

DISEÑO DE UN SISTEMA DE RECONOCIMIENTO ESTADÍSTICO
PARA EL DIAGNÓSTICO AUTOMÁTICO EN OTONEUROLOGÍA

M. CHACÓN¹

M. VILLANUEVA²

G. TELLEZ³

RESUMEN -- Se presenta un estudio de Audiogramas para el diagnóstico automático, realizando una extracción de características y discriminando entre tres patologías, y el caso normal. Las mediciones de pérdida de audición de un órgano auditivo se ordenan en un vector, las cuales se ingresan al sistema de reconocimiento que se diseñó mediante técnicas de Análisis Multivariado de Datos. Para disminuir la gran cantidad de datos obtenidos conservando la información más relevante, se extrajeron las características esenciales mediante un Análisis en Componentes Principales. Para implementar el sistema de reconocimiento se aplicaron dos técnicas alternativas de clasificación: Método de Bayes para Patrones Normales y Vecino Más Cercano. El sistema desarrollado fue probado con algunos audiogramas suplementarios que tenían diagnóstico previo. Los resultados obtenidos reflejan que el método de Bayes presenta una mejor clasificación y además entrega información adicional que permite una evaluación más precisa.

1. INTRODUCCION

El Diagnóstico Automático ha cobrado una gran importancia en los últimos años con el desarrollo de los equipos computacionales, lo que ha permitido implementar diversas técnicas de Reconocimiento de Patrones.

Muchos exámenes médicos entregan como resultado índices o señales biológicas, los cuales sólo pueden ser interpretados por especialistas, quienes determinan la patología que sufre el paciente. La misma información, se puede representar por un vector en un espacio multidimensional e ingresarlo a un sistema de reconocimiento de patrones.

En los trabajos de Evans (1981, 1983) y Chacón (1986) se aplicaron diferentes técnicas de Reconocimiento de Patrones al diagnóstico de enfermedades vasculares; en ese caso, los datos de entrada son obtenidos a partir de señales Doppler ultrasónico. En este trabajo, los datos se obtuvieron mediante el examen audiométrico, que es un elemento fundamental en el Diagnóstico en Otoneurología. Dada la simplicidad de estas mediciones, se tiene una ventaja adicional para su ingreso a un sistema automático de reconocimiento.

(1) Dpto. Ing. Eléctrica, Universidad de la Frontera - Casilla 54-D, Temuco, Chile - Actualmente en Ing. Biomédica, COPPE/UFRJ.

(2) Dpto. Matemática y Estadística, Universidad de la Frontera - Casilla 54 -D, Temuco, Chile - Actualmente en Ing. Sistemas y Computación, COPPE/UFRJ.

(3) Dpto. Ing. Eléctrica, Universidad de Santiago de Chile - Casilla 10233, Santiago, Chile.

2. EXAMEN AUDIOMÉTRICO

El exámen más frecuente en Otoneurología es el denominado Audiograma (Selkurt, 1962) que consiste en construir una gráfica de pérdida de audición - medida en decibeles - en función de la frecuencia, medida en octavas. Dicho examen se divide en dos etapas: en la primera se realizan las mediciones por vía aérea, es decir, se estimula acústicamente el tímpano del paciente, a diferentes frecuencias, obteniendo por consulta directa, el umbral de audición para ocho valores de frecuencia comprendidos entre 250 Hz y 8 KHZ; la curva que une estos puntos se denomina audiometría tonal. En la segunda etapa, se obtiene el trazado audiométrico por vía ósea; ésto se realiza aplicando vibraciones mecánicas directamente sobre la base de la hipófisis mastoide (Uttal, 1979), el umbral de audición se determina de igual forma que en el caso anterior, examinándose ahora seis frecuencias cuyo rango se extiende desde los 250 Hz a 4 KHz. Cada una de estas mediciones se realiza independientemente en cada oído del paciente y, los trazados son inscritos en un mismo gráfico.

3. PLANTEAMIENTO DEL PROBLEMA

En un registro audiométrico se inscribe la representación de los dos órganos auditivos, los cuales no necesariamente padecen la misma patología. Aquí se consideró como objeto estadístico de interés un órgano auditivo de un paciente, el cual queda representado por un vector de catorce componentes donde las ocho primeras corresponden a la audiometría tonal y las seis restantes a la audiometría obtenida por vía ósea.

Para el trabajo que se presenta se consideraron tres patologías y el caso normal, cuyas características se describen a continuación.

3.1 Caso normal: este audiograma se caracteriza por el alto nivel de audición, que se refleja en la elevada posición de las curvas tonal y ósea, y por no presentar cambios abruptos.

3.2 Presbiacusia: la principal característica de este audiograma es que las curvas tonal y ósea se entrelazan y descienden paulatinamente con la frecuencia. Esta declinación está asociada a una pérdida sensitivo-neuronal de la audición, la cual se produce habitualmente por el envejecimiento del órgano auditivo.

3.3 Trauma acústico: esta patología se reconoce por la abrupta caída de los dos trazados audiométricos (aéreo y óseo), para determinadas frecuencias. La causa más frecuente es la exposición continua al ruido, en gamas específicas de frecuencias.

3.4 Otitis media crónica: en este caso, en el audiograma se observa una clara separación entre la curva obtenida por vía ósea y aquella obtenida por vía aérea, que se ubica en la zona inferior del audiograma.

Para cada una de las patologías consideradas y para el caso normal, se tomó una muestra de cinco objetos que tenían un diagnóstico previo efectuado por un especialista. Estos datos se ordenaron en una matriz de veinte por catorce, con la cual se diseñó el sistema de reconocimiento.

4. MÉTODO DE SOLUCIÓN

Con el objetivo de reducir la dimensión del espacio de trabajo, se realizó un Análisis en Componentes Principales (Lebart, 1979) que permite seleccionar las características esenciales de los objetos.

Utilizando la representación en el espacio de las componentes principales se desarrollaron dos métodos alternativos de clasificación (Diday, 1982), (Fukunaga, 1972), (Tou, 1974); Vecino Más Cercano, que hace una exploración de la distribución geométrica de los puntos asociados a los patrones, y Clasificación Bayesiana que introduce conceptos probabilísticos.

Finalmente, el sistema automático de reconocimiento fue contrastado con el diagnóstico dado por el especialista para algunos audiogramas.

4.1 - Método del Vecino Más Cercano

Aprovechando la representación geométrica de cada órgano auditivo, como un punto en el espacio de las componentes principales, se puede evaluar su similitud mediante la proximidad entre los puntos, midiendo su distancia.

Para clasificar un nuevo vector se examina la distancia de éste a cada uno de los puntos conocidos y, se asigna a la clase del objeto con el cual su distancia es mínima, que se denomina vecino más cercano.

Como los vectores están en el espacio de las componentes principales y éstas tienen distinto poder de discriminación, la distancia se modificó ponderando cada componente de la distancia por la tasa de inercia correspondiente.

Con esto, dadas las clases C_1, C_2, C_3 y C_4 , los vectores $\vec{w}_1, \dots, \vec{w}_{20}$ que representan a los individuos en el espacio de las q primeras componentes principales, y considerando la distancia euclidiana ponderada por las tasas de inercia $\lambda_1, \dots, \lambda_q$; \vec{x} se asigna a la clase C_k a la cual pertenece el individuo representado por \vec{w}_t , $1 \leq t \leq 20$, siendo \vec{w}_t el más cercano a \vec{x} . Esto se traduce en la ecuación (1).

$$\sum_{j=1}^q \lambda_j (x_j - w_{tj})^2 = \min_{1 \leq i \leq 20} \sum_{j=1}^q \lambda_j (x_j - w_{ij})^2 \quad (1)$$

Denotando Λ la matriz diagonal cuyos elementos son las tasas de inercia de las componentes principales, minimizar la distancia es equivalente a maximizar

$$D_i(\vec{x}) = 2 \vec{w}_i' \Lambda \vec{x} - \vec{w}_i' \Lambda \vec{w}_i \quad (2)$$

donde \vec{w}_i es el vector traspuesto de \vec{w}_i .

$D_i(\vec{x})$ corresponde a una función de decisión lineal por tramos.

4.2 - Clasificación Bayesiana para Patrones Normales

Dadas las clases de individuos C_1, C_2, C_3 y C_4 con probabilidades $p(C_1); p(C_2), p(C_3)$ y $p(C_4)$ respectivamente, el problema es: dado un vector \vec{x} determinar a qué clase pertenece, considerando que \vec{x} tiene distribución normal multivariada en cada clase.

Denotando $p(C_i/\vec{x})$ la probabilidad de asignar \vec{x} a C_i , L_{ij} el costo de asignar \vec{x} a C_i siendo que en realidad \vec{x} pertenece a C_j , se tiene que el costo promedio de esta decisión es

$$r_j(\vec{x}) = \sum_{i=1}^4 L_{ij} p(C_i/\vec{x}) \quad (3)$$

El clasificador bayesiano escoge la clase con menor riesgo.

En general se considera la función de costo que asigna uno al equivocarse y cero si la decisión es correcta.

Definiendo

$$\ell_j(\vec{x}) = \ln\{p(\vec{x}/C_j) p(C_j)\} \quad (4)$$

\vec{x} se asigna a la clase C_j que maximice $\ell_j(\vec{x})$.

Considerando la fórmula de Bayes y la densidad de la normal multivariada se obtiene

$$\ell_j(\vec{x}) = \frac{q}{2} \ln(2\pi) + \ln\{p(C_j)\} - \frac{1}{2} \ln(\det(V_j)) - \frac{1}{2} (\vec{x} - \vec{m}_j)^t V_j^{-1} (\vec{x} - \vec{m}_j) \quad (5)$$

donde \vec{m}_j : vector de medias en la clase C_j

V_j : matriz de varianzas-covarianzas en la clase C_j

q : número de componentes principales utilizadas

En este caso la función de decisión $\ell_j(\vec{x})$ resulta ser una función cuadrática.

Con este método, es posible evaluar la clasificación realizada, comparando los valores de las probabilidades a posteriori $p(C_j/\vec{x})$, ya que la clase elegida tiene la mayor de estas probabilidades.

5. DISCUSIÓN DE RESULTADOS

Del Análisis en Componentes Principales se obtiene que la importancia de las componentes es 65.8%, 15.8%, 10.2%, 3.3% respectivamente para las cuatro primeras. Como de la cuarta componente en adelante la contribución a la explicación de la varianza es baja, se utilizó una representación en las tres primeras componentes que acumulan 91.7% de inercia.

Con el propósito de tener una visión más clara se graficó en el plano principal (que tiene una tasa de inercia de 81.5%), la representación de los órganos auditivos con diagnóstico previo utilizados para el diseño del sistema de reconocimiento. Este gráfico se muestra en la figura 1.

En la figura 2 se muestra la clasificación obtenida, utilizando el Método del Vecino Más Cercano, para los individuos suplementarios. Se consideraron dos en cada clase y su proyección en el plano principal está representada por el número de la clase a la cual pertenece.

Las regiones fueron trazadas a partir de la distribución de los objetos de diseño en el plano principal y, considerando que la función de decisión es lineal por tramos, de acuerdo a la ecuación (2).

Se aprecia que el grupo normal y el grupo con Otitis Media Crónica quedan bien separados entre sí y de los otros dos grupos. Estos últimos, Presbiacusia y Trauma Acústico, se confunden porque ambos tienen pérdida aérea y ósea en frecuencias medias y altas.

También se observa que todos los individuos suplementarios quedan bien clasificados.

En cada clase los patrones presentan un comportamiento de acuerdo a una normal multivariada, lo que se comprobó mediante la d^ocima chi-cuadrado de bondad de ajuste con un nivel de significación variando entre 5 y 10%. Por este hecho, se utilizó el Método de Clasificación de Bayes para Patrones Normales. Se consideraron todas las clases con igual probabilidad a priori.

En la figura 3 se entrega en forma aproximada las regiones correspondientes a la clasificación Bayesiana.

Considerando que, en este caso, la función de decisión es cuadrática, las regiones quedan limitadas por alguna función cónica. Para ubicar las fronteras de las clases, se evaluaron las probabilidades a posteriori de los objetos de diseño.

Se observa que todos los objetos de prueba quedan bien clasificados, con probabilidades entre 0,95 y 0,99 de pertenecer a la clase asignada.

6. CONCLUSIONES

De los resultados obtenidos, se puede concluir que los métodos de clasificación son eficaces para un sistema de diagnóstico automático. Si bien al clasificar los objetos de prueba, ambos métodos lo hicieron correctamente en todos los casos, el método de Bayes presenta al facultativo, una considerable ventaja con respecto al método del vecino más cercano, ya que entrega la probabilidad de que pertenezca a cada una de las clases. Estas probabilidades al unirse a información clínica adicional, permiten una decisión más efectiva.

El software desarrollado tiene dos etapas. Primera: el diseño del sistema de reconocimiento que requiere un análisis en componentes principales de los sujetos de base, y de la d^ocima de bondad de ajuste sobre la normalidad en cada clase, esta etapa debe desarrollarse solo al realizar el diseño. La segunda etapa es de reconocimiento, que será ejecutada cada vez que se pretenda obtener un probable diagnóstico; para esto es necesaria la representación del paciente en las componentes principales, que equivale a una combinación lineal de éstas, y su posterior clasificación por el método elegido. En este trabajo, la implementación de los algoritmos se realizó en un IBM-PC en lenguaje C, utilizando una reducida cantidad de memoria y de tiempo de procesamiento.

Para la implementación práctica de un sistema de diagnóstico definitivo existen todavía algunas etapas a realizar: determinar las probabilidades a priori de cada clase de acuerdo a la proporción de éstas en la población, validar el sistema con muestras de mayor tamaño, considerar un mayor número de patologías y desarrollar una interfase con el usuario, utilizando - de preferencia - técnicas gráficas para el ingreso de los datos, para facilitar

el manejo por parte del especialista.

7. AGRADECIMIENTOS

Los autores agradecen al Departamento de Otoneurología del Hospital Regional de Temuco de Chile por la colaboración en la recolección de la información.

8. REFERENCIAS

- CHACÓN, M. - VILLANUEVA, M. & TÉLLEZ, G. (1986)
Reconocimiento Estadístico de Patrones Aplicado al Diagnóstico de Arterio-patías.
VII Congreso de la Asociación Chilena de Control Automático A.C.C.A.
- DIDAY, E. - LEMAIRE, J. - POUGET, J. & TESTU, F. (1982)
Eléments d'Analyse de Données, Ed. Dunod, France
- EVANS, D. - PRYTHORCH, D. - SMITH, M. & MACPHERSON, D. (1981)
On Line Clasification on Arterial Stenosis Using Pattern Recognition Techniques to Process Doppler Ultrasound Waveforms.
VII Congreso Brasileiro de Engenharia Biomédica.
- EVANS, D. - MACPHERSON, D. & BELL, P. (1983)
A Comparison of Three Methods of Analysis of Ultrasonic Doppler Waveforms Recorder from the Comon Femoral Artery of Patients with Vascular Disease
VIII Congreso Brasileiro de Engenharia Biomédica.
- FUKUNAGA, K. (1972)
Introduction to Statistical Pattern Recognition
Ed. Academic Press, New York
- LEBART, L. - MORINEAU, A. & FENELÓN, J. (1979)
Traitement des Données Statistiques. Ed. Dunod, France.
- SELKURT, E. & COL. (1962)
Fisiologia. Ed. Interamericana, México.
- TOU, J. & GONZÁLEZ, R. (1974)
Pattern Recognition Principles. Addison-Wesley
Publishing Company, U. S. A.
- UTTAL, W. (1979)
Sensory Coding (Selected Readings). Little Brown Company, Boston.

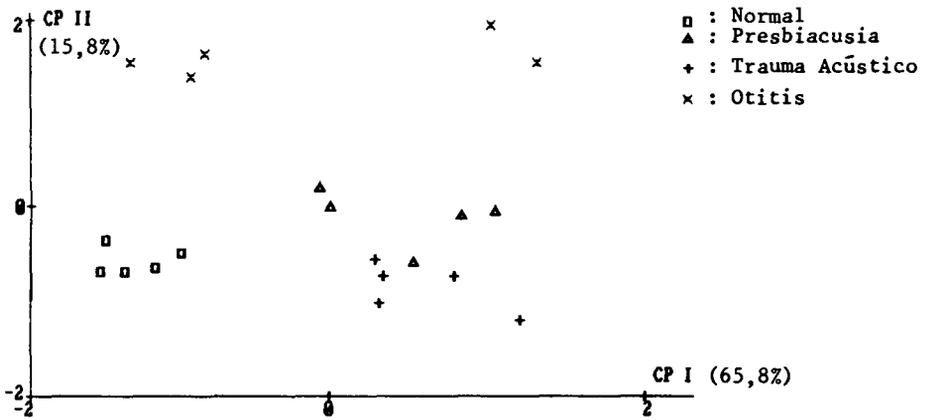


Fig. 1 - Objetos de diseño en las dos primeras componentes principales

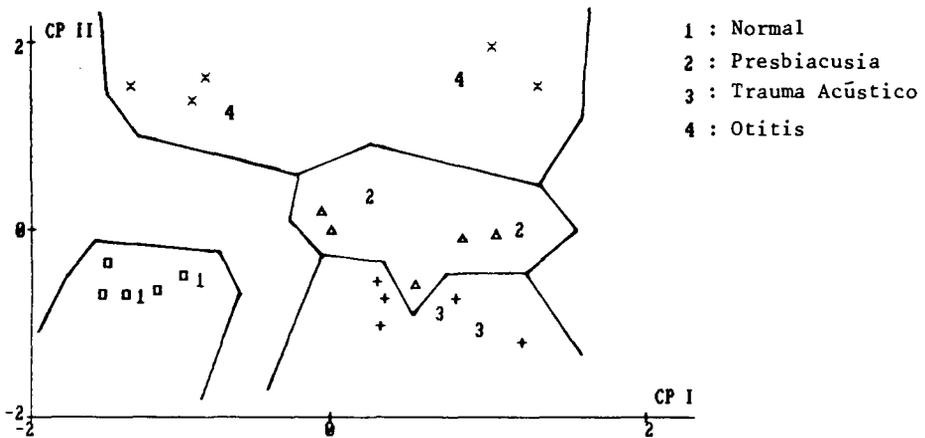


Fig. 2 - Clasificación por Vecino Más Cercano

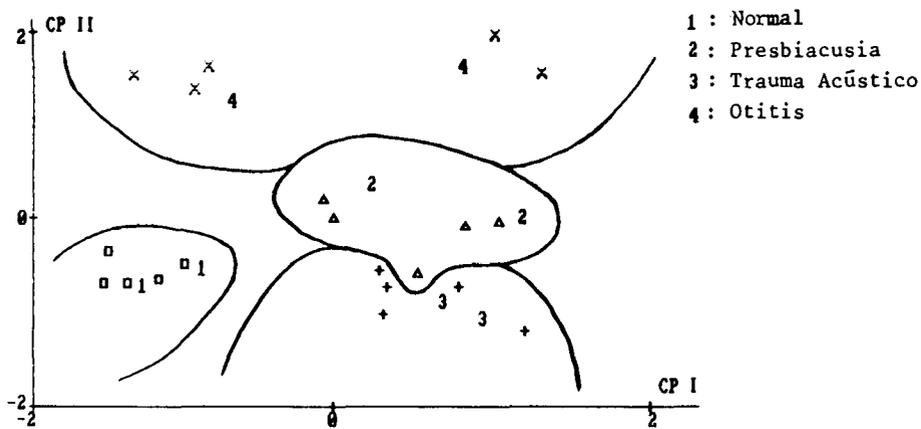


Fig. 3 - Clasificación Bayesiana

DESIGN OF A STATISTICAL RECOGNITION SYSTEM FOR
AUTOMATIC DIAGNOSTIC IN OTONEUROLOGY

ABSTRACT -- A system for automatic diagnostic in Otoneurology is presented. For this purpose, audiometries of a set of patients with their appropriate diagnostics were obtained. In this set three pathological groups and one normal group can be identified. The measurements of audition loss in each ear of a patient are represented as a m-dimensional vector. By means of these vectors the essential features are extracted, using the statistical technique of Principal Components. In this way, the patients are represented in a space with low dimensionality which conserves the most important characteristics of the original data. To discriminate between the different groups, two alternative techniques of classification have been developed: the Nearest Neighbor and Bayes Classification for Normal Patterns. With this, in the feature space, the regions where the groups lie are identified in such a way that if a new patient is mapped, one can easily determine the possible pathology that the patient suffers. In the present work, the techniques were performed to be used in a micro-computer. The output shows the feature space and indicates the pathological groups. The results suggest that Bayes Classification is better than the Nearest Neighbor because it also provides the probabilities for each group.