelo AR, el tamaño de la ventana de prueba, y el umbral de segmentación.

La labor de ajustar debidamente los parámetros es una de las más cruciales en todos los algoritmos de segmentación. En algunos casos, existen demasiados parámetros, y además algunos de ellos dependen de otros que tienen que ser fijados con criterios de experiencia ya que existen en muchos casos pocas medidas objetivas disponibles. (Mic79)

*Cambio de ángulo  
en los polos de un modelo AR*




Figura 4.24.

*Espectros de la señal CAAR*




Figura 4.25.

### Cambio de orden en una señal AR

conservando igual dos de los polos




Figura 4.26.

### Espectros de la señal COAR




Figura 4.27.

En los métodos MES y RGV, uno de los parámetros más importantes es  $p$ , el orden del predictor. La elección de  $p$  debe de hacerse de una manera cuidadosa, ya que el número de operaciones aritméticas depende de  $p^2$  en el caso del método MES, y de  $p$  en el método RGV. Si el orden exacto de los procesos AR no es conocido, se debe estimar un valor suficientemente grande para llevar a cabo la predicción. Por otro lado, el orden  $p$  no debe ser escogido excesivamente grande, debido a que esto limitaría a el uso de ventanas de prueba grandes, ya que el tamaño de la ventana debe mantenerse mucho mayor que el orden  $p$  para obtener buenos resultados en los algoritmos de predicción. En el método MES,  $p$  debe mantenerse lo menor posible, pero lo suficientemente grande como para que se obtenga un conjunto de parámetros representativo, y se mantenga, en caso de no haber cambios, un error espectral descorrelacionado (blanco), para que no exista una falsa alarma por sobrepasarse el umbral de segmentación US.

Una regla que se utiliza comúnmente en este tipo de análisis es hacer  $p$  igual al doble de las resonancias esperadas en el espectro. En EEG generalmente se tienen cuatro resonancias, más un pico debido a la pendiente en la zona de la frecuencia de corte menor, lo cual requiere mínimo de un orden diez, sin embargo es práctica común utilizar quince coeficientes para una ventana de treinta segundos. Una de las primeras ventajas del procesamiento con presegmentación, es que al dividir la señal en porciones estacionarias, las señales no contendrán tanta variedad espectral como los segmentos de treinta segundos. En [Bod77] se sugiere que se utilicen únicamente 6 coeficientes para EEG. Para cada tipo de señal existen estudios a priori que nos determinarán un valor inicial de prueba para el orden  $p$ , el cual a partir de pruebas se puede ir mejorando.

El número de coeficientes de la FAC que se utilizan en el método FAC y en el método MES, es generalmente obtenido a partir de los análisis anteriormente mencionados, ya que la función de autocorrelación está íntimamente relacionada al cálculo de los coeficientes de predicción lineal. Es lógico pensar que este número será igual a  $p$ .

Para optimizar el tamaño de las ventanas  $LV$  con respecto al error que se podría presentar en el caso de ser fijado incorrectamente, se debe hacer un estudio en una señal sin cambios. Al observar cómo se producen diferencias de modelo al cambiar el tamaño de la ventana, se debe determinar un tamaño adecuado de acuerdo a las características espectrales de la señal, es decir, en función de las frecuencias más importantes. Generalmente este estudio (realizado más adelante en este trabajo) lleva a que las ventanas deben contener un mínimo de dos ciclos de las componentes más lentas de la señal, o dicho de otra manera, deberán ser por lo menos igual a dos veces el periodo de la componente de menor frecuencia.

En la decisión del tamaño de las ventanas existen puntos opuestos. Por un lado, se obtienen estimaciones estadísticas estables y por lo tanto incidencias de error pequeñas al escoger un valor de  $LV$  mucho mayor que  $p$ , pero se causa un aumento en los retardos de detección. Por otro lado, las ventanas no deben ser tampoco muy grandes, debido a que se pueden esconder pequeños segmentos interesantes al análisis posterior.

El ajuste de los umbrales de segmentación depende de la aplicación en particular para la cual se esté diseñando el algoritmo de segmentación. En muchas aplicaciones, es necesario mantener el número de falsas alarmas por debajo de un límite. Sin embargo establecer el impacto de los umbrales de segmentación sobre la incidencia de falsas alarmas es muy complicado de hacer teóricamente, por lo que por medio de simulaciones se estudia el comportamiento de los tres algoritmos con las distintas señales para diferentes umbrales de segmentación, [App83].

En los dos métodos que fueron implantados bajo un esquema de procesamiento por bloques (el método FAC y el método MES), se deben definir parámetros de avance de las ventanas. Para el método FAC se le llamó traslape, lo que significa es el número de muestras que comparten dos ventanas consecutivas. Si se tiene un traslape de cero, el análisis será rápido en comparación con análisis donde sí exista traslape. La ventaja del traslape es el poder analizar más a fondo la señal ya que una misma muestra es incluida dentro de varias ventanas. En la figura 4.28 se ejemplifica un análisis con el método FAC en el que existe un traslape de  $LV / 2$ . Para el método MES se tiene una medida de avance llamada barrido y lo que representa es la cantidad de muestras que se avanzan por paso de la segmentación. Esta medida es muy parecida al traslape, pero en vez de retroceder, avanza. De acuerdo con el ejemplo de la figura 4.28 se tendría un barrido en ese caso de  $LV / 2$ .

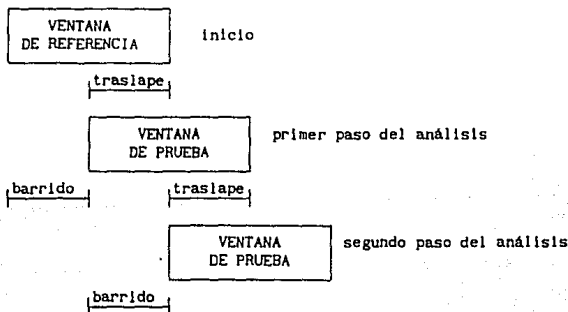


Figura 4.28.

#### 4.6. Comparación de los Diferentes Métodos.

Las primeras pruebas que se les realizó a los tres algoritmos de segmentación ya descritos, fue la de probar su comportamiento en señales que teóricamente no presentan ningún cambio. El comportamiento ideal que deben de obedecer este tipo de algoritmos ante tal tipo de señales es obviamente el de no detectar cambio alguno. Sin embargo, debido a las estructuras internas de los algoritmos, en ocasiones al no seleccionar adecuadamente los parámetros de análisis, podemos caer en falsas alarmas.

Dos de los parámetros más importantes en los análisis, son el tamaño de la ventana (o ventanas) y el orden del modelo que se supone, al hacer la segmentación. Para los tres métodos, se corrieron simulaciones con señales sin cambio y se observó cómo se comportaban las diferentes medidas de cambio al variar los dos parámetros mencionados.

Para el análisis de la selección óptima del tamaño de la ventana y del orden de predicción, con respecto a la baja incidencia de falsas alarmas, se hicieron simulaciones con los tres métodos para determinar una justificación heurística al hacer las decisiones. Se tomaron las señales de prueba *cos 0.05*, *AR 0.9 30*, y *AR orden 8*, y de acuerdo con su frecuencia fundamental mínima (tomada de sus espectros) se determinó su periodo máximo. Para la primera señal *cos 0.05* se tiene un periodo de 20 muestras, para la señal *AR 0.9 30* se tiene un periodo máximo de doce muestras, lo mismo que para la señal *AR orden 8*.

A la señal *cos 0.5* se le aplicó el método FAC usando cuatro coeficientes. Al variar al tamaño de la ventana desde dos hasta 60, se observó el comportamiento de la diferencia porcentual máxima, mismo que se presenta en la figura 4.29. Podemos advertir un comportamiento mejor en lo que respecta a falsas alarmas, conforme se aumenta el tamaño de la ventana. También, se observa que existen puntos en que la diferencia es ideal (cero por tratarse de una señal sin cambios) en valores de la ventana múltiplos de diez.

Para la señales *AR 0.9 30* y *AR orden 8*, se obtuvieron las gráficas de las figuras 4.30 y 4.31 al aplicar el método FAC sucesivamente con cuatro y ocho coeficientes respectivamente, pero con tamaño de ventana desde dos hasta 60 muestras. Para ambas señales su periodo máximo es doce muestras debido al par de polos que tienen con ángulo 30°. En las gráficas se observa que para ventanas muy chicas se llegan a tener errores muy grandes, mientras que al aumentar el tamaño de la ventana por arriba del doble del periodo, se logra que la diferencia tienda a un valor constante.

Para la señal *AR orden 8*, se hicieron simulaciones en las cuales se mantenía el tamaño de la ventana fijo, pero se variaba el número de coeficientes a ser calculados. Se encontró que la diferencia era insignificante, y que los resultados eran muy parecidos usando dos o tres






Figura 4.29.




Figura 4.30.




Figura 4.31.

coeficientes, que utilizando nueve o diez. Creemos que lo anterior se debe a que para calcular las diferencias porcentuales, se utilizan sólo los primeros coeficientes positivos de la *FAC*, lo que significa que si el primer cruce por cero de la *FAC* se da en el tercer coeficiente, será lo mismo utilizar tres que más coeficientes. Cabe mencionar que la rapidez del cruce depende de la frecuencia de la señal, para frecuencias muy bajas, la *FAC* tardará más en cruzar cero por primera vez.

En las gráficas anteriores observamos que en la vecindad de 200% del periodo de la señal, podemos trabajar con cierta seguridad. El irnos más arriba nos disminuye este tipo de error, sin embargo, como fue mencionado anteriormente, es conveniente mantener el tamaño de la ventana en el mínimo posible para no perder información de segmentos cortos.

Para el método *MES*, también se hicieron pruebas parecidas con las tres señales sin cambio arriba mencionadas. Para la señal *cos 0.05*, usando un orden de predicción igual a cinco, y variando el tamaño de la ventana desde dos hasta 60 muestras se obtuvo la gráfica de la figura 4.32. En esta gráfica se observa que para tamaños muy pequeños de la ventana, existe gran posibilidad de caer en una falsa alarma. Al aumentar el tamaño de la ventana para este tipo de señal, no se observa mejoría, únicamente cuando la ventana adquiere tamaños múltiples de diez.

Para las señales *AR 0.9 30* y *AR orden 8* se hicieron series de simulaciones variando el tamaño de la ventana desde doce hasta 100 muestras, con ordenes de predicción cuatro y ocho respectivamente. Las gráficas obtenidas se presentan en las figuras 4.33 y 4.34, en ellas observamos que existe una zona de error bajo, en las proximidades del 200%, aunque sólo a partir del 400% en adelante se puede trabajar con cierta seguridad de no caer en falsas alarmas.

Cuando se aplico el método *MES* para diferentes ordenes de predicción desde dos hasta 32 a la señal *AR orden 8*, se obtuvieron resultados más significativos que en el experimento análogo con el método *FAC*. En la figura 4.35. se observa que al aumentar el orden se reduce el error producido por el método. Sin embargo, es prudente aclarar, que despues de cierto valor del orden, el error no disminuye demasiado y lo que si aumenta, es el número de operaciones requeridas para hacer la predicción, en proporción del orden al cuadrado.

Es interesante hacer notar que el efecto producido por el cambio de los parámetros de barrido y traslape en las gráficas correspondientes a los métodos *MES* y *FAC* respectivamente, es el de suavizar las curvas conforme se avanza más lentamente. En el método *MES*, se presentan las gráficas cuando se tiene barrido máximo equivalente al tamaño de la ventana. Al hacer simulaciones con barrido mínimo igual a uno, obtuvimos comportamientos parecidos, sólo que como se menciono arriba, a las gráficas se les suavizaron los picos. Las gráficas obtenidas en el caso del método *FAC*, fueron debidas a análisis sin traslape. Al aumentar el traslape en el método *FAC*, se obtenía un resultado parecido al mencionado en el caso de reducir el barrido del método *MES*.




Figura 4.32.




Figura 4.33.




Figura 4.34.

## METODO MES

Decisión sobre el orden del predictor




Figura 4.35.

Al efectuar las pruebas sobre falsas alarmas en las tres señales sin cambios, utilizando el método RGV, obtuvimos resultados contrastantes. Cuando aplicamos el método RGV a la señal sinusoidal  $\cos 0.05$  utilizando un orden cuatro y variando el tamaño de la ventana deslizante de dos a 60 muestras, obtuvimos un comportamiento muy peculiar, mostrado en la figura 4.36. Esta gráfica tiende a parecerse a las dos anteriores obtenidas con la misma señal, sólo que en ésta, al contrario del método MES, si existe una disminución a medida que se incrementa el tamaño de la ventana, pero la disminución no es tan acentuada como en el método FAC. También en este caso, se observan los mínimos alrededor de los tamaños de la ventana múltiplos de diez muestras.

El contraste se observó cuando aplicamos el método RGV a las señales AR 0.9 30<sup>o</sup> y AR orden 8, utilizando ordenes de predicción cuatro y ocho respectivamente. Al variar el tamaño de la ventana desde dos hasta 100 muestras obtuvimos las curvas mostradas en las figuras 4.37 y 4.38. Estas dos gráficas nos muestran un comportamiento muy bueno a partir del 100% del tamaño de la ventana relativo al periodo.

La diferencia entre las curvas obtenidas con el método RGV para una señal senoidal y para las señales AR, era de esperarse si pensamos que el algoritmo de segmentación de dicho método se basa en la suposición de que la señal tiene asociado un modelo AR.




Figura 4.36.




Figura 4.37.




Figura 4.38.

## Método RGV

Decisión sobre el orden del predictor




Figura 4.39.

En la figura 4.39 se muestra el comportamiento de la distancia de verosimilitud máxima que se presentó al aplicarle el método RGV a la señal AR orden 8, utilizando un tamaño de ventana de dieciséis muestras y variando el orden de predicción. En esta gráfica se puede advertir que la distancia disminuye cuando nos encontramos alrededor del orden real de la señal, mientras que si lo disminuimos se aumenta la diferencia de la señal consigo misma. El aumentar el orden parece no mejorar las falsas alarmas, y si aumenta el tiempo de cálculo en la etapa de predicción, al tenerse que realizar operaciones proporcionales al orden.

Una vez que a los diferentes métodos se les aplicaron las pruebas con señales sin cambio, se procedió a efectuar diferentes pruebas con los algoritmos, para observar cómo detectaban algunos cambios conocidos de antemano por nosotros. Ya en la sección 4.5.1 se describieron las señales que se utilizaron en el procedimiento que describiremos a continuación.

Una vez que se tiene un mecanismo para la selección de algunos parámetros, como el caso del tamaño de la ventana y del orden del predictor, a partir de las características espectrales y temporales de la señal, se procede a realizar intentos de segmentación. En estas pruebas lo principal es determinar un valor adecuado para el o los umbrales, que permita detectar el máximo de segmentos, pero con el mínimo de falsas alarmas.

Las diferencias en la naturaleza de las señales utilizadas en las pruebas para el ajuste de umbrales, nos permiten estudiar el comportamiento de los algoritmos para cada tipo de señal. Esta variedad aunque no abarca el universo de las señales, posee representantes muy significativos. Es también importante señalar que, con estas señales de prueba, podemos analizar el cambio que presenta cada una, en ambos sentidos.

La primera señal que se estudió fue aquella que contiene una señal sinusoidal de frecuencia constante, que tiene una disminución de amplitud y posteriormente un aumento de ella. Esta señal fue denominada anteriormente como CAS. A partir del espectro de la señal (figura 4.19), observamos que la frecuencia menor, y única en este caso, se presenta alrededor de 0.125. Con la ecuación (4.37) obtenemos que el período máximo de la señal es de ocho muestras. De acuerdo con las pruebas anteriores, si utilizamos un tamaño de las ventanas equivalente a un 500% del período, 40 muestras en este caso, tendremos una baja incidencia de falsas alarmas. A pesar de que una señal sinusoidal pura corresponde a un segundo orden teórico, cuando se utilizan modelos ARMA es más seguro caracterizarlos con un orden mayor para disminuir las falsas alarmas. Supondremos, por tanto, un orden cinco.

Análisis de la señal CAS con el método FAC. Fijando los umbrales de amplitud y frecuencia en un valor muy alto de manera que no se detecten los cambios. En la figura 4.40 se estudia cómo evoluciona la diferencia porcentual total entre la ventana de referencia y la ventana de prueba al ir avanzando de cinco en cinco muestras a través de la señal. Se advierte que en las primeras 200 muestras la diferencia es muy baja en comparación con la diferencia que se presenta en el intervalo entre la muestra 200 y la 400. A partir de esta gráfica podemos determinar que los umbrales tienen que tomar un valor entre el 20% y el 100% para que se detecte el primer cambio. Si optamos por un umbral muy bajo, se tendrá la posibilidad de caer en falsas alarmas. Sin embargo si el umbral lo fijamos muy alto, el segundo cambio podría esconderse. Como en la gráfica se observa que el cambio de subida es equivalente en magnitud al cambio de bajada, podemos optar por el umbral alto de 100%.

En la figura 4.41 se muestra la evolución de la medida de diferencia, con umbrales de amplitud y frecuencia iguales a uno. El comportamiento de la diferencia es muy bueno de acuerdo con la información que tenemos de antemano sobre los cambios. En la gráfica se observan dos picos por arriba del 100% en el valor que toma la diferencia. Ambos picos corresponden a la detección de un cambio en la respectiva muestra en la que se conoce que se encuentran.

Análisis de la señal CAS con el método MES. A partir de un barrido de cinco muestras, y con un umbral de segmentación muy grande, se obtiene el comportamiento de la MES que se presenta en la figura 4.42. En esta ocasión tenemos algo parecido al comportamiento obtenido con el método FAC. Si optamos por escoger un umbral alto de diez, obtenemos el comportamiento de la figura 4.43. En esta gráfica se observa que se detectó el primer cambio, ya que se presenta un pico por arriba del umbral, sin embargo el segundo cambio se esconde. Para mejorar lo anterior, disminuimos el valor

### Evolución de la distancia FAC

Umbraltes infinitos




Figura 4.40.

### Evolución de la distancia FAC

Umbraltes definidos

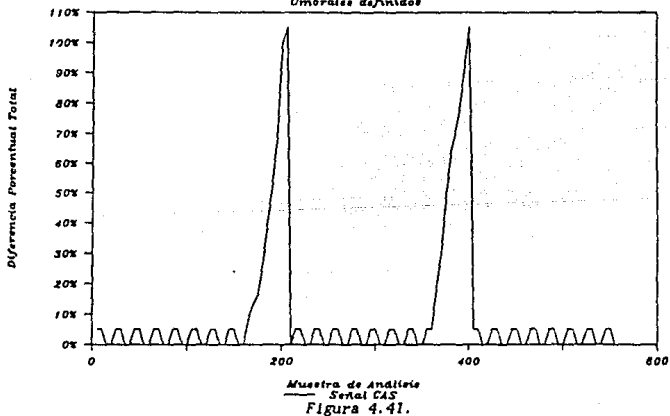


Figura 4.41.






Figura 4.42.




Figura 4.43.




Figura 4.44.

del umbral al mínimo posible de 4.8. En la figura 4.44 se nota cómo el cambio del umbral nos permitió en este caso detectar el segundo cambio, aunque nos arriesgamos a obtener una falsa alarma.

Análisis de la señal CAS con el método RGV. La figura 4.45 muestra el resultado del análisis, con umbral de segmentación muy grande. En esta gráfica se observa un comportamiento muy particular. Al inicio del análisis se tiene un pico muy significativo que al crecer la ventana de referencia se estabiliza en un valor constante. En esta gráfica es interesante advertir cómo la distancia de verosimilitud desciende en lugar de aumentar, alrededor de las muestras 200 y 400. Lo que se puede comentar al respecto de estos comportamientos es que pueden existir irregularidades debido a que el algoritmo de detección, al tratar de estimar los parámetros del modelo AR de una señal pura, diverja debido a que los polos están sobre el círculo unitario.

De la gráfica anterior decidimos por un umbral de 50 y obtenemos el comportamiento de la figura 4.46, en donde se observa que se detecta una falsa alarma producida por la predicción, un poco después de iniciado el análisis. Esta gráfica nos permite pensar que los cambios que estamos buscando se encuentran en las inmediaciones del valor de 25. La figura 4.47 muestra el análisis con el valor de umbral ajustado a 25 y se observa que detecta los cambios un poco antes de las muestras 200 y 400. Los cambios detectados en la figura 4.47 se encuentran aproximadamente en donde se hayan los picos, en las muestras 155 y 345 respectivamente.

A continuación se hacen las pruebas con la señal CFS (figura 4.20), la cual presenta cambios de frecuencia ascendente y descendente en una señal sinusoidal. A partir de los espectros asociados a esta señal (figura 4.21), se obtiene, usando el procedimiento mencionado en la señal anterior, que el período máximo de la señal equivale a 40 muestras. En esta ocasión escogeremos un valor del tamaño de la ventana de 80 muestras, equivalente al 200% del período, mínimo permisible de acuerdo con los análisis hechos anteriormente. En estas simulaciones se supone por seguridad un orden de cinco.

Análisis de la señal CFS con el método FAC. En las figuras 4.48 y 4.49 se presentan las gráficas obtenidas, primero fijando los umbrales en un valor muy alto que no detenga el análisis de la distancia, y posteriormente utilizando umbrales iguales a 0.5. En estas gráficas se observa un comportamiento muy aceptable, ya que se detectan ambos cambios con exactitud y con la misma magnitud en la diferencia.

Para todos los análisis con los métodos FAC Y MES, se ajustan los parámetros de avance de manera que las ventanas que se mueven, lo hagan de cinco muestras en cinco muestras. Los análisis por el método RGV se hacen muestra por muestra debido a la naturaleza del algoritmo ya mencionada anteriormente en este trabajo.

Análisis de la señal CFS con el método MES. El comportamiento observado en la MES al aplicar el método, con umbral muy grande, se muestra




Figura 4.45.




Figura 4.46.




Figura 4.47.

ESTA TESIS NO DEBE  
SALIR DE LA BIBLIOTECA

### Evolución de la distancia FAC

Umbral = infinito




Figura 4.48.

### Evolución de la distancia FAC

Umbral = 0.5




Figura 4.49.

en la figura 4.50. De acuerdo con esta gráfica, casi no existen opciones en lo que al umbral de segmentación se refiere. Si fijamos el valor del umbral en dieciséis, se obtiene la detección de los dos cambios según se puede advertir en la figura 4.51.

Es interesante observar que para las señales sinusoidales, las medidas de distancia basadas en predicción de parámetros, tienen comportamientos extraños debido a la naturaleza no paramétrica de estas señales. Una de estas peculiaridades es la disminución, en lugar de aumento, de las medidas de distancia en las proximidades de las fronteras (ver figuras 4.42, 4.45 y 4.50).

Análisis de la señal *CFS* con el método *RGV*. Primero se aplicó con un valor muy grande para el umbral de segmentación. En la figura 4.52 se observa la evolución a través del tiempo discreto de la distancia de verosimilitud. Basándonos en esta gráfica, podemos decidir qué valor darle al umbral de segmentación. Por ejemplo, si escogemos un valor menor a 20, se detectará una falsa alarma alrededor de la muestra 100. Es necesario fijar el umbral en un valor un poco más alto. Si utilizamos un umbral de 30 obtenemos detección exacta, se detectan los cambios alrededor de la muestras 200 y 400.

Para las siguientes tres señales con cambios en las características del modelo *AR*, se tiene para todas ellas que su periodo máximo, es aquel debido al par de polos con ángulo de  $30^\circ$ , equivalente a 12 muestras. Si queremos el mínimo de falsas alarmas debidas a la selección de los parámetros estudiadas en las pruebas anteriores, podemos tomar valores del tamaño de las ventanas relativamente grandes, 500% del periodo, y para el orden de predicción, duplicaremos el orden de diseño de las señales. Para las señales *CHAR* y *CAAR* se usarán ventanas de 60 muestras y ordenes iguales a cuatro. Para la señal *COAR*, las ventanas serán de 60 muestras y el orden será de ocho.

Análisis de la señal *CHAR* con el método *FAC*. Con umbrales muy grandes, se obtiene por primera vez, en este tipo de pruebas, para este método, un comportamiento no ideal de la medida de diferencia. Sin embargo, la gráfica de la figura 5.54 nos permite tener una idea del valor que debemos asignar a los umbrales, para obtener una segmentación adecuada. En la figura 4.55 se observa el resultado de la segmentación al haber escogido umbrales iguales a 6.5. El primer cambio se detecta exactamente, pero en el segundo, el algoritmo se "pasa" unas cuantas muestras. Ambos cambios son de la misma magnitud.

Análisis de la señal *CHAR* con el método *MES*. La evolución de la *MES* mejora en comparación con el mismo tipo de gráfica para las señales sinusoidales. En la figura 4.56 se observa un comportamiento muy bueno, ya que la *MES* se mantiene baja en los intervalos de señal equivalentes al primer modelo, y sube significativamente cuando la ventana recorre la señal asociada al segundo modelo. A partir de esta gráfica, fijamos el valor del umbral de segmentación en lo que parecía un buen valor, 3.5. Sin embargo, como se observa en la figura 4.57, el umbral es demasiado alto para

### Evolución de la distancia MES

Umbral infinito




Figura 4.50.

### Evolución de la distancia MES

Umbral = 16




Figura 4.51.

### Evolución de la distancia RGV

Umbral infinito




Figura 4.52.

### Evolución de la distancia RGV

Umbral = 30




Figura 4.53.

### Evolución de la distancia FAC




Figura 4.54.

### Evolución de la distancia FAC




Figura 4.55.






Figura 4.56.




Figura 4.57.




Figura 4.58.

detectar el segundo cambio, por lo que tuvimos que disminuir el umbral a 2.2 para obtener detección de ambos cambios. En la figura 4.58 se advierte que a pesar de que se detectan los dos cambios, el posicionamiento no es el óptimo. Se tiene un cambio detectado alrededor de la muestra 190, y otro detectado en las proximidades de la muestra 460. Se observa que la magnitud de los picos no es la misma.

Análisis de la señal *CHAR* con el método *RGV*. El comportamiento observado en la medida de distancia con umbral muy grande, se muestra en la figura 4.59. Como se observa en la gráfica, existe una distancia constante conforme la ventana crece dentro de las primeras 200 muestras. A partir de la muestra 200 la distancia comienza a aumentar. En la muestra 400, después de disminuir su valor, regresa a un comportamiento parecido al de un principio. Con esta gráfica es fácil hacer un primer intento en el umbral. Tomando un valor de dos para el umbral de segmentación se obtuvo una segmentación satisfactoria, tal como se advierte en la figura 4.60. El primer cambio es detectado con mucha precisión, pero el segundo es detectado un poco antes de tiempo. Se puede notar que el segundo cambio es de mayor amplitud que el primero.

Para las siguientes dos señales, se sigue la misma metodología: se aplica el método en cuestión, haciendo que los umbrales sean muy grandes, de manera que no detengan el proceso. A continuación se determina un valor estimado tentativo para el umbral, de manera que detecte el primer cambio. Se realiza el análisis con ese valor, y se estudia si se detectaron ambos cambios. En caso contrario, se modifica el umbral para hacer posible la detección del segundo cambio. A continuación se comentan las características más sobresalientes de las gráficas obtenidas en las pruebas con estas dos últimas señales. Es importante destacar que la determinación de los umbrales se debe de hacer sobre la base de un análisis de cada tipo de señal. Un procedimiento recomendable es el observar la dinámica de las medidas de diferencia, para los análisis con umbrales infinitos, y de acuerdo con sus variaciones determinar un rango dentro del cual debe caer el valor de los umbrales. Posteriormente se debe hacer un compromiso entre el número de falsas alarmas que se permitirán, y el número de segmentos que se esconderán en el análisis.

Análisis de la señal *CAAR* con el método *FAC*. A partir de la figura 4.61 se propone un umbral igual a dos. En la figura 4.62 se observa que se detectaron ambos cambios con bastante precisión, sobre todo el primero. Ambos cambios son de la misma magnitud.

Análisis de la señal *CAAR* con el método *MES*. La figura 4.63 muestra un comportamiento normal, a partir del cual se escoge un umbral de 1.5. La figura 4.64 indica la efectividad de esta decisión al advertirse que ambos cambios son detectados, con aparentemente la misma magnitud. La precisión es mayor en el primer cambio que en el segundo.

Análisis de la señal *CAAR* con el método *RGV*. Para la primera gráfica, mostrada en la figura 4.65, se advierte un comportamiento ascendente en la medida de distancia, pero se observa que pueden existir dificultades para

### Evolución de la distancia RGV

Umbral infinito




Figura 4.59.

### Evolución de la distancia RGV

Umbral = 2.0




Figura 4.60.

### Evolución de la distancia FAC

Umbrales infinitos




Figura 4.61.

### Evolución de la distancia FAC

Umbrales = 200%




Figura 4.62.

### Evolución de la distancia MES

Umbral infinito




Figura 4.63.

### Evolución de la distancia MES

Umbral = 1.5




Figura 4.64.

### Evolución de la distancia RGV

Umbral infinito




Figura 4.65.

### Evolución de la distancia RGV

Umbral = 3.0




Figura 4.66.

detectar el primer cambio, ya que este se encuentra dentro de un valle de la distancia. Al optar por un umbral que nos detecte un poco más allá del valle, fijamos el umbral en tres. Se obtiene la gráfica de la figura 4.66 en donde se aprecia la detección de ambos cambios, aunque en el primero existe imprecisión. Ambos cambios son de la misma magnitud.

Análisis de la señal *COAR* con el método *FAC*. La gráfica de la figura 4.67 nos advierte sobre una posible falsa alarma en caso de fijar los umbrales muy abajo. Aquí existen dos alternativas, aceptar la falsa alarma y estudiar el comportamiento una vez absorbida, o saltarse la falsa alarma subiendo los umbrales. En este caso nos saltamos la falsa alarma fijando los umbrales iguales a 1. En la figura 4.68 se muestra el efecto, el primer cambio se detecta tardíamente, pero el segundo es detectado con exactitud.

Análisis de la señal *COAR* con el método *MES*. En la figura 4.69 se observa en el comportamiento de la *MES*, la posibilidad de una falsa alarma en las primeras muestras. En este caso absorbemos la falsa alarma para estudiar su efecto. En la figura 4.70 se advierte que al fijar el umbral igual a dos, se detecta, como se había previsto, una falsa alarma. Sin embargo, el no saltarnos esa falsa alarma nos produce una gran precisión en la detección de los dos cambios. Se aprecia una desigualdad en la magnitud de los cambios.

Análisis de la señal *COAR* con el método *RGV*. Este método, a diferencia de los dos anteriores, no presenta, en la gráfica de la figura 4.71, tendencias hacia la falsa alarma antes detectada en las primeras muestras. De manera que la selección del umbral se hace más sencilla. Al seleccionar un umbral igual a cinco, se produce el comportamiento observado en la figura 4.72. El primer cambio es detectado con exactitud, sin embargo, el umbral es demasiado alto para detectar el segundo cambio. En la figura 4.73 se observa el resultado producido por una ligera disminución en el umbral. Ambos cambios son detectados, y sus magnitudes son apreciablemente las mismas.

#### 4.7. Resultados.

En las simulaciones realizadas en computadora, se observó que se obtenían resultados muy buenos, a partir de una adecuada selección de los parámetros.

De una manera general, se puede decir, que si se fijan en un valor relativamente grande los tamaños de las ventanas, se mejora la segmentación. Aunque se consume mayor tiempo en el cálculo de los parámetros asociados y se utiliza más memoria.

### *Evolución de la distancia FAC*

Umbral = infinitos




Figura 4.67.

### *Evolución de la distancia FAC*

Umbral = 100%




Figura 4.68.



### Evolución de la distancia MES

Umbral infinito




Figura 4.69.

### Evolución de la distancia MES

Umbral = 2.0




Figura 4.70.

*Evolución de la distancia RGV*  
Umbral infinito




Figura 4.71.

*Evolución de la distancia RGV*  
Umbral = 4.0




Figura 4.72.

*Evolución de la distancia RGV*  
Umbral = 4.5




Figura 4.73.

Con lo que respecta al número de parámetros de comparación (correlaciones o aks), al aumentar el orden no siempre se gana precisión, debido a que una vez que se sobrepasa el orden "real", los valores dejan de ser significativos, y si se pierde tiempo en el cálculo. Los resultados de la simulaciones revelan que una reducción en el orden de predicción  $p$ , por abajo del límite inferior, resulta en un aumento en la incidencia de falsas alarmas.

Una característica importante de estos algoritmos es su necesidad de ser acondicionados a cada señal para la que serán utilizados. Uno de los ajustes más importantes es el de los umbrales de segmentación. Si estos valores no se encuentran por encima de un valor adecuado, se puede caer en innumerables falsas alarmas, o si los niveles son muy grandes, el procedimiento no detectará algunos cambios.

Durante las simulaciones se puede advertir que los métodos MES y RGV son vulnerables a señales que no hayan sido generadas con un modelo autoregresivo "estable". Al aplicarles señales sinusoidales puras, los algoritmos se disparaban en ocasiones, debido a la cercanía con la región de inestabilidad de los parámetros AR de una frecuencia pura.

A partir del estudio individual de cada uno de los algoritmos, de su implantación en lenguaje de alto nivel, y de las pruebas realizadas con ellos, podemos enumerar en las Tablas 4.1 algunas de sus características que los hacen fuertes o débiles con respecto de unos con los otros.

Tabla 4.1.a

Comportamiento con señales sinusoidales de frecuencia pura	
F A C	Detecta muy bien los cambios en las frecuencias puras, siempre y cuando el número de coeficientes de la FAC sea el suficiente para cubrir hasta el primer cruce con cero de la FAC asociada a la frecuencia menor.
M E S	Tiene dificultad al estimar los parámetros $\alpha_k$ asociados a una señal de frecuencia pura. Presenta un comportamiento contrario al normal alrededor de las fronteras, la MES disminuye para aquellas ventanas en las cuales existen muestras de dos modelos.
R G V	Se producen picos inesperados en la medida de distancia de verosimilitud debidos a la cercanía de los polos de la señal al área de inestabilidad fuera del círculo unitario, sobre todo cuando la ventana creciente tiene su tamaño mínimo.

Tabla 4.1.b

Comportamiento con señales generadas a partir de un modelo AR	
F A C	En general la medida de diferencia se comporta mejor para señales menos ruidosas. Si un segmento asociado a un modelo, es muy ruidoso, y presenta variaciones grandes en su amplitud y su frecuencia, la medida de diferencia será muy vulnerable a falsas alarmas.
M E S	Para señales generadas a partir de un modelo AR, la MES presenta un comportamiento muy bueno. Generalmente permanece constante en segmentos iguales y se observan variaciones significativas en cuanto existe un cambio. Sin embargo es propensa a falsas alarmas en ocasiones.
R G V	La medida de distancia de verosimilitud paga su precio con este tipo de señales, se comporta de una manera excelente, y es muy difícil que se encuentren brinco bruscos en esta medida cuando no existen cambios.

Tabla 4.1.c

Precisión en la detección de cambios	
F A C	Este método tiene una buena precisión en la localización de las fronteras entre segmentos, ya que como se observa en las gráficas de los experimentos en señales con cambio, detecta los cambios en las proximidades cercanas a la frontera. El algoritmo de interpolación lineal que determina el lugar exacto, mejora el primer valor estimado de manera significativa. Es necesario decir que este algoritmo consume mayor tiempo en la medida en que se le exige mayor resolución.
M E S	Este método es el más limitado en este sentido, ya que no cuenta con una etapa de optimización de la posición de la frontera. Los momentos de detección se acercan a la posición de las fronteras, aunque en ocasiones detecta los cambios un poco antes.
R G V	Este método puede hacer estimaciones de fronteras a veces mas acertadas que el método FAC. Sin embargo, la desventaja es que el proceso de optimización toma mucho tiempo y, requiere mucha memoria. Los tiempos de detección son una buena aproximación, aunque generalmente ocurren antes de la frontera.

Tabla 4.1.d

Bidireccionalidad en la detección de cambios	
F A C	El método FAC detecta los cambios en ambos sentidos de una manera similar, lo que permite que el valor del umbral sea determinado en una forma sencilla.
M E S	El método MES es el más problemático en este aspecto, ya que en ocasiones, se determina el umbral de acuerdo con el cambio en una dirección, pero al hacer el experimento, el cambio en la otra dirección es ignorado, lo que nos obliga a hacer una rectificación.
R G V	El método RGV se comporta de manera muy parecida en ambas direcciones del cambio, lo que permite simplificar el proceso de selección de umbrales.

Tabla 4.1.e

Tiempo de cálculo y facilidad de implantación	
F A C	El número de operaciones por muestra depende principalmente del número de coeficientes de la FAC truncada. La implantación de este algoritmo es sumamente sencilla ya que sus operaciones matemáticas son únicamente sumas, multiplicaciones y divisiones, estas operaciones son actualmente muy rápidas en los nuevos microprocesadores, aunque las divisiones toman más tiempo.
M E S	El número de operaciones por muestra depende en la etapa de inicialización del orden al cuadrado. Una vez que la estimación de los parámetros ha sido efectuada, las operaciones se reducen en un orden de magnitud, es decir, dependen directamente del orden. La implantación en tiempo real es muy complicada debido al cambio en el número de operaciones que sucede cada vez que se detecta un cambio.
R G V	El número de operaciones por muestra es mayor que para los dos otros métodos, pero tiene la ventaja de ser constante en todas las etapas del algoritmo. Para su implantación en tiempo real, se requiere de una arquitectura con un microprocesador especializado para procesamiento digital de señales. El cálculo de los logaritmos crea una desventaja, ya que se debe realizar mediante la búsqueda en una tabla.

## APLICACIONES DE LA SEGMENTACION

5

### 5.1. Clasificación y Reconocimiento de EEG.

Cuando se hace el análisis clínico de un electroencefalograma (EEG), el especialista busca a través de la señal la presencia de diferentes tipos de actividad, para poder hacer una interpretación y un posterior diagnóstico. Aunque puede suceder que sólo se presente actividad de un sólo tipo en un registro en particular, es más frecuente el caso en el que diferentes tipos de actividad son encontrados.

En el análisis de EEG por medio de una computadora, se seleccionan porciones que contengan tipos de actividad muy específicos, como primera fase del análisis. Generalmente en los sistemas computarizados de análisis de EEG, la intervención del operador es necesaria para seleccionar las porciones particulares del registro [Bar81]. A partir de finales de los años 70s se han desarrollado programas para la segmentación automática de EEGs, buscándose que se identifiquen las fronteras entre diferentes tipos de actividad encefalográfica.

El propósito del análisis automático de EEG, es el de obtener información cuantitativa a partir de dos diferentes filosofías. El primer método es el de análisis espectral, con él se obtiene una buena reducción de los datos, pero, al tratar al registro como una señal estacionaria, se pierde la mayor parte de la información temporal. El segundo método es el de análisis de la onda, con el cual se trata de describir a la señal en el tiempo, extrayendo patrones de ella. No obstante, el reconocimiento de estos patrones sólo es posible cuando se trata de picos muy pronunciados o elementos fuera de lo común, [Pra77].

Para lograr un buen análisis del EEG, se debe de tratar de simular lo mejor posible, la manera en que lo hace un neurólogo. Para esta simulación, se puede considerar que el EEG está compuesto de varios

segmentos de diferentes longitudes. Cada uno de estos segmentos es una señal estacionaria en la cual su contenido espectral no varía con el tiempo.

Si se tiene la señal dividida en este tipo de segmentos, perfectamente caracterizados por su espectro de potencia y su duración, y si se le extraen los eventos transitorios, se puede obtener una muy buena representación del EEG. La ventaja de lo anterior, es el poder preservar la estructura temporal de la señal. Además, si los segmentos y los transitorios pueden ser representados por un pequeño número de parámetros, éstos, se pueden comparar fácilmente por medio de métodos estadísticos. Los segmentos idénticos pueden ser agrupados, y se puede crear un algoritmo para la descripción del EEG a partir de segmentos y transitorios bien definidos, que inclusive denomine los segmentos usando la descripción verbal que utilizan los neurólogos.

El propósito original del análisis por segmentación del EEG fue presentado por [Pra77] y [Bod77], y se trataba de encontrar en una señal de EEG, aquellos segmentos que podía considerarse tenían propiedades estadísticas invariables. Esto significa que se debía considerar a estos segmentos como cuasiestacionarios, y se debía tener en cuenta que el tamaño de estos segmentos era variable. Esta teoría creó una gran necesidad por el desarrollo de criterios y procedimientos para encontrar las fronteras de los segmentos. Gran parte del desarrollo de los métodos desarrollados en el capítulo 4 se deben a los esfuerzos enfocados a segmentar EEG.

Los principales elementos de un sistema automático de análisis de EEG según [Bar81] son: (a) segmentación, (b) agrupación de los segmentos en grupos representativos, (c) obtención de una gráfica del comportamiento de las diferentes clases en el tiempo asociándoles su amplitud y frecuencia promedio, y (d) cálculo del espectro asociado a cada tipo de actividad (estado).

En el primer paso, el de la segmentación, se puede utilizar cualquiera de los tres algoritmos descritos en el capítulo anterior. Sin embargo en la literatura ([Bar81], [Mic78] y [Pra77]) se reportan resultados aceptables usando técnicas de segmentación del tipo FAC, basadas en cambios de amplitud y frecuencia. Se ha encontrado que el método FAC se aproxima al proceso visual que realiza un especialista clínico. [Bar81].

Para agrupar los segmentos de EEG, se deben establecer clases típicas contra las cuales serán comparados los segmentos en análisis. En este punto, se pueden utilizar técnicas computacionales sofisticadas, tales como bases de datos relacionales, sistemas expertos, programación orientada a objetos, etc.

El perfil temporal del comportamiento del EEG es muy importante para el diagnóstico, ya que representa el resultado de la agrupación. Esta gráfica es comúnmente llamada hipnograma, debido a su asociación con estados de sueño, y es muy útil ya que representa la distribución en el tiempo de tipos de actividad particulares. En la figura 5.1 se muestra un

burdo ejemplo de este tipo de gráfica. En el eje de las abscisas se representa el tiempo del registro, mientras que en el eje de las ordenadas se representan las diferentes clases típicas. En la gráfica se observa como evoluciona el EEG a través del tiempo pareciéndose por intervalos a las clases típicas previamente fijadas (en este caso son cuatro).




Figura 5.1.

El espectro de potencia se calcula como se menciona en el capítulo 1, a partir de los coeficientes de autocorrelación de la clase en cuestión, o a partir de un método paramétrico que involucre los parámetros AR de la clase. Estos espectros de potencia pueden ser patrones representativos de cada clase, lo mismo que la función de autocorrelación.

A partir del análisis del EEG por medio de métodos de segmentación surgen varias preguntas. La primera es obviamente, qué tan buenos son los resultados del análisis como para que se haga un diagnóstico directo, y la segunda es cómo se puede hacer uso de estos métodos en aspectos que no intervengan en el diagnóstico. La respuesta a la primera pregunta es la más difícil de obtener, existen especialistas de las neurociencias que son muy entusiastas con respecto a estos métodos, sin embargo existen otros que cuestionan fuertemente la validez de estos análisis. Se ha visto que los sistemas computarizados de EEG son en la mayoría de los casos usados como herramienta auxiliar y sus resultados son siempre supervisados por un especialista. La respuesta a la segunda pregunta es menos conflictiva, este tipo de análisis puede ser usado para reducir la enorme cantidad de datos de registros de EEG, al quitarle la redundancia al registro.



## 5.2. Reconocimiento de Voz.

El reconocimiento de voz es el paso final del esfuerzo de simplificar el proceso de comunicación entre el hombre y sus máquinas. Consiste en sistemas de reconocimiento de voz automática (RVA), que permiten que un operador humano utilice comandos hablados comunes para interactuar con un proceso computacional. A través de la historia moderna, la comunicación entre el hombre y sus máquinas ha sido de acuerdo a los requerimientos operacionales de las máquinas. El poder controlar máquinas o computadoras requiere del aprendizaje de lenguajes especiales o de secuencias complicadas de comandos por medio de palancas, botones y mandos, en el orden correcto. Cualquier desviación de estas restricciones produce errores difíciles de detectar debido a la complejidad de las reglas de comunicación entre el hombre y sus máquinas.

El desarrollo de sistemas de reconocimiento de voz, aunque de capacidades limitadas, ha hecho posible por primera vez que los humanos le "digan" directamente a la máquina lo que desean que haga, sin necesidad de difíciles pasos de tecleo de botones. La alimentación de datos a las máquinas se simplifica desde el momento en que el operador da las instrucciones en su lenguaje natural. La máquina por tanto se adapta a las necesidades del ser humano, y simplifica de gran manera la intercomunicación entre los dos. [Mar76]

Las cuatro funciones principales contenidas en un sistema simple de reconocimiento de voz, con un vocabulario limitado se presenta en [Mar76], y se reproduce aquí en la figura 5.2. Este sistema consiste de un micrófono transductor, un preprocesador, un extractor de rasgos, y de un clasificador de nivel para hacer la decisión final.




Figura 5.2.

Es posible pasar la señal de voz por múltiples transformaciones de manera que se realcen ciertas propiedades para hacerlas más detectables en un sistema de RVA. La señal de voz no es ni periódica ni aperiódica, se considera como una señal cuasiperiódica, tal que las técnicas analíticas

desarrolladas para su análisis deben reflejar sus características temporales y frecuenciales de importancia. Este punto de vista hace necesario que se modifiquen las técnicas clásicas de análisis en el dominio del tiempo y de la frecuencia. Para mantener ambos tipos de características en el análisis, se debe de proceder por medio de técnicas que produzcan espectros de corta duración. Es aquí, en el preprocesador, donde los métodos de segmentación tienen aplicación. Si se segmenta adecuadamente la señal de voz se puede hacer este análisis espectral de una manera óptima.

La representación frecuencial de una señal de voz presenta ventajas ya que se conoce que el sistema auditivo humano realiza un crudo análisis frecuencial como parte del sistema sensorial auditivo, y además, se ha demostrado que una descripción exacta de un sonido es obtenida por medio de modelos de frecuencia natural. [Mar76]

El análisis espectral es únicamente un paso inicial en el procesamiento de voz. Se requiere una considerable cantidad de procesamiento posterior para lograr detección y reconocimiento de los rasgos significativos de la voz. Sin embargo, un análisis incorrecto en el preprocesador puede destruir o esconder los rasgos que serán buscados posteriormente. La codificación por predicción lineal (LPC) ha sido extensamente aplicada en sistemas de comunicación que manejan voz. Esto ha propiciado el estudio y posterior conclusión de que los parámetros  $\alpha$  pueden ser usados como rasgos en un esquema de reconocimiento. Una ventaja de utilizar un método de segmentación paramétrico sería que además de obtener análisis espectral óptimo de los sonidos, se obtienen los segmentos caracterizados por sus parámetros predictivos.

Para los diferentes procesos de RVA se han desarrollado herramientas matemáticas muy formales, pero hasta ahora no existe una teoría general que pueda seleccionar las porciones de voz que contienen la información. Es por ésto, que el diseño de los extractores de rasgos debe de hacerse de una manera heurística usando estrategias numéricas de acuerdo con cada aplicación. Sólo después de un análisis experimental de los resultados es como se puede calificar un conjunto de rasgos. En la actualidad, numerosos grupos de investigación enfocan sus esfuerzos al diseño de extractores de rasgos para sistemas de reconocimiento de patrones, ya que éstos son la parte esencial de tal sistema.

La decisión se hace en un proceso de clasificación que generalmente es realizado por una computadora. Cuando se detecta el final de un vocablo, la duración de la palabra es tradicionalmente dividida en un número fijo de segmentos (generalmente 16) y los rasgos son reconstruidos en una base de tiempo. La lógica del clasificador compara estos rasgos ocurridos contra rasgos característicos guardados en una especie de diccionario, y determina a cuál se le parece más.

El esquema anterior funciona satisfactoriamente para palabras solas, pero cuando se trata de reconocimiento de palabra continua, con grandes requerimientos de vocabulario, existen todavía muchos problemas por

resolver. Una de las posibles soluciones según [And88] es el tratar de reconocer las unidades fonéticas básicas de la voz. Un sistema que logre ésto se conoce como sistema de reconocimiento analítico. En la figura 5.3 se presenta un diagrama a bloques simplificado de tal sistema.

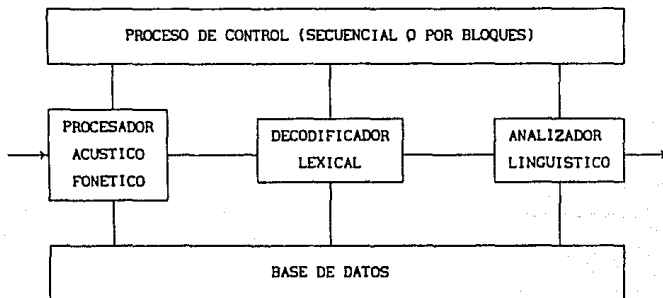


Figura 5.3.

El procesador acústico fonético codifica la señal de voz en una cadena de unidades de subpalabras, como fonemas, difonemas, sílabas, etc. El decodificador léxico reconoce palabras a partir de la cadena de subpalabras previamente obtenida. El analizador lingüístico toma en cuenta las reglas de semántica y lingüística relevantes a la aplicación en cuestión. El proceso de control tiene como objetivo coordinar y supervisar a los demás bloques.

La aplicación de la segmentación se haya dentro del nivel del procesador acústico fonético. En este nivel es donde se requiere la segmentación de la palabra continua.

## CONCLUSIONES Y PERSPECTIVAS

6

### 6.1. Conclusiones.

Durante las simulaciones se pudo observar que lo más importante al usar alguno de estos algoritmos, debe ser la selección adecuada de los parámetros del análisis (tamaño de las ventanas, número de coeficientes o parámetros de predicción, umbrales de segmentación, traslape, etc.)

En los métodos FAC y RGV se utilizan procedimientos sofisticados para la determinación de las fronteras, sin embargo, no existe razón para pensar que este tipo de procedimientos adaptables no puedan ser incorporados al método MES.

El método FAC tiene la ventaja principal de la simplicidad. Este método puede implantarse en casi cualquier arquitectura y sus resultados, cuando esta bien calibrado, son adecuados.

Una de las ventajas evidentes del algoritmo RGV es que puede ser implantado de una manera sencilla en un microprocesador especializado ya que el número de operaciones por muestra se mantiene constante tanto en el proceso de búsqueda de un cambio como en el proceso de la determinación exacta de la posición. Este procedimiento requiere, sin embargo de más operaciones por muestra en comparación con los otros dos algoritmos. Tiene la desventaja de que se debe efectuar el cálculo de varias divisiones y de dos logaritmos, los cuales en arquitecturas de microprocesadores especializados, toman mucho tiempo u ocupan bastante memoria debido a que debe efectuarse por medio de una tabla.

Para los tres algoritmos, es posible introducir nuevas tendencias más rápidas y más robustas, de cálculo de correlaciones y de predicción de parámetros. Por ejemplo, si para el método MES se cambiara el algoritmo de estimación de parámetros por un algoritmo recursivo rápido que implica un

número de operaciones proporcionales a  $p$ , se eliminaría un orden de magnitud en el número de operaciones por muestra, ya que el algoritmo de Levinson implica operaciones del orden de  $p^2$ .

Es muy importante, contar con una buena metodología de calibración de cada uno de los algoritmos para cada señal en específico. A partir del estudio de este trabajo se puede pensar en la proposición de una secuencia de procedimientos que nos calibren de manera heurística, cada algoritmo. Es necesario tomar en cuenta las características de la señal real. Es aconsejable tomar información de especialistas en cada señal sobre datos como el orden aproximado de la señal cuando se aproxima a un modelo AR. Es importante también, conocer la duración mínima de un segmento significativo para el proceso de clasificación. Una vez obtenida esta información, se deberá hacer un análisis espectral de la señal de manera que se obtengan frecuencias significativas. A partir de este análisis podemos proponer un estimado para los tamaños de las ventanas y los órdenes de predicción o número de correlaciones. El siguiente paso es obtener un valor adecuado para el o los umbrales de segmentación, que nos produzcan una señal segmentada apropiadamente a nuestras necesidades posteriores. Es importante recordar que estos algoritmos se proponen en este trabajo como parte de un sistema que realiza una actividad más elaborada, como el caso de la clasificación y el reconocimiento, y por tanto es posible pensar que una vez acoplados al sistema, existirá interacción entre sus diferentes etapas con vistas a un mejor desempeño. Por ejemplo, una vez determinadas las diferentes clases típicas en un sistema de reconocimiento y clasificación de EEG, será posible determinar umbrales de acuerdo con las diferentes combinaciones entre las clases.

## 6.2. Perspectivas.

El estudio de los cambios es un tema que puede llevar a conocer a fondo ciertos fenómenos naturales. Si a través del estudio, por ejemplo, de las señales sísmicas de una zona de la tierra, podemos llegar a caracterizar de alguna manera científica los cambios que ocurrieron en la señal algunos momentos antes de un temblor, quizá se puedan diseñar sistemas que reconozcan este tipo de cambios en el futuro y sean capaces de tomar una decisión importante.

La caracterización de los cambios en las señales de la naturaleza puede ayudar a conocer mejor los sistemas que las producen y a comprender las diferentes situaciones que propician diferencias en las señales. Con una adecuada caracterización de las señales que produce nuestro cuerpo podemos llegar a comprender mejor su funcionamiento, sobre todo en lo que se refiere al sistema nervioso central. A partir de cambios producidos en las señales cerebrales, los especialistas en la materia pueden detectar

comportamientos y clasificarlos dentro de patrones empiricos de normalidad y anormalidad.

Por medio del estudio de los cambios de señales se puede lograr una mejor interacción de las computadoras con el medio que las rodea. Si la computadora posee una manera de transformar su entorno visual en una señal eléctrica, el siguiente paso es el poder lograr que la computadora reconozca las diferentes regiones de ese campo visual, y de esta manera asocie lo que "ve", con experiencias pasadas o con patrones predeterminados por el programador.

El reconocimiento e identificación de la voz humana por una computadora es una disciplina en la que todos los días se mejoran los sistemas, algunos de estos avances se han logrado gracias a nuevas técnicas que permiten seccionar las palabras y dividir las en elementos básicos que puedan ser relacionados con alguna base de datos para su identificación.

En un sistema de reconocimiento y clasificación de EEG se requiere una etapa de segmentación previa al procesamiento para evitar el análisis de información redundante y aumentar la eficiencia del reconocimiento. Por lo tanto, es de gran importancia el agregar una etapa de segmentación en dichos sistemas. La realización de este trabajo permitirá la implantación de dicha etapa dentro del sistema de clasificación y reconocimiento de señales bioeléctricas en desarrollo en la DEPFI-UNAM.

Tomando como base los resultados de este trabajo, se está preparando un artículo en el cual se presenta una metodología de selección y de calibración de los algoritmos de segmentación estudiados, de acuerdo con las características de las señales de EEG. Lo anterior, tomando en cuenta los criterios de tiempo de cálculo, complejidad de la estructura, facilidad de implantación y desempeño de los algoritmos. El artículo se titula "Selección y Calibración de Algoritmos de Segmentación dentro de un Sistema de Reconocimiento y Clasificación de señales EEG".

## BIBLIOGRAFIA.

- [Alc86] Alcántara, Rogelio. "Implantación de Algoritmos Rápidos en Microprocesadores Especializados de Señales". Tesis de Doctorado. Escuela Nacional Superior de Telecomunicaciones. París, Francia. Septiembre 1986. En Francés.
- [Alc89] Alcántara, Rogelio. *Apuntes de Procesamiento Digital de Señales*. DEPMI-UNAM. México, D.F. 1989.
- [And88] Andre-Obrecht, Regine. "A New Statistical Approach for the Automatic Segmentation of Continuous Speech Signals". *IEEE Transactions on Acoustics, Speech and Signal Processing*. Vol. 36. No. 1. January 1988. pp. 29-40.
- [App83] Appel, Ulrich y Brandt, Achim v. "Adaptive Sequential Segmentation of Piecewise Stationary Time Series". *Information Sciences*. Vol 29. 1983. pp. 27-56.
- [App84] Appel, Ulrich y Brandt, Achim v. "A Comparative Study of Three Sequential Time Series Segmentation Algorithms". *Signal Processing*. Vol. 6. 1984. pp. 45-60.
- [Bar81] Barlow, J. S., Creutzfeldt, O. D., Michael, D., Houchin, J., y Epelbaum, H. "Automatic Adaptive Segmentation of Clinical EEGs". *Electroencephalography and Clinical Neurophysiology*. No. 51. 1981. pp. 512-525.

- [Bas88] Basseville, Michèle. "Detecting Changes in Signals and Systems - A Survey". *Automatica*. Vol. 24. No. 3. 1988. pp. 309-326.
- [Bod77] Bodenstein, Günter y Praetorius, H. Michael. "Feature Extraction from the Encephalogram by Adaptive Segmentation". *Proceedings of the IEEE*. Vol. 65. No. 5. May 1977. pp. 642-652.
- [Bra83] Brandt, Achim v. "Detecting and Estimating Parameter Jumps Using Ladder Algorithms and Likelihood Ratio Tests". *Proceedings of the International Conference on Acoustic Speech and Signal Processing ICASSP 83, BOSTON*. 1983. pp. 1017-1020.
- [Fr182] Friedlander, Benjamin. "Lattice Filters for Adaptive Processing". *Proceedings of the IEEE*. Vol. 70. No. 8. August 1982. pp. 829-867.
- [Kay81] Kay, Steven M., y Marple Jr., Stanley Lawrence. "Spectrum Analysis - A Modern Perspective". *Proceedings of the IEEE*. Vol. 69. No. 11. November 1981. pp. 1380-1419.
- [Mak75] Makhoul, John. "Linear Prediction: A Tutorial Review". *Proceedings of the IEEE*. Vol. 63. 1975. pp. 561-580.
- [Mar76] Martin, Thomas B. "Practical Applications of Voice Input to Machines". *Proceedings of the IEEE*. Vol. 64. April 1976. pp. 487-501.
- [Mic79] Michael, D. y Houchin, J. "Automatic EEG Analysis: A Segmentation Procedure Based on the Autocorrelation Function". *Electroencephalography and Clinical Neurophysiology*. Vol. 46. 1979. pp. 232-235.
- [Opp83] Oppenheim, A. V. y Schafer, Ronald W. *Digital Signal Processing*. Prentice Hall. Englewood Cliffs, NJ. 1983.
- [Pap84] Papoulis, Athanasios. *Probability, Random Variables, and Stochastic Processes*. Second Edition. McGraw Hill International Editions. Singapore. 1984



- [Pra77] Praetorius, H. M., Bodenstein, G., y Creutzfeldt, O. D. "Adaptive Segmentation of EEG Records: A New Approach to Automatic EEG Analysis". *Electroencephalography and Clinical Neurophysiology*. No. 42. 1977. pp. 84-94.
- [Por82] Porat, B., Friedlander, B., y Morf, M. "Square-root Covariance Ladder Algorithms". *IEEE Transactions on Automatic Control*. Vol. AC-27. No. 4. 1982. pp. 813-829.
- [The89] Therrien, Charles W. *Decision Estimation and Classification: An Introduction to Pattern Recognition and Related Topics*. John Wiley & Sons. U.S.A. 1989.
- [Van68] Van Trees, H.L. *Detection, Estimation, and Modulation Theory*. John Wiley & Sons. U.S.A. 1968.

## APENDICE 1

### A1. Sistema de Simulación en Microcomputadora PC.

Al correr el programa SIMULA.EXE, aparece en la pantalla el menú principal de la pantalla A1.1. A partir de este momento la nomenclatura de las pantallas es la siguiente, el texto que aparece es el mismo que se ve en la pantalla, el símbolo (!) representa un carácter desplegado por la computadora y que depende de la corrida, y el símbolo (?) representa información que debe ser introducida por el usuario.

1. Algos.
2. Segmentación.
3. Sumar archivos.
4. Salir.

Opción >?

#### Pantalla A1.1

La opción 1 del menú principal nos lleva al programa ALGOS, para desplegar señales y hacerles procesamiento. (El programa ALGOS está en etapa de desarrollo por diferentes becarios de la DEPEFI-UNAM y a cargo del Dr. Rogelio Alcántara. Aunque he tomado parte en el desarrollo del programa no considero prudente que en este trabajo se mencione su modo de

uso). El programa ALGOS nos sirvió para generar las señales sintéticas AR a partir de los polos y los ceros, y las señales sintéticas sinusoidales. Con el programa ALGOS obtuvimos los espectros utilizados en el capítulo 4.

La opción 2 del menú principal nos lleva al menú de segmentación de la pantalla A1.2.

1. Función de AutoCorrelación
2. Medida de Error eSpectral.
3. Razón Generalizada de verosimilitud.

Opción >?

Pantalla A1.2

La opción 1 del menú de segmentación nos lleva al menú del método FAC de la pantalla A1.3. En este menú se presentan en la derecha los parámetros y archivos utilizados en la última corrida.

Definición de los parámetros de análisis (Método FAC)

- |                               |              |
|-------------------------------|--------------|
| 1. Archivo de señal           | !!!!!!!!!!!! |
| 2. Archivo de correlaciones   | !!!!!!!!!!!! |
| 3. Tamaño de la ventana       | !!           |
| 4. Número de coeficientes FAC | !!           |
| 5. Umbral de amplitud         | !!!!!!       |
| 6. Umbral de frecuencia       | !!!!!!       |
| 7. Traslape                   | !!           |
| 8. Número de iteraciones      | !!           |
| 9. Análisis                   |              |
| 0. Salir                      |              |

Opción ==>?

Pantalla A1.3

La opción 1 del menú FAC nos desplegará los archivos de señal (extensión .DAT) que existen en el directorio actual, y nos pedirá el nombre del archivo correspondiente a la señal a analizar. (Pantalla A1.4).

```

Volumen en unidad ! etiquetado !!!!!!!!!!!!!
Directorio de !:\

!!!!!!!!.DAT      !!!!!!!!!.DAT      !!!!!!!!!.DAT      !!!!!!!!!.DAT
!!!!!!!!.DAT      !!!!!!!!!.DAT      !!!!!!!!!.DAT      !!!!!!!!!.DAT
      ! Archivo(s)  !!!!!!!!! bytes libres

Máximo número de muestras = 8192
Nombre completo del archivo de señal : ?????????????

```

*Pantalla A1.4*

La opción 2 del menú FAC nos pide el nombre del archivo en donde se guardará el resultado de la segmentación. En la pantalla A1.5, además se especifica el formato de este archivo.

```

En este archivo se guarda el resultado de la
segmentación de la siguiente manera:

      Número de muestras totales
      Número de coeficientes por segmento
      Por cada segmento:
          Muestra de inicio del segmento
          Coeficientes del segmento
          Muestra de fin del segmento

Nombre completo del archivo de correlaciones : ?????????????

```

*Pantalla A1.5*

La opción 3 del menú FAC sirve para cambiar el tamaño de la ventana, tanto de la de referencia como la deslizante. (Pantalla A1.6).

La opción 4 del menú FAC nos permite determinar el número de coeficientes de correlación que caracterizarán a la ventana. (Pantalla A1.7).

Tamaño actual de la ventana = 11  
Nuevo tamaño de la ventana ( $0 < LV \leq 256$ ) : ?

*Pantalla A1.6*

Coefficientes por bloque  $R(0), \dots, R(1)$   
Nuevo número de coeficientes  
por bloque  $R(0), \dots, R(N-1)$ , ( $2 \leq N \leq 16$ ) = ?

*Pantalla A1.7*

Las opciones 5 y 6 del menú FAC permiten mover independientemente los umbrales de amplitud y frecuencia. (Pantallas A1.8 y A1.9 respectivamente).

Umbral de amplitud = !!!!!!!!!!!  
Nuevo umbral de amplitud : ?

*Pantalla A1.8*

Umbral de frecuencia = !!!!!!!!!!!  
Nuevo umbral de frecuencia : ?

*Pantalla A1.9*

La opción 7 del menú FAC sirve para determinar el traslape entre ventanas, siendo un traslape de cero equivalente a un análisis sin traslape. El máximo traslape es el tamaño de la ventana menos uno. (Pantalla A1.10)

```
Traslape = !!  
Traslape (máximo !!) : ?
```

*Pantalla A1.10*

En la opción 8 del menú FAC se fija el número de iteraciones que se hacen en la interpolación lineal que determina la posición de las fronteras. (Pantalla A1.11). El máximo número de iteraciones es igual al tamaño de la ventana.

```
Iteraciones = !!  
Iteraciones (máximo !!) : ?
```

*Pantalla A1.11*

La opción 9 del menú FAC da comienzo a el análisis en sí. El programa al ir recorriendo la señal presenta la pantalla A1.12. La información es sobre la extensión de la ventana de prueba, la diferencia porcentual de amplitud *DPA*, la diferencia porcentual de frecuencia *DPF* y la diferencia total *DT*.

Una vez que encuentra un cambio, determina la posición exacta de la frontera y presenta la pantalla A1.13. Esta pantalla contiene información acerca de la interpolación lineal, hasta que finalmente encuentra la distancia  $D(t)$  que debe retrocederse y notifica del lugar del cambio de modelo y de las diferencias ocurridas en ese punto. Al final del análisis se presenta el valor máximo de la diferencia en la pantalla A1.14.

!!!! Muestras leidas

-----  
Ventana (!! - !!)

DPA = !!!!!.!!!!  
DPF = !!!!!.!!!!  
DT = !!!!!.!!!!  
-----

Pantalla A1.12

Determinación de la posición exacta:

-----  
Muestra !!  
A(x) = !!!!!.!!  
AUX = !!!  
-----

D(t) = !!  
A(t) = !!!!!.!!  
m x (A(x)) = !!!!!.!!  
-----

Cambio de modelo en !!  
DPA = !!!!!.!!!!  
DPF = !!!!!.!!!!  
DT = !!!!!.!!!!  
-----

<Teclee cualquier tecla para continuar>

Pantalla A1.13

-----  
Fin del análisis

DT máx = !!!!!.!!!!  
-----

<Teclee cualquier tecla para continuar>

*Pantalla A1.14*

La opción 2 del menú de segmentación nos lleva al menú del método MES de la pantalla A1.15. En este menú se presentan también en la derecha los parámetros y archivos utilizados en la última corrida.

Definición de los parámetros de análisis (Método MES)

- |                               |              |
|-------------------------------|--------------|
| 1. Archivo de señal           | !!!!!!!!!!!! |
| 2. Archivo de parámetros AR   | !!!!!!!!!!!! |
| 3. Tamaño de la ventana       | !!           |
| 4. Orden del filtro PE        | !!           |
| 5. Coeficientes FAC del error | !!           |
| 6. Umbral de segmentación     | !!!!!!.      |
| 7. Incremento de barrido      | !!           |
| 8. Análisis                   |              |
| 0. Salir                      |              |

Opción ==>?

*Pantalla A1.15*

Las opciones 1 y 3 del menú MES son equivalentes al primer método y se refieren a las pantallas A1.4 y A1.6 respectivamente.

La opción 2 del menú MES nos pide el nombre del archivo en donde se guardará el resultado de la segmentación. En la pantalla A1.16, se especifica además el formato de este archivo.



En este archivo se guarda el resultado de la segmentación de la siguiente manera:

Número de muestras totales  
Orden del predictor por segmento  
Por cada segmento:  
    Muestra de inicio del segmento  
    Parámetros AR del segmento  
    Muestra de fin del segmento

Nombre completo del archivo de parámetros AR : ??????????????

*Pantalla A1.16*

La opción 4 del menú MES nos permite cambiar el orden del modelo AR con la pantalla A1.17.

Parámetros AR por bloque  $a(0), \dots, a(!)$

Nuevo orden del predictor  
 $a(0), \dots, a(p-1), (2 \leq p \leq 16) = ?$

*Pantalla A1.17*

La opción 5 del menú MES sirve para fijar el número de correlaciones que se le calcularán al error de predicción. (Pantalla A1.18)

Correlaciones del error  $r(0), \dots, r(!)$

Nuevo número de correlaciones  
del error  $r(0), \dots, r(M-1), (2 \leq M \leq 16) = ?$

*Pantalla A1.18*

La opción 6 del menú MES nos permite variar el umbral de segmentación.  
(Pantalla A1.19)

Umbral de segmentación = !!!!!!!!!!!

Nuevo umbral de segmentación : ?

Pantalla A1.19

La opción 7 del menú MES nos permite variar el barrido de la ventana deslizante, un barrido de 1 hace que la ventana avance muestra por muestra.  
(Pantalla A1.20).

Incremento de barrido = !!

Nuevo barrido (máximo !!) : ?

Pantalla A1.20

La opción 8 del menú MES corre dicho método. Para cada paso del análisis se despliega la pantalla A1.21 en donde se da información de la ventana de prueba y el valor de la Medida de Error eSpectral.

!!! Muestras leídas

-----  
Ventana (!! - !!)

Medida de Error eSpectral = !!!!!.!!!!

-----  
Pantalla A1.21

Una vez que se encuentra un cambio se notifica con la pantalla A1.22.

```
-----  
Cambio en !!  
-----  
  
<Teclee cualquier tecla para continuar>
```

*Pantalla A1.22*

Al final del análisis se presenta en la pantalla A1.23 el valor máximo que tomó la MES durante la corrida.

```
-----  
Fin del análisis  
MES máxima = !!!!!.!!!!  
-----  
  
<Teclee cualquier tecla para continuar>
```

*Pantalla A1.23*

La opción 3 del menú de segmentación nos lleva al menú del método RGV de la pantalla A1.24. También en este menú se presentan en la derecha el archivo y los parámetros utilizados en la última corrida.

La opción 1 del menú RGV nos presenta con una pantalla similar a las de los métodos anteriores, sólo que como este programa funciona en línea, no existe restricción respecto al tamaño del archivo de señal. (Pantalla A1.25).

La opción 2 del menú RGV cambia el tamaño de la ventana deslizando mediante una pantalla idéntica a la A1.6.

Definición de los parámetros de análisis (Método RGV)

- |                                    |              |
|------------------------------------|--------------|
| 1. Archivo de señal                | !!!!!!!!!!!! |
| 2. Tamaño de la ventana deslizante | !!           |
| 3. Orden del predictor             | !!           |
| 4. Umbral de segmentación          | !!!!!!!!!!!! |
| 5. Análisis                        |              |
| 0. Salir                           |              |

Opción ==>?

Pantalla A1.24

Volumen en unidad ! etiquetado !!!!!!!!!!!!!

Directorio de !:\

!!!!!!!!!.DAT	!!!!!!!!!.DAT	!!!!!!!!!.DAT	!!!!!!!!!.DAT
!!!!!!!!!.DAT	!!!!!!!!!.DAT	!!!!!!!!!.DAT	!!!!!!!!!.DAT
! Archivo(s) !!!!!!!!!! bytes libres			

El archivo puede ser de cualquier tamaño

Nombre completo del archivo de señal : ?????????????

Pantalla A1.25

La opción 3 del menú RGV nos permite cambiar el orden del predictor usado en los algoritmos Ladder mencionados en el capítulo 2. (Pantalla A1.17).

Con la opción 4 del menú RGV se varía el umbral de segmentación contra el cual se compara la distancia de verosimilitud. (Pantalla A1.19).

La opción 5 del menú RGV corre un análisis de acuerdo con los parámetros ya establecidos. Para cada muestra, se presenta una pantalla en donde se muestran los intervalos de las ventanas creciente y deslizante y el valor de la distancia de verosimilitud. (Pantalla A1.26)

-----  
Ventana creciente (!! - !!)

Ventana deslizante (!! - !!)

d = !!!!!.!!!!  
-----

*Pantalla A1.26*

Cuando se detecta un cambio y se determina su posición se presenta la pantalla A1.27 para mostrar la posición de la frontera.

-----  
Se detectó un cambio en !!  
-----

<Teclee cualquier tecla para continuar>

*Pantalla A1.27*

Cuando se termina la señal, en la pantalla A1.28 se despliega el valor máximo de la distancia de verosimilitud.

La opción 3 del menú principal permite construir señales compuestas con varios modelos. El programa pide el nombre de los archivos que se suman y el nombre que se le quiere dar a la suma. (Pantalla A1.29).

Todas las opciones denominadas "Salir" regresan a un menú anterior o salen del menú principal.

-----  
Fin del análisis

d máxima = !!!!!.!!!!

-----  
<Teclee cualquier tecla para continuar>

Pantalla A1.28

Volumen en unidad 1 etiquetado !!!!!!!!!!!  
Directorio de 1:\

!!!!!!!.DAT    !!!!!!!!.DAT    !!!!!!!!.DAT    !!!!!!!!.DAT  
!!!!!!!.DAT    !!!!!!!!.DAT    !!!!!!!!.DAT    !!!!!!!!.DAT  
! Archivo(s)    !!!!!!!! bytes libres

Nombre del archivo 1 > ??????????????

Nombre del archivo 2 > ??????????????

Nombre del resultado > ??????????????

!!! Muestras en la suma

Pantalla A1.25

## APENDICE 2

### A2. Listado de los programas en TURBO PASCAL.

A continuación se presenta el listado del programa del método de segmentación FAC.

```

{
  (* PROGRAMA PARA DETECTAR CAMBIO DE MODELO EN
  (* UNA SEÑAL UTILIZANDO EL MÉTODO DE LA
  (* FUNCIÓN DE AUTOCORRELACIÓN
  *)
PROGRAM AUTOCOR;
($M 4000,0,0)
USES
  DOS,CRT;
CONST
  UMBRAL = 1.00;      (* VALOR DEL UMBRAL DE DETECCIÓN
  MAXORD = 10;       (* VALOR MÁXIMO DEL ORDEN
  MAXVENT = 256;     (* LONGITUD MÁXIMA DE LA VENTANA
  MAXARCH = 6192;    (* MÁXIMO NÚMERO DE MUESTRAS
TYPE
  CC = RECORD
    S : STRING;      (* ARCHIVO DE PARAMETROS
    G : STRING;
    O : INTEGER;
    OP : REAL;
    IV : INTEGER;
  END;
  DIM = ARRAY [1..MAXARCH] OF REAL;
  DIMO = ARRAY [1..MAXORD] OF REAL;
  DIMV = ARRAY [1..MAXVENT] OF REAL;
VAR
  CONF : CC;          (* CONFIGURACION ANTERIOR
  X : DIM;           (* VALORES DE LA SEÑAL COMPLETA
  RE,
  RS,
  RAUX : DIMO;       (* FAC DE LA VENTANA DE PRUEBA
  (* FAC DE LA VENTANA DE REFERENCIA
  (* FAC AUXILIAR
  Y : DIMV;          (* VALORES DE LA VENTANA
  OPCION,
  YZLA : CHAR;
  SEÑAL,
  CORR : CORRELACIONES; (* NOMBRE DEL ARCHIVO DE CORRELACIONES

```







```

'2': BEGIN
      RNDOM(1,1,80,25);
      C=0;
      REPEAT
        C=C+1;
        WRITE(2) 'En este archivo se guarda el resultado de la';
        WRITE(2) 'segmentacion de la siguiente manera';
        WRITE(2) 'Numero de muestras totales';
        WRITE(2) 'Numero de coeficientes por segmento';
        WRITE(2) 'Por cada segmento';
        WRITE(2) 'Muestra de inicio del segmento';
        WRITE(2) 'Coeficientes del segmento';
        WRITE(2) 'Muestra de fin del segmento';
        WRITE(2) 'Nombre completo del archivo de correlaciones : ';
      UNTIL C=24;
      RNDOM(47,24,59,25);
      REPEAT
        WRITE(1) 'REPETICION(_____)';
        READ(1) (CORR);
        UNTIL (CORR > 1);
        ASSIGN (ARCH2,CORR);
        WRITE(ARCH2);
        REPEAT
          I=I+1;
          IORESULT = 0;
        UNTIL I=24;
        CLOSE(ARCH2);
      UNTIL C=24;
      ENDD=2;
'3': BEGIN
      RNDOM(1,1,80,25);
      C=0;
      REPEAT
        C=C+1;
        WRITE(2) 'Tamaño actual de la ventana = ',LV;
        WRITE(2) 'Nuevo tamaño de la ventana (0 < LV ≤ ',MAXVENT,')';
        WRITE(2) 'REPETICION(_____)';
        WRITE(2) 'Muestra de inicio del segmento';
        WRITE(2) 'Coeficientes del segmento';
        WRITE(2) 'Muestra de fin del segmento';
        UNTIL (LV > 0) AND (LV ≤ MAXVENT);
      REPEAT
        ENDD=3;
'4': BEGIN
      RNDOM(1,1,80,25);
      IF C=1 THEN
        I=1;
        WRITE(1) 'Coeficientes por bloque R(0),...,R('LFAC-1,')';
        WRITE(1) 'REPETICION(_____)';
        WRITE(1) 'Nuevo numero de coeficientes';
        WRITE(1) 'Muestra de inicio del segmento';
        WRITE(1) 'Muestra de fin del segmento';
        WRITE(1) 'Coeficientes del segmento';
        UNTIL (LFAC > 1) AND (LFAC ≤ MAXORD);
      REPEAT
        ENDD=4;
'5': BEGIN
      RNDOM(1,1,80,25);
      C=0;
      REPEAT
        C=C+1;
        WRITE(1) 'Amplitud de amplitud = ',UMBA:10:4;
        WRITE(1) 'Nuevo umbral de amplitud :';
        WRITE(1) 'REPETICION(_____)';
        WRITE(1) 'Muestra de inicio del segmento';
        WRITE(1) 'Muestra de fin del segmento';
        WRITE(1) 'Coeficientes del segmento';
        UNTIL (UMBA > 0);
      REPEAT
        ENDD=5;
'6': BEGIN
      RNDOM(1,1,80,25);
      C=0;
      REPEAT
        C=C+1;
        WRITE(1) 'Umbral de frecuencia = ',UMBF:10:4;
        WRITE(1) 'Nuevo umbral de frecuencia :';
        WRITE(1) 'REPETICION(_____)';
        WRITE(1) 'Muestra de inicio del segmento';
        WRITE(1) 'Muestra de fin del segmento';
        WRITE(1) 'Coeficientes del segmento';
        UNTIL (UMBF > 0);
      REPEAT
        ENDD=6;
'7': BEGIN
      RNDOM(1,1,80,25);
      C=0;
      REPEAT
        C=C+1;
        WRITE(1) 'Traslape = ',TRASL;
        WRITE(1) 'Nuevo traslape (maximo ',LV-1,')';
        WRITE(1) 'REPETICION(_____)';
        WRITE(1) 'Muestra de inicio del segmento';
        WRITE(1) 'Muestra de fin del segmento';
        WRITE(1) 'Coeficientes del segmento';
        UNTIL (TRASL > 0);
      REPEAT
        ENDD=7;

```

```

COTON(28,17);
UNTIL (TRAS<LV) AND (TRASL>0);
END
(*END7*);

'B': BEGIN
  N(1,1,80,25);
  C(1,1,10,1);
  WRITE('Iteraciones = ',0);
  WRITE('Iteraciones (maximo ',LV,')');
  REPEAT
    COTON(28,20);
    READ(A,Q);
  UNTIL ((Q>1) AND (Q<LV));
  END
(*END8*);

'B': BEGIN
  ASSIGN(ARCH1,CORR);
  REWRITE(ARCH2);
  ASSIGN(ARCH1,SEMA);
  REWRITE(ARCH1);
  MAXI:=0;
  (* LEE NUMERO DE MUESTRAS *)
  I:=1;
  WHILE ((NOT EOF(ARCH1)) AND (I<MAXARCH)) DO
    BEGIN
      READ(ARCH1,X[I]);
      I:=I+1;
    END
  (* FIN *)
  N(1,1,80,25);
  C(1,1,10,5);
  COTON(1,2);
  TOTRUE:=2;
  WRITE('TOTRUE, Muestras leidas');
  NO := 0;
  (* SE ESCRIBE FORMATO EN EL ARCHIVO DE CORRELACIONES *)
  REWRITE(ARCH2,FORMAT);
  WHILE (NO < (TOTRUE-(2*LV))) DO
    BEGIN
      (* SE DETERMINA LA VENTANA DE REFERENCIA *)
      FOR L=1 TO LV DO
        BEGIN
          I:=X[L*NO];
          END
        (*ENDFOR*);
      (* CALCULA LA AUTOCORRELACION DEL PRIMER BLOQUE *)
      FAC(V,LFAC,LV,RA);
      (* ESCRIBE EN EL ARCHIVO DE CORRELACIONES *)
      WRITE(ARCH2,NO);
      FOR L=1 TO LFAC DO
        WRITE(ARCH2,RR[L]);
      (*ENDFOR*);
      CAMBIO:=FALSE;
      NO:=NO+LV-TRASL;
      (* REPITE EL PROCEDIMIENTO HASTA EL TOTAL DE MUESTRAS *)
      WHILE ((NO < (TOTRUE-LV)) AND (NOT CAMBIO)) DO
        BEGIN
          FOR L=1 TO LV DO
            BEGIN
              I:=X[L*NO];
              END
            (*ENDFOR*);
            FAC(V,LFAC,LV,RP);
            (* DISTANCIA DE ENERGIA *)
            IF RR[1] < RR[11] THEN
              MIN := RR[1];
            ELSE
              MIN := RR[11];
            (*ENDIF*);
            IF MIN <= 0.0 THEN
              ADIF := 0.00000001;
            ELSE
              ADIF := ABS(SORT(RR[1]) - SORT(RR[11])) / SORT(MIN);
            (* DISTANCIA ESPECTRAL *)
            B := 0.0;
            E := 0.0;
            C21 := FALSE;
            C22 := FALSE;
            WHILE (NOT(C21) AND NOT(C22) AND (K<LFAC)) DO
              BEGIN
                IF RR[1] < 0 THEN C21 := TRUE;
                IF NOT C22 THEN C22 := TRUE;
                IF NOT C21 THEN
                  RR:=RR[K]/RR[1]
                ELSE

```













```

COTRKY(10,8);
PRINT('0: relaciones del error r(0),...,r('FACE-1,') ');
PRINT('0: Nuevo numero de correlaciones ');
COTRKY(10,32);
PRINT('0: error r(0),...,r(N-1), (2 * M = 'MAXORD,') = ');
REPEAT
  READ(FACE);
  READ(N);
  UNTIL (FACE > 1) AND (FACE <= MAXORD);
  END
  (*END6*);

'6': BEGIN
  WINDOW(1,1,80,25);
  COTRKY(10,3);
  PRINT('0: Nivel de segmentacion = 'UMBS:10:4);
  PRINT('0: Nuevo umbral de segmentacion ');
  REPEAT
    COTRKY(42,15);
    READ(UMBS);
  UNTIL (UMBS > 0);
  END
  (*END6*);

'7': BEGIN
  WINDOW(1,1,80,25);
  COTRKY(10,18);
  PRINT('0: Elemento de barrido = 'TRASL);
  PRINT('0: Nuevo barrido (maximo 'LV-1,') ');
  REPEAT
    COTRKY(28,17);
    READ(TRASL);
  UNTIL (TRASL < LV) AND (TRASL > 0);
  END
  (*END7*);

'8': BEGIN
  READ(ARCH2,ARMA);
  READ(ARCH2,AR);
  ASSIGN(ARCH1,SEMAL);
  READ(ARCH1,SEM);
  READ(MAX);
  (* LEE NUMERO DE MUESTRAS *)
  I:=1;
  WHILE ((NOT EOF(ARCH1)) AND (I<MAXARCH)) DO
    BEGIN
      READ(ARCH1,X(I));
      I:=I+1;
    END
    (* END LOOP *)
    WINDOW(1,1,80,25);
    CLEAR;
    COTRKY(1,1);
    WRITE('0: ');
    WRITE('0: Muestras leidas');
    NO := LV;
    (* SE ESCRIBE FORMATO EN EL ARCHIVO DE CORRELACIONES *)
    WRITE(ARCH2,FORM);
    WRITE(ARCH2,OROP);
  REPEAT
    BEGIN
      (* SE DETERMINA LA VENTANA DE REFERENCIA *)
      FOR I:=1 TO LV DO
        BEGIN
          J:=X(I+NO);
          END
          (*ENDFOR*);
        (* CALCULA LOS PARAMETROS AR DEL BLOQUE DE REFERENCIA *)
        AC(L,OROP,LV,AR);
        LFC(AR,AA,OROP);
        (* ESCRIBE EN EL ARCHIVO DE PARAMETROS AR *)
        WRITE(ARCH2,NO);
        FOR I:=1 TO OROP DO
          WRITE(ARCH2,AA(I));
        (*ENDFOR*);
        (* CALCULO DEL FILTRO *)
        FOR I:=1 TO LV DO
          BEGIN
            FOR J:=0 TO OROP DO
              IF (NO-LL) > 0 THEN
                E[L+NO]:=E[L+NO]+AA[LL]*X[L+NO-LL];
              ELSE
                E[L+NO]:=E[L+NO];
            (*ENDFOR*);
          END
        END
      END
    END
  END
  (*END8*);

```

```

(*ENDFOR*);
(* CALCULO DE LA FAC DEL ERROR *)
FOR I=1 TO LV DO
  BEGIN
    E(I) := E(L+NO);
  (*ENDFOR*);
  FAC := CERR(LV,RR);
  RES := RAJOL;
  RESB := FALSE;
  BEGIN
    NO := NO + TRASL;
    FOR LI=(LV-TRASL) TO LV DO
      BEGIN
        NO:=0;
        FOR I=0 TO ORDP DO
          IF I=NO AND LI=0 THEN
            E(LI+NO):=E(L+NO)+AA[LI]*X(L+NO-LL)
          ELSE
            E(LI+NO):=E(L+NO)
          (*ENDFOR*);
        (*ENDFOR*);
      BEGIN
        (*ENDFOR*);
        FOR I=1 TO LV DO
          E(I) := E(L+NO);
        (*ENDFOR*);
        FACV,FACE,LV,RR);
        (* CALCULO DE LA MEDIDA DE ERROR ESPECTRAL *)
        MES := RESB/RR(0) - 1;
        FOR I=1 TO FACE DO
          BEGIN
            RR(I)/RR(0);
            AUX1 := AUX1+AUXI;
            MES := MES + 2*AUXI;
          (*ENDFOR*);
          WINDOW(21,3,62,10);
          PRINT('-----');
          PRINT(' Ventana (' ,NO,' - ',NO+LV,')');
          PRINT(' Medida de Error eSpectral = ',MES:10:8);
          PRINT('-----');
          IF MES > MESMAX THEN MESMAX:=MES;
          * UNBS THEN
            BEGIN
              NO:=NO+TRUNC(LV/2);
              WINDOW(21,10,62,18);
              PRINT('-----');
              PRINT(' Cambio en ',NO);
              PRINT('-----');
              PRINT(' DO 28);
              GOTO 21;
            TELN 'Pulse cualquier tecla para continuar>';
            TELA:=READKEY;
          END;
        UNTIL ((CAMBIO) OR ((NO+TRASL+LV)>(TOTRUE)));
        NO+TRASL+LV)>(TOTRUE);
        PRINT(' DO 28);
        WINDOW(21,18,62,22);
        PRINT('-----');
        PRINT(' Fin del analisis');
        PRINT(' MES maxima = ',MESMAX:10:4);
        PRINT('-----');
        PRINT(' DO 28);
        TELN 'Pulse cualquier tecla para terminar>';
        TELA:=READKEY;
      END;
    (*ENDIF*);
  (*NOELSE*);
  END;
(*ENDCASE*);
UNTIL (OPCION='0');
CONF.:=SINAL;
CONF.:=ORA;
CONF.:=LV;

```



```

MEMORIA : VENTANA;      { * MEMORIA QUE GUARDA LAS ENERGÍAS PASADAS }
NOPEPA : CHAR;         { * OPCION DEL MENU PRINCIPAL }
Opcion, : CHAR;        { * CONTINUAR DESPUES DE LEER MENSAJES }
DELA,   : STRING;      { * NOMBRE DEL ARCHIVO DE CONFIGURACION }
SENA,   : FILE OF REAL; (* ARCHIVO DE ENTRADA (SENA A SEGMENTAR) *)
ARCHI,  : FILE OF REAL; (* ARCHIVO DE CONFIGURACION *)
CONFIG : TEXT;         { * BELAJ AUXILIAR PARA MEDIR TIEMPOS }
HORA,   : REAL;        { * BELAJ AUXILIAR PARA MEDIR TIEMPOS }
NOTO,   : REAL;        { * BELAJ AUXILIAR PARA MEDIR TIEMPOS }
SERVIND : WORD;        { * BELAJ AUXILIAR PARA MEDIR TIEMPOS }
CENTSRA: WORD;        { * BELAJ AUXILIAR PARA MEDIR TIEMPOS }
DELTAD, : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
YTL,    : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
DRAAX,  : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
NA,     : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
NS,     : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
URBS,   : REAL;        { * MEDIDA PARA OPTIMIZAR POSICION DE FRONTERAS }
T,      : REAL;        { * TIEMPO DE INICIO DE SEGMENTACION }
CRP,    : REAL;        { * INDICE DE RESERVA }
LA,     : REAL;        { * TIEMPO DE INICIO DE SEGMENTACION }
ORDP,   : INTEGER;     { * ORDEN DE RESEGUIMIENTO DESDE EL ULTIMO CAMBIO }
E1,     : REAL;        { * ORDEN DE RESEGUIMIENTO DESDE EL ULTIMO CAMBIO }
L,      : REAL;        { * ORDEN DE RESEGUIMIENTO DESDE EL ULTIMO CAMBIO }
SUCE,   : INTEGER;     { * ORDEN DE RESEGUIMIENTO DESDE EL ULTIMO CAMBIO }
EXISTE : BOOLEAN;      { * BANDERA DE ERROR EN LECTURA/ESCRITURA }
CAMBIO : BOOLEAN;      { * BANDERA DE DETECCIÓN DE CAMBIO }

```

```

{ * PARA MANEJAR POSIBLES SINGULARIDADES SE DEFINE 1/X=0 PARA X MUY PEQUEÑA }

```

```

FUNCTION DIVIDE(A,B:REAL): REAL;

```

```

BEGIN
  IF ABS(B) < CHIQUITO THEN
    DIVIDE:=0
  ELSE
    DIVIDE:=A/B;
  END;

```

```

{ * CALCULA EL MINIMO DE DOS NUMEROS }
FUNCTION MINIMO(A,B:INTEGER): INTEGER;

```

```

BEGIN
  IF A < B THEN
    MINIMO:=A;
  ELSE
    MINIMO:=B;
  END;

```

```

{ * ALGORITMO DE MEMORIA DESLIZANTE }
PROCEDURE DESLIZA(ORDP:INTEGER; VAR ZS:MATRIZ; YT,YTL:REAL);

```

```

  ORDP = ORDEN
  ZS = VECTOR DE ESTADO EN T-1
  YT = SENAL EN T
  YTL = SENAL EN T - LV

```

```

VAR
  N : INTEGER; (* CONTADOR DE ORDEN *)
  E : REAL; (* E (n,t) *)
  ZA : MATRIZ; (* VECTOR DE ESTADO EN T *)

```

```

BEGIN
  ZA[0,0] := YT;
  ZA[0,1] := YTL;
  ZA[1,0] := YT;
  ZA[1,1] := YTL;

```











