

UNA NUEVA SOLUCION EN DETECCION ADAPTIVA DE SEÑALES (*)

Darío Maravall Gómez-Allende

*Laboratorio de Ordenadores, Cibernética y Teoría de Sistemas
ETSI de Telecomunicación. UPM*

Only one solution for binary signals detection under unknown and/or variable stochastic channels has so far been obtained [1] and [2].

In this paper, the above detector is modelled by the first time as a finite deterministic automaton operating in a random environment in order to obtain a new, more powerful type of detector based on probabilistic automata.

Through computer simulations, a discrete-time probabilistic detector governed by means of a learning algorithm due to the author is compared with the classic deterministic detector for several stochastic channels. The experimental results show that the probabilistic detector is clearly superior to the deterministic one.

1. Introducción

El problema planteado es la obtención de una tasa mínima de errores (falsas detecciones) que se producen en un sistema de transmisión de pulsos digitales a través de un canal aleatorio variable en el tiempo y/o desconocido «a priori» por el diseñador.

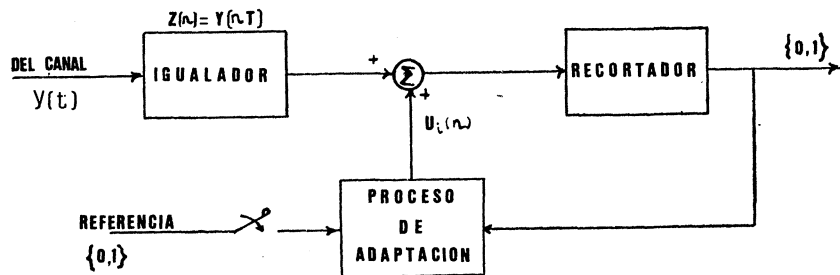
Nos centramos tan sólo en la parte final del receptor, es decir, la que convierte las muestras de la señal analógica transmitida en una secuencia binaria que se pretende sea coincidente con la secuencia de pulsos binarios del emisor.

Hasta donde sabemos, sólo se ha propuesto una solución a la detección óptima cuando las propiedades estadísticas del canal son desconocidas y/o variables en el tiempo [1] y [2]. En este trabajo se modela esta solución como un autómata finito determinístico en un medio aleatorio, a fin de proponer una nueva solución más potente.

(*) Presentada en la sesión celebrada el 13 de febrero de 1980.

2. Proceso de aprendizaje por umbral

La citada solución, debida a Sklansky, responde al diagrama de bloques:



La idea es muy sencilla. Si se envía un «0» («1») y se detecta un «0» («1»), se mantiene el valor de la tensión de umbral aplicada al recortador. Por el contrario, si se envía un «0» y es detectado un «1» (falsa alarma), se aplica el umbral inmediatamente superior. Análogamente, al detectarse un «0» tras el envío de un «1» (falsa pérdida), la acción es bajar al umbral inmediatamente inferior. Para realizar este proceso adaptivo se requiere conocer la secuencia binaria transmitida: interruptor cerrado (fase de aprendizaje). Una vez obtenido el umbral óptimo se pasaría a la fase normal de funcionamiento, es decir, sin secuencia de referencia.

Sklansky estudió este procedimiento adaptivo de detección como una cadena de Markov. Nosotros lo hemos modelado [3] como un autómata finito determinístico en un medio aleatorio. Pasamos a describir brevemente esta formalización del proceso de aprendizaje por umbral: PAU).

Definimos el PAU como la quintupla $\langle E, \emptyset, S, g, f \rangle$, donde $E = \{a, b, c\}$ es el conjunto de señales de entrada del autómata. La señal «a» se genera cuando se produce una detección correcta. La señal «b» indica falsa pérdida y la «c» corresponde a una falsa alarma.

$$\emptyset \equiv S \equiv \{u_1, u_2, \dots, u_k\},$$

conjunto de estados internos del autómata (\emptyset) y de señales de sali-

da (S). Son equivalentes y están formados por los k posibles valores de tensión de umbral.

$g \equiv f$ son las funciones de transición de estados (g) y de salida (f). Puesto que \emptyset y S son equivalentes, también lo son ellas. Si se supone que los umbrales están ordenados de forma que sus tensiones sean:

$$u_1 < u_2 < \dots < u_k,$$

g y f vienen dadas por:

$\emptyset \equiv S$	E			
		a	b	c
u_1		u_1	u_1	u_2
u_2		u_2	u_1	u_3
\vdots		\vdots	\vdots	\vdots
u_k		u_k	u_{k-1}	u_k

En cuanto al medio aleatorio representa la acción (desconocida y/o variable) del canal y se caracteriza por dos tipos de probabilidades de «castigo»:

$$p_1, p_2, \dots, p_k \quad \text{y} \quad q_1, q_2, \dots, q_k,$$

que dan las probabilidades de falsa pérdida y de falsa alarma respectivamente y para cada uno de los umbrales u_1, u_2, \dots, u_k del receptor.

El objetivo de este autómata es elegir el estado (umbral) cuya suma de probabilidades de castigo asociadas sea mínima. Naturalmente, estas probabilidades son desconocidas por el diseñador y pueden variar.

3. Proceso probabilístico de aprendizaje

Basándonos en un conocido resultado de la teoría de autómatas, según el cual un autómata determinístico en medio aleatorio necesita un número infinito de estados para lograr un aprendizaje (elección del estado menos castigado) comparable al de un autómata estocástico finito, hemos propuesto un detector de naturaleza probabilística [3] que describimos rápidamente.

El proceso probabilístico de detección umbral es la quintupla

$$\langle E, S, \emptyset, \mathbf{P}(n), A \rangle,$$

donde E , S y \emptyset coinciden con los definidos para el caso determinístico.

$$\mathbf{P}(n) = \| p_1(n), p_2(n), \dots, p_k(n) \|$$

es una distribución de probabilidades definida sobre el conjunto de valores de umbral, para cada instante n de muestreo y toma de decisión del detector.

A es un algoritmo de aprendizaje que calcula la nueva distribución de probabilidades $\mathbf{P}(n+1)$, con el objetivo de obtener una probabilidad máxima para el estado (umbral) de castigo mínimo. El algoritmo escogido en el estudio comparativo que pasamos a describir es el algoritmo de aprendizaje incremental que propusimos previamente en [3].

4. Resultados de simulaciones comparativas en ordenador

Por último, hemos comparado el rendimiento: tasa de falsas detecciones (cociente entre el número de falsas detecciones y número total de detecciones realizadas) de los dos detectores para 15 diferentes canales aleatorios. Como es habitual en las simulaciones de autómatas de aprendizaje hemos considerado dos estados, es decir, dos umbrales.

Las simulaciones se han llevado a cabo para secuencias de 5.000 bits, o lo que es equivalente, la duración de la etapa de aprendizaje de cada autómata (detector) constaba de 5.000 ensayos.

Los canales simulados se caracterizan por presentar un umbral óptimo destacado y para todos ellos el comportamiento del detector probabilístico ha sido superior. Por la cantidad tan elevada de medios simulados es imposible presentar todas las curvas de aprendizaje (tasa de errores versus número de ensayos) en este trabajo. Nos limitamos a recoger las dos curvas «extremas», esto es, en las que la diferencia de la tasa de errores de ambos detectores al final de la secuencia de 5.000 bits es mínima y máxima.

En abscisas se representan los sucesivos ensayos (detecciones) y en ordenadas la tasa de falsas detecciones, $f(n)$, de cada detector.

En ambas figuras la curva de aprendizaje con mayor tasa de error corresponde al detector determinístico (línea discontinua). También se puede apreciar que sobre el eje de abscisas se ha marcado la respuesta plana de un detector ideal.




Fig. 1.




Fig. 2.

Estos resultados y los temas abiertos a continuar, en especial la realización mediante circuitería electrónica de autómatas de aprendizaje, forman parte de un amplio esfuerzo bajo la dirección del profesor García Santesmases tendente a obtener aplicaciones de estos autómatas en Ingeniería Cibernética.

Bibliografía

- [1] GLORIOSO, R. M. 1975. *Engineering Cybernetics*. Prentice-Hall, N. J.
- [2] SKLANSKY, J. 1973. *Pattern Recognition*. Dowden, Hutchinson & Ross, Inc. Stroudsburg, Pensylv.
- [3] MARAVALL GÓMEZ-ALLENDE, D. 1979. *New solutions in adaptive signal detection*. Primer Premio del IEEE Region 8 P. S. P. C., EUROCON 80, Stuttgart.