

Procedimiento automático de reducción de variables basado en ACP para el reconocimiento de formas con ultrasonido

Automatic Procedure for Variables Reduction Based on PCA Applied to Object Shapes Recognizing with Ultrasound

ANDRÉS DAVID RESTREPO GIRÓN

Ingeniero Electrónico y Magíster en Automática de la Universidad del Valle. En la actualidad se desempeña como profesor de tiempo completo en la Universidad Santiago de Cali, en donde está vinculado al Grupo de Instrumentación Electrónica (GIE). Sus áreas de interés son el diseño análogo y digital, la instrumentación inteligente y el procesamiento de señales acústicas.

adareg378@yahoo.com

andres.restrepo00@usc.edu.co

HUMBERTO LOAIZA CORREA

Ingeniero Electricista y Magíster en Automática de la Universidad del Valle. PhD. en Robótica y Visión Artificial de L'Université d'Evry, Francia. En la actualidad se desempeña como profesor titular de la Escuela de Ingeniería Eléctrica y Electrónica de la Universidad del Valle. Dentro del grupo de investigación en Percepción y Sistemas Inteligentes trabaja en las líneas de procesamiento de imágenes y señales, percepción inteligente y robótica móvil.

hloaiza@univalle.edu.co

EDUARDO FRANCISCO CAICEDO BRAVO

Ingeniero Electricista de la Universidad del Valle (1984). Magíster en Informática Industrial (1993) y Doctor Ingeniero en Informática Industrial (1995) de la Universidad Politécnica de Madrid. En la actualidad se desempeña como profesor titular en la Escuela de Ingeniería Eléctrica y Electrónica de la Universidad del Valle. Asimismo, está vinculado al grupo de investigación en Percepción y Sistemas Inteligentes, su trabajo se centra en el área de los microprocesadores y los sistemas inteligentes.

ecaicedo@univalle.edu.co

Clasificación del artículo: Investigación

Fecha de recepción: 11 de septiembre de 2006

Fecha de aceptación: 30 de abril de 2007

Palabras clave: reducción de variables, clasificación de patrones, análisis en componentes principales, pseudovisión ultrasónica, ACP.

Keywords: variables reduction, pattern classification, principal component analysis, ultrasonic pseudo-vision, PCA.

RESUMEN

En algunos casos de desarrollo de un sistema de clasificación de patrones, la elección de las características a partir de los datos capturados puede llevar a disponer de un conjunto bastante numeroso de variables; en tales circunstancias, es fundamental disponer de una técnica para definir las características muy ruidosas que aportan muy poca información o llevan información redundante, con el objetivo de eliminarlas y trabajar con un número total que reduzca el esfuerzo computacional. En este artículo se presentan los resultados preliminares de una metodología para eliminar sistemáticamente las variables muy correlacionadas mediante un algoritmo informático; ésta se basa en los resultados obtenidos del Análisis en Componentes Principales (ACP) [1] sobre un conjunto de datos estadísticos. La presentación se basa en un grupo de variables extraídas de las señales de eco ultrasónico captadas por un Sistema Ultrasónico de Reconocimiento de Formas (SURF) de objetos.

ABSTRACT

Sometimes, when a classification system is developed, the choice of characteristics from saved data can lead to a great number of variables. At these circumstances, the use of a tool like Principal Component Analysis (PCA) is required, so the noisy, meaningless or redundant variables can be determined and eliminated later. Then, it is possible to work with a less number of variables and reduce computational effort. This paper shows preliminary results about a method to eliminate those highly correlated variables through an algorithm, based on application of Principal Component Analysis (PCA) over a set of statistical data. The explanation is based on a set of characteristics from ultrasonic signals used in an Object Shape Recognizing System.

* * *

1. Introducción

En el sistema ultrasónico de reconocimiento previamente desarrollado [2] pueden llevarse a cabo cinco análisis diferentes de los ecos ultrasónicos, para así obtener un conjunto de características o variables por cada uno:

- Análisis en el tiempo: 24 características.
- Análisis de los coeficientes de la Transformada Discreta de Fourier [3]: 16 características.
- Análisis del espectro de Fourier tomado como un histograma: 16 características.
- Análisis de los coeficientes de la Transformada Discreta Wavelet [4]: 112 características.
- Análisis de las envolventes Wavelet tomadas como histogramas: 112 características.

Las características generadas en cada análisis corresponden a un número menor de mediciones que se repiten sobre cuatro señales de eco resultantes

de una exploración ultrasónica, la cual utiliza un montaje sensorial conformado por dos emisores y dos receptores [2] [5] [6]. Dadas las cualidades del sistema, puede darse el caso de disponer un conjunto de 152 variables en total; este número implica un aumento en el esfuerzo de cálculo y, probablemente, diferentes variables están diciendo prácticamente lo mismo. Para determinar la relevancia de las variables se eligió la técnica del ACP, como se revisa en el apartado 2. Posteriormente, en el apartado 3 se exponen los pasos del algoritmo de reducción automática de variables, cuyos resultados se resumen en el apartado 4; por último, en el quinto se muestran las conclusiones del trabajo.

2. Análisis en Componentes Principales (ACP)**2.1. Generalidades**

El ACP hace uso de la *Transformada de Karhunen-Loève* (TKL) que tiene por objetivo transformar un

espacio P de representación de datos, patrones o unidades estadísticas [1] de dimensión N_{CAR} (en el cual cada eje coordenado representa una variable o característica y cada dato resulta formado por un vector de N_{CAR} características y representado por un punto en el espacio P), a un nuevo espacio vectorial P' en el cual los datos presenten una varianza máxima (gráfica 1). Esta maximización se consigue mediante la transformación lineal de la ecuación (1) [7], en la cual X representa el conjunto de patrones originales (en forma matricial, cada dato o patrón corresponde a un vector columna, como en la gráfica 2), Y el conjunto de patrones transformados, y W la Matriz de Transformación:

$$Y = W^T X \quad (1)$$

La matriz de transformación W se obtiene considerando que para que los datos en el nuevo espacio P' exhiban máxima varianza debe realizarse una operación de maximización sobre la matriz de covarianza de los datos en Y (COV_Y).




Figura 1. Maximización de la varianza al pasar del espacio P al P' . Fuente [7]

Además de tener una varianza máxima, en la TKL existe una intención adicional: conseguir que todas las características transformadas estén *descorrelacionadas* entre sí, es decir, que no exista *redundancia* en la información; para ello, la matriz COV_Y debe ser *diagonal*. Con estos requerimientos se deduce [7] y que la matriz W debe cumplir con:

$$(COV_X - \lambda I) W = 0 \quad (2)$$

En (2), COV_X es la matriz de covarianza de los datos X (en el espacio P). A la vez, el vector λ debe satisfacer:

$$|COV_X - \lambda I| = 0 \quad (3)$$

Cada elemento λ_i sobre la diagonal de la matriz de covarianza de los datos en Y (matriz diagonal COV_Y) corresponde al valor de la varianza maximizada que exhiben los patrones con respecto a la variable transformada i . Estas varianzas están *ordenadas* numéricamente:

$$\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots \geq \lambda_d \quad (4)$$

La ecuación (4) significa que *la primera característica transformada porta la mayor cantidad de información* y que ésta va disminuyendo a medida que se avanza hacia variables de mayor orden. Por tanto, el ACP tiene dos objetivos principales [1]:

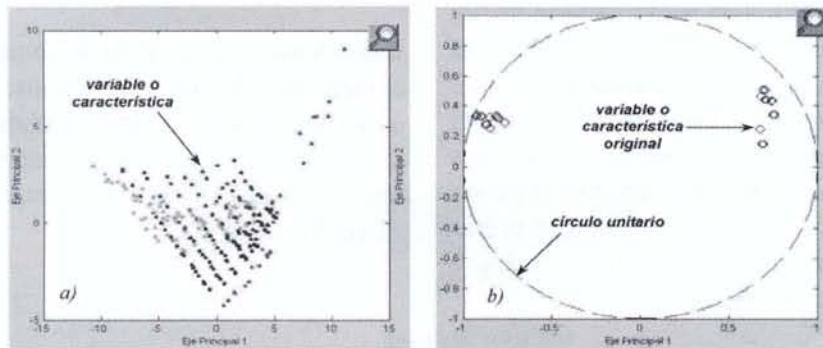
- Formar grupos homogéneos de patrones que eventualmente permitan hacer una clasificación de los datos.
- Analizar las correlaciones entre las variables originales en X para luego *reducir su conjunto* a aquellas que aporten la *información más relevante*, ya sea a partir de las variables transformadas [8] [9], o de las variables originales a través del *círculo de correlación* [2].

2.2 Nube de puntos y círculos de correlación

Cada patrón característico puede ser representado como un punto en el espacio P' , gracias a los valores de las características que han sido transformadas por la TKL y que actúan como coordenadas. La nube de puntos o *plano principal* (gráfica 2a) se forma cuando se dibujan todos estos puntos con respecto a dos ejes. Al igual que con los datos, a cada variable original también se le puede asignar un punto en el espacio P' cuyas coordenadas correspondan a los valores de correlación entre dicha variable y las variables transformadas; en consecuencia, a través de la cercanía entre una y otra se

puede visualizar el grado de correlación entre las características originales. Cuando involucra sólo dos ejes principales, el diagrama así generado se denomina *círculo de correlación* (gráfica 2b). Aunque

en algunos casos el ACP se restringe a los primeros dos ejes principales, se adoptó una estrategia que considerara más ejes.



Gráfica 2. a) Ejemplo real de una nube de puntos sobre el primer plano principal. b) Ejemplo real de un círculo de correlación

3. Metodología de reducción automática de variables

3.1 Aspectos generales de la reducción de variables

Cuando se trabaja con el grupo de variables transformadas o *principales* se estudian los λ_i y se partió de un porcentaje de información P_{info} que se desea conservar después del proceso de eliminación. La relación entre P_{info} y el número entero de variables N_C que se conservan está dado por la ecuación (5):

$$P_{info} \approx \frac{\sum_{k=1}^{N_C} \lambda_k}{\sum_{k=1}^{N_{CAR}} \lambda_k} \quad (5)$$

En este caso se quisieron reducir las variables originales x_i . Para esto inicialmente se define el número de planos principales requeridos para satisfacer P_{info} ; visto desde (5); esto equivale a reemplazar N_C por el parámetro *eje_{pmax}*, que indicará el número de ejes principales para tener en cuenta. La estrategia continúa definiendo parejas de variables fuertemente correlacionadas en el *primer plano principal*, para luego investigar qué ocurre con ellas en los demás

planos: sólo las parejas que permanezcan fuertemente correlacionadas en cada uno de los planos principales involucrados serán catalogadas como tal. Con el propósito de evitar un mayor esfuerzo computacional, los planos estudiados siempre serán consecutivos, es decir, construidos con los ejes principales k y $k+1$. En consecuencia, es probable que dos variables fuertemente correlacionadas bajo este criterio no lo sean en algún plano no consecutivo, aunque se puede demostrarse que tampoco estarán considerablemente descorrelacionadas.

3.2 Algoritmo de reducción de características

A continuación se enuncian los pasos del procedimiento propuesto. Para su ejecución se desarrollaron rutinas basadas en funciones propias del programa MATLAB.

- 1) Mediante la función *prestd()* de MATLAB se normaliza el conjunto de patrones originales, de tal modo que los valores adoptados por cada característica a través de todos los datos tengan una media de 0 y una varianza igual a 1. La notación X representará la matriz normalizada.
- 2) Transformación en componentes principales (TKL) sobre los patrones normalizados me-

dante la función *princomp()* de MATLAB [10]. Los resultados son la matriz de transformación W , las varianzas maximizadas λ_i y los datos transformados en forma de una matriz Y^T cuyas filas son los nuevos patrones.

- 3) Cálculo de la matriz de correlación entre las variables o características originales de los datos en X y las variables principales o carac-

terísticas de los datos transformados en Y . En la matriz resultante M_{CORR} , las filas y las columnas aparecen de tal forma que las variables x_i se concatenan con las variables y_j ; por tanto, si ésta se divide en cuatro partes iguales, la submatriz de interés $M_{CORREJES}$ pertenece a la sección superior derecha, en la cual las filas corresponden a las x_i y las columnas a las y_j (cuadro 1).

	...	x_i	x_{i+1}	y_j	y_{j+1}	...
...
x_i	...	$corr(x_i, x_i)$	$corr(x_i, x_{i+1})$	$corr(x_i, y_j)$	$corr(x_i, y_{j+1})$...
x_{i+1}	...	$corr(x_{i+1}, x_i)$	$corr(x_{i+1}, x_{i+1})$	$corr(x_{i+1}, y_j)$	$corr(x_{i+1}, y_{j+1})$...
$M_{corr} = \dots$
...
y_j	...	$corr(y_j, x_i)$	$corr(y_j, x_{i+1})$	$corr(y_j, y_j)$	$corr(y_j, y_{j+1})$...
y_{j+1}	...	$corr(y_{j+1}, x_i)$	$corr(y_{j+1}, x_{i+1})$	$corr(y_{j+1}, y_j)$	$corr(y_{j+1}, y_{j+1})$...
...

Cuadro 1. Matriz de correlación general entre los datos en X y Y

- 4) Generación de una matriz $M_{CORREJES}$, que contiene las correlaciones entre todas las variables originales (filas) y los dos primeros ejes principales del espacio transformado P' (columnas). Es decir que, inicialmente:

$$M_{corr2jes} = [M_{correjes}(i, 1) \quad M_{correjes}(i, 2)] \quad (6)$$

- 5) Separación de las dos columnas de la matriz $M_{CORREJES}$ y réplica de las mismas, para obtener dos matrices cuadradas $C_{CORREJE1}$ y $C_{CORREJE2}$ cuyas columnas sean idénticas entre sí e iguales a la columna de correlaciones entre las x_i y el primer eje principal para la primera matriz resultante, y la columna de correlaciones entre las x_i y el segundo eje principal para la segunda matriz resultante.

$$C_{correje1} = [M_{correjes}(i, 1) \quad \dots \quad M_{correjes}(i, 1)] \quad (7)$$

$$C_{correje2} = [M_{correjes}(i, 2) \quad \dots \quad M_{correjes}(i, 2)]$$

Dado que cuando se construye el círculo de correlación el primer eje principal actúa como eje de abscisas y el segundo como eje de ordenadas, ahora es posible encontrar la separación con respecto al eje horizontal y al vertical entre cada par de variables y calcular las diferencias entre las correlaciones con el primer y segundo eje principal, respectivamente. Con las matrices en (7) se procede:

$$D_1 = C_{correje1} - C_{correje1}^T \quad \text{y} \quad D_2 = C_{correje2} - C_{correje2}^T \quad (8)$$

En (8), D_1 y D_2 son matrices cuyos elementos $D_1(i, j)$ y $D_2(i, j)$ son las distancias rectangulares entre las variables i y j . Estas matrices son simétricas y tienen ceros en sus diagonales.

- 6) Cálculo del cuadrado de los elementos de las matrices D_1 y D_2 para generar la matriz D_E con las distancias euclidianas entre la característica x_i (fila i) y la característica x_j (columna j), aplicando la ecuación:

$$D_E(i, j) = \sqrt{D_1(i, j)^2 + D_2(i, j)^2} \quad (9)$$

- 7) Construcción de una lista de parejas de variables separadas por una distancia menor o igual a una distancia d_{max} , que define si dos variables están altamente correlacionadas. La lista se trabaja en forma de una matriz V_{CORR} de dos columnas:

$$V_{CORR} = \left\{ \forall (x_i, x_j) \mid D_E(i, j) \leq d_{max} \right\} \quad (10)$$

De esta forma, la lista contendrá todas las parejas de variables bastante correlacionadas y que, por tanto, llevan información muy similar.

- 8) Puesto que la matriz D_E es simétrica, en el arreglo V_{CORR} del punto anterior, cada pareja estará repetida dos veces. De este de modo se quitan todas las parejas; donde $i > j$.

$$M_{corr2jes}^{(k)} = [M_{corrijes}(i, k) \quad M_{corrijes}(i, k+1)] \quad \text{y} \\ V_{corr}^{(k)} = \left\{ \forall (x_i, x_j) \mid D_E(i, j)^{(k)} \leq d_{max} \right\}, \text{ con } k = 1, 2, \dots, \text{ejepmax}-1 \quad (11)$$

- 10) Comparación para determinar si cada pareja de variables correlacionadas en el primer círculo de correlación siguen con esta condición en los demás círculos. Para ello fue implementado un algoritmo de búsqueda que toma una a una las parejas en $V_{CORR}^{(1)}$ y las compara con las parejas de cada lista obtenida de los círculos restantes, $V_{CORR}^{(2)}, V_{CORR}^{(3)}, \dots, V_{CORR}^{(ejepmax)}$. Los resultados de las comparaciones se guardan en una matriz auxiliar M_{AUX} .
- 11) Selección de las parejas que, de acuerdo con la matriz M_{AUX} del punto anterior, se repitan en todas las listas $V_{CORR}^{(k)}$, y conformación de una lista global y definitiva V_{CORRX} que contendrá todas las parejas de características originales

- 9) Repetición de los pasos 4) hasta el 9) sobre las correlaciones entre las características x_i y cada dos ejes principales consecutivos. Lo anterior significa que, habiendo encontrado las parejas de variables correlacionadas en el círculo de correlación formado por el 1^{er} y 2^{do} eje principal, se debe hacer la misma búsqueda a través de los círculos formados por el 2^{do} y el 3^{er} eje principal, el 3^{er} y 4^{to}, el 4^{to} y 5^{to}, y así sucesivamente hasta aquel formado por los dos últimos ejes principales tenidos en cuenta. Por consiguiente, en cada iteración se obtiene una lista de parejas correlacionadas (similares a la matriz V_{CORR}), y al final se tendrán tantas listas como círculos de correlación se analicen. Matemáticamente, si $ejepmax$ es el número de ejes principales analizados, y k representa el índice de cada iteración, tenemos:

que se mantienen correlacionadas a través de todos los círculos de correlación consecutivos involucrados en el análisis:

$$V_{CORRX} = \{(x_i, x_j) \in V_{corr}^{(k)}, \forall k = 1, 2, \dots, \text{ejepmax}\} \quad (12)$$

- 12) Extracción de la lista de variables individuales y diferentes entre sí que se encuentran en la lista global de parejas correlacionadas V_{CORRX} y conformación de un único vector. A manera de ejemplo, si se tiene la lista de parejas (V_{CORRX}) de la tabla 1a, en la que cada variable está representada por un número entre el 1 y el 24 ($N_{CAR} = 24$), el vector con las variables individuales seleccionadas sería el de la tabla 1b.

1	5
2	6
3	7
4	8
10	11
10	12
11	12
14	15
13	16
13	21
14	22
15	22
14	23
15	23
22	23
13	24
16	24
21	24

a)

1
2
3
4
10
11
14
13
15
22
16
21
5
6
7
8
12
23
24

b)

Tabla 1. a) Lista de parejas de variables correlacionadas a través de los planos principales involucrados: V_{CORRX} . b) Lista de variables individuales

13) Creación de grupos o racimos de variables correlacionadas fuertemente con una de ellas, la cual será la *cabeza* o primer elemento del racimo. Cada variable diferente en V_{CORRX} se convertirá en cabeza de un racimo que habrá de ser completado con las demás variables que estén fuertemente correlacionadas con ella. Para conformar los racimos se busca la presencia de

cada cabeza de racimo en las parejas del arreglo $V_{CORR \cdot X}$. Cada vez que ella aparezca se escoge la variable que la acompaña en V_{CORRX} para ir constituyendo el racimo respectivo. Como ejemplo, en la tabla 2 se muestra la conformación de un conjunto de racimos a partir de los arreglos de la tabla 1.

Variable cabeza de Racimo

Racimo 1	1	5		
Racimo 2	2	6		
Racimo 3	3	7		
Racimo 4	4	8		
Racimo 5	10	11	12	
Racimo 6	11	12	10	
Racimo 7	14	15	22	23
Racimo 8	13	16	21	24
Racimo 9	15	22	23	14
Racimo 10	22	23	14	15
Racimo 11	16	24	13	
Racimo 12	21	24	13	
Racimo 13	5	1		
Racimo 14	6	2		
Racimo 15	7	3		
Racimo 16	8	4		
Racimo 17	12	10	11	
Racimo 18	23	14	15	22
Racimo 19	24	13	16	21

Tabla 2. Organización de las variables correlacionadas en racimos

14) Cuando se han llenado todos los *racimos*, éstos se organizan de acuerdo con la distancia desde el origen del círculo de correlación para el primer plano principal hasta las variables que son

cabeza de los mismos, de modo que el primer racimo que aparezca sea aquel cuya cabeza esté más alejada del origen que las cabezas del resto. Después de esta organización, vuelven a

ordenarse, esta vez de acuerdo con el número de variables que conforman cada racimo, de tal manera que ahora el primero será aquel que reúna más variables correlacionadas.

El número de variables que conforman el racimo es el criterio más importante para el ordenamiento porque así, probablemente, estos grandes racimos absorberán a otros más pequeños, lo que asegura una reducción más eficiente; sin embargo, gracias al primer criterio, cuando existan dos o más racimos con el mismo número de variables correlacionadas

tendrán prelación aquellos cuyas cabezas corresponden a las variables más alejadas del origen del primer círculo de correlación, con lo que se da preferencia a las características que presenten una correlación más grande con las dos variables transformadas de mayor varianza. Para realizar lo descrito, de cada racimo se extrae la información que se observa en la tabla 3a, y al aplicar los criterios de reordenamiento se obtiene la lista de la tabla 3b; así, los racimos mostrados en la tabla 2 quedarían dispuestos como enseña la tabla 4.

Racimo No.	# de Variables en cada Racimo	Distancia de la "cabeza" al origen
1	2	0,84417
2	2	0,92681
3	2	0,87093
4	2	0,69858
5	3	0,84411
6	3	0,86023
7	4	0,95529
8	4	0,90176
9	4	0,95555
10	4	0,9765
11	3	0,87553
12	3	0,90388
13	2	0,84222
14	2	0,92453
15	2	0,86647
16	2	0,69661
17	3	0,82538
18	4	0,99064
19	4	0,90426

Racimo No.	# de Variables en cada Racimo	Distancia de la "cabeza" al origen
18	4	0,99064
10	4	0,9765
9	4	0,95555
7	4	0,95529
19	4	0,90426
8	4	0,90176
12	3	0,90388
11	3	0,87553
6	3	0,86023
5	3	0,84411
17	3	0,82538
2	2	0,92681
14	2	0,92453
3	2	0,87093
15	2	0,86647
1	2	0,84417
13	2	0,84222
4	2	0,69858
16	2	0,69661

Tabla 3. a) Información de los racimos. b) Reorganización de acuerdo con la información de los racimos

15) Elección de las características que se quedan y las que se eliminan. La primera variable o característica que se conserva es la cabeza del racimo de mayor prioridad, de acuerdo con el orden final definido en el punto anterior. Enseguida, interativamente se observa si las variables que

acompañan a la cabeza de este racimo aparecen a la vez como cabezas de otros racimos; si es así, entonces se inhiben los racimos correspondientes a dichas variables, escribiendo un cero en la posición de sus cabezas.

Racimo 18	23	14	15	22
Racimo 10	22	23	14	15
Racimo 9	15	22	23	14
Racimo 7	14	15	22	23
Racimo 19	24	13	16	21
Racimo 8	13	16	21	24
Racimo 12	21	24	13	
Racimo 11	16	24	13	
Racimo 6	11	12	10	
Racimo 5	10	11	12	
Racimo 17	12	10	11	
Racimo 2	2	6		
Racimo 14	6	2		
Racimo 3	3	7		
Racimo 15	7	3		
Racimo 1	1	5		
Racimo 13	5	1		
Racimo 4	4	8		
Racimo 16	8	4		

Tabla 4. Nueva organización de los racimos de variables de acuerdo con los criterios del punto 15

16) Cuando se termina de revisar el *racimo* de mayor prioridad se continúa con el *racimo no inhibido* que le siga; el proceso se repite con los demás *racimos* que no sean inhibidos durante la ejecución del proceso (puntos 16 y 17). Al final, las variables cabeza de los *racimos* que no fueron inhibidos se convierten en las *carac-*

terísticas seleccionadas, dado que ellas aportan la mayor parte de la información de las que se eliminan. En la tabla 5 se muestran los *racimos* inhibidos y no inhibidos, y en el diagrama 1 el algoritmo general del procedimiento de reducción descrito.

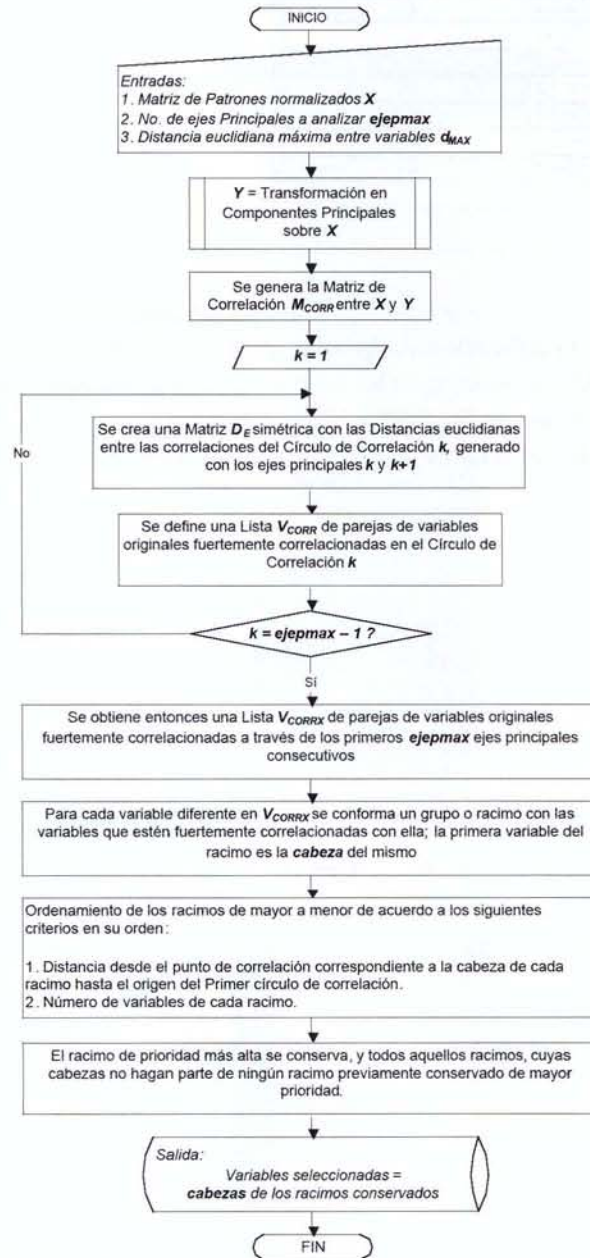


Diagrama 1. Algoritmo para el procedimiento de reducción

Racimo 18	23	14	15	22
Racimo 10	0	23	14	15
Racimo 9	0	22	23	14
Racimo 7	0	15	22	23
Racimo 19	24	13	16	21
Racimo 8	0	16	21	24
Racimo 12	0	24	13	
Racimo 11	0	24	13	
Racimo 6	11	12	10	
Racimo 5	0	11	12	
Racimo 17	0	10	11	
Racimo 2	2	6		
Racimo 14	0	2		
Racimo 3	3	7		
Racimo 15	0	3		
Racimo 1	1	5		
Racimo 13	0	1		
Racimo 4	4	8		
Racimo 16	0	4		

Tabla 5. Racimos inhibidos (en blanco) y no inhibidos (en gris)

4. Resultados

Para revisar los resultados de la aplicación de la reducción automática de variables propuesta, se ha elegido como ejemplo una combinación de análisis que reúne las características de las señales en el

tiempo del espectro de frecuencia con la Transformada Rápida de Fourier (FFT) y de las envolventes *Wavelet* como histogramas. Las gráficas 3, 4 y 5 muestran los primeros círculos de correlación para cada análisis respectivo.




Figura 10. Círculo de correlación para las variables del análisis en el Tiempo

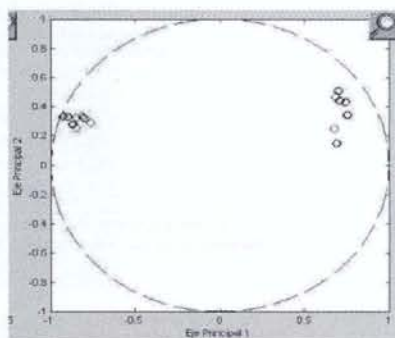


Figura 11. Círculo de correlación para las variables del análisis del espectro en frecuencia

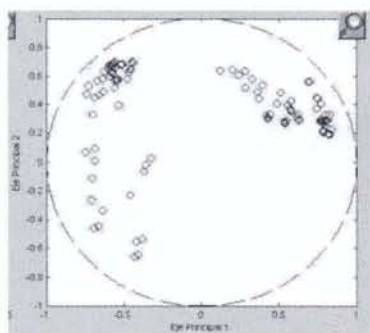


Figura 12. Círculo de correlación para las variables del análisis de las envolventes Wavelet como histogramas

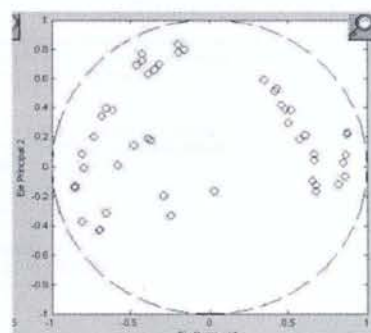


Figura 13. Resultados de la reducción de variables en la combinación de análisis Tiempo-FFT-histograma Wavelet

Cuando se trata de varios análisis combinados, el sistema SURF realiza la reducción sobre las características pertenecientes a cada uno de los análisis, para luego tomar las variables conservadas de cada eliminación (relevantes) y concatenarlas en un único vector de características que también se someterá a un proceso nuevo de reducción; de esta forma, para el ejemplo mostrado se realizan en total cuatro procesos de reducción automática. El resultado de ellos se muestra sobre el primer plano principal y el primer círculo de correlación en la gráfica 6.

En este ejemplo, de 152 variables resultantes del análisis combinado sobre las señales de ultrasonido se llega a un conjunto reducido de 48 variables para un porcentaje de información conservada del 95%. Entonces, se obtiene un 68,4% de reducción, esto es aproximadamente las dos tercios partes del conjunto original de características.

Es destacable que en el grupo de las 48 variables sobrevivientes del ejemplo existen cinco características temporales, cuatro provenientes del espectro discreto de *Fourier*, y 39 de las envolventes *Wavelet*. Esto significa que se conservan las características correspondientes a los tres análisis, a pesar de que en un principio pueda pensarse que en el caso de la FFT sea más probable que no existe informa-

ción suficientemente relevante para una aplicación ultrasónica con transductores de reducido ancho de banda como para pasar el proceso de reducción. En otras combinaciones de análisis que emplean el espectro de *Fourier* sucede lo mismo. Además, es importante anotar que para diferentes selecciones de variables y configuraciones del clasificador, el sistema SURF alcanzó un porcentaje promedio de éxito entre 90 y 95%. En algunas pruebas, cuando se utilizó un umbral de reconocimiento del 50%, el acierto es mayor del 95%, lo cual confirma que el procedimiento de reducción de variables características propuesto se desempeña con efectividad.

Por último, se llevó a cabo una comparación entre la metodología propuesta con las variables originales extraídas únicamente del análisis en el tiempo de las señales de ultrasonido, y el procedimiento clásico de tomar las primeras características transformadas a partir de la aplicación del ACP, para un porcentaje de información conservada del 90% aproximadamente en ambos casos, sin aplicar umbral de reconocimiento y la misma estructura para las redes neuronales empleadas en la clasificación¹. Los resultados presentados en la tabla 6 muestran que el desempeño de la metodología propuesta es mejor que su contraparte a pesar de que la reducción es ligeramente menor.

	Reducción por selección de variables transformadas de mayor varianza a partir del ACP	Reducción de variables originales (no transformadas) mediante la metodología propuesta
Porcentaje de reducción	83%	75%
Porcentaje promedio de éxito en la clasificación	58%	96%

Tabla 6. Comparación entre los resultados de clasificación empleando la metodología propuesta y la reducción por selección de variables transformadas de mayor varianza a partir del ACP

¹ El número de neuronas ocultas del perceptrón multicapa se ajusta según el número de variables de entrada a la red de acuerdo con el criterio planteado en [2].

5. Conclusiones

- Se ha desarrollado un procedimiento algorítmico que reduce en forma automática un

conjunto de variables o características extraídas de señales de eco-ultrasonido y que parte de la aplicación del ACP sobre ellas. El método podría ajustarse a otras aplicaciones diferentes al uso del ultrasonido.

- La metodología propuesta reviste importancia, porque la reducción del número de características en un conjunto inicial bastante grande es un proceso dispendioso; un procedimiento automático agrega objetividad al proceso de reducción y es importante para cualquier sistema de clasificación de patrones, porque desecha aquellas variables que sólo aportan ruido o son redundantes, con la consecuencia directa de disminuir el esfuerzo de cálculo y la probabilidad de confundir al clasificador. Además, la reducción sobre las variables originales (no transformadas) ayuda a definir las mediciones reales que son suficientes sobre las señales de interés.
- La reducción se desarrolla seleccionando y eliminando las variables menos relevantes en función de la cantidad de información que portan. Para ello se generan racimos de variables suficientemente correlacionadas entre sí a través de todos los círculos de correlación generados con los ejes principales consecutivos necesarios para conservar un porcentaje dado de información; luego se eligen los racimos de mayor importancia mediante la aplicación de dos criterios básicos, para tomar de cada racimo la variable alrededor de la cual éste se formó (cabeza del racimo).
- Los resultados de la aplicación de esta técnica a un sistema de reconocimiento de formas de objeto con ultrasonido no sólo demostraron que se pueden alcanzar reducciones significativas y un desempeño exitoso del sistema en la clasificación de formas, sino que también al usar características combinadas provenientes de diferentes métodos de análisis es posible conocer el aporte de información de cada análisis con respecto a los demás.
- Los resultados preliminares arrojados por la metodología propuesta para la reducción de variables son sobresalientes y permiten afirmar que su aplicación puede extenderse a otros proyectos en los que se trabaje con información tomada de señales de diversa índole; sin embargo, aún es necesario continuar con su evaluación y la mejora de su sustentación teórica. Este es uno de los trabajos que en la actualidad se encuentra en desarrollo en el grupo de investigación.

Referencias bibliográficas

- | | |
|---|--|
| <p>[1] Foucart, T. (1997). <i>L'Analyse des Données: Mode d'Emploi</i>. Francia.</p> <p>[2] Restrepo, A. D., Loaiza, H. y Caicedo, E. F. (Septiembre de 2005). <i>Sistema ultrasónico de reconocimiento de formas basado en técnicas frecuenciales e inteligencia computacional</i>. Memorias del X Simposio de Señales, Imágenes y Visión Artificial, Universidad del Valle.</p> <p>[3] Proakis, J. y Manolakis, D. (1998). <i>Tratamiento digital de señales</i>. Ed. Prentice Hall, 3ª ed., España.</p> <p>[4] Tang, X. y Stewart, W. (2000). "Optical and Sonar Image Classification: Wavelet Packet Transform vs. Fourier Transform". <i>Computer Vision and Image Understanding</i>, (79), pp. 25-46.</p> <p>[5] Restrepo, A. D., Loaiza, H. y Caicedo, E. F. (Abril de 2006). "Control y adquisición serial de señales ultrasónicas con Matlab". <i>Ingeniería e Investigación</i>, Revista de la Facultad de Ingeniería de la Universidad Nacional de Colombia, Vol. 26 (1), pp. 103-109.</p> | <p>[6] Kleeman, L. (Noviembre de 2001). <i>Advanced Sonar Sensing. Proceedings 10th International Symposium Robotics Research</i>. Lorne Victoria, Australia, pp. 286-295.</p> <p>[7] Cortijo, F. (Septiembre de 2001). <i>Selección y extracción de características</i>. Disponible en: http://www-etsi2.ugr.es/depar/ccia/rl/www/tema5_00-01_www/node1.html</p> <p>[8] Uenohara, M. y Kanade, T. (August 1997). "Use of Fourier and Karhunen–Loeve Decomposition for Fast Pattern Matching with a Large Set of Templates". <i>IEEE Transactions on Pattern Analysis and Machine Intelligence</i>, Vol. 19 (8), pp. 891-898.</p> <p>[9] Wu, H., Siegel, M. y Khosla, P. (May 1998). "Vehicle Sound Signature Recognition by Frequency Vector Principal Component Analysis". <i>IEEE Instrumentation and Measurement Technology Conference</i>, USA.</p> <p>[10] MathWorks. (2001). <i>Statistics Toolbox for Use with MATLAB, User's Guide</i>, Versión 3.</p> |
|---|--|