

**PRAC1: MAP Y DATOS GAUSSIANOS
CRITERIOS DE CLASIFICACIÓN BASADOS EN MAXIMIZAR LA
PROBABILIDAD A POSTERIORI.**

Asignatura: CLP: Clasificación de Patrones.
Optativa de 2º Ciclo
ETSETB-UPC
TSC-UPC

Profesores:
Margarita Cabrera
Josep Vidal
UPC-TSC-D5

Marzo-2006

1	Introducción a PR-TOOLS	2
2	Objetivos de la práctica 1	4
3	Laboratorio: Creación de Bases de datos Gaussianas.	4
3.1	PARTE 1:	4
3.2	PARTE 2:	4
3.3	PARTE 3:	5
3.4	PARTE 4: OPCIONAL (Clasificador Cuadrático)	6
3.5	PARTE 5: OPCIONAL (Curva ROC para 2 distribuciones gaussianas monodimensionales).....	6
4	Subrutinas a Utilizar	7

1 Introducción a PR-TOOLS

PR-TOOLS consiste en un paquete de software de Matlab, especialmente diseñado para realizar aplicaciones de Clasificación de patrones y trabajar con bases de datos experimentales.

PR-Tools ha sido creado por: *Pattern Recognition Group, Delta University of Technology (Holanda)*. <http://www.ph.tn.tudelft.nl/prtools>.

A continuación se presentan algunas características importantes del trabajo con este tipo de software:

- Conjuntos de objetos etiquetados.
- Un **objeto** es un vector k-dimensional. En cada coordenada se almacena un valor de una característica.
- El espacio definido por todos los valores posibles de características se denomina **espacio de características**.
- Los objetos se representan como puntos o vectores en este espacio.
- Una **función de clasificación asigna etiquetas a nuevos objetos** que aparecen dentro del espacio de características.

Conjuntos de objetos: Los conjuntos de objetos similares dentro del espacio de características **se agrupan en “Clusters”**.

Problema fundamental: Hallar una **medida de distancia**. La distancia euclídea suele cambiarse a través de transformaciones de escalado o de movimientos o rotaciones del vector de características que representa un objeto.

La dimensionalidad del espacio de características se puede reducir por la selección de sub-conjuntos de características, mediante diferentes tipos de algoritmos que se denominan como estrategias de “Feature Selection”. Ventajas:

- Mejora de la Velocidad Computacional
- Ocasionalmente mejora la precisión de los algoritmos de clasificación.
- Menor complejidad de los algoritmos de clasificación.

Los clasificadores pueden ser:

- Lineales
- No lineales

Y se hallan basados en dos estrategias distintas:

- Minimizar el error de clasificación a partir de la estimación de las f.d.p (Regla de Bayes, en el caso de que se conociera exactamente la f.d.p.)
- Optimizar determinadas funciones de clasificación.

En el entrenamiento de un clasificador, es interesante realizar estrategias de

- Cross-Validation
- Rotación

Programación PR-Tools con MATLAB:

Clases (Equivalen a 2 tipos de estructuras de datos): Dataset y Mapping

DATASET (A): Conjunto de objetos representados por una matriz de vectores de características. Adjunto a esta matriz se tiene información adicional de los datos:

DATASET Dataset class constructor

a = dataset(d,labels,featlist,prob,lablist,imheight)

A dataset object is constructed from:

d size [m,k], a set of m datavectors of k features

labels size [m,n] labels for each of the datavectors either in string or in numbers

featlist size [k,f] defines the labels for the k features (Los nombres de las características)

prob size [c,1], apriori probabilities for each of the c classes

prob = 0: all classes have equal probability 1/c

prob = []: all datavectors are equally probable

lablist size [c,n] classlabels (Los nombres de las clases)

Alternativamente se puede utilizar esta subrutina para testear todos los parámetros que forman el objeto de este tipo:

[nlab,lablist,m,k,c,prob,featlist,imheight] = dataset(a)

MAPPING (W): Almacena clasificadores entrenados, resultados de extracción de características, definiciones de escalado de datos, proyecciones no lineales, etc..

A*W es un dataset.

MAPPING Mapping class constructor

w = mapping(map,d,lablist,k,c,v,par)

A map/classifier object is constructed from:

d size (any), a set of weights defining the mapping

lablist size [c,n], defines the labels for the outputs ('classes') of the mapping, either in string or in numbers c is the number of classes. At least two labels should be supplied.

map type or name of routine used for learning or testing

k number of inputs (número de características)

c number of outputs (número de clases). Note that if c == 1, lablist should still have two labels, one for each 'direction'

v size [c] or size [1] Output multiplication factor, for all outputs simultaneously or for each output separately

par size (any), parameter vector describing the structure of the mapping (type dependent)

classbit 0 | 1 if classc==1 this is a classifier: map by w*sigm*normm which constructs normalized probabilistic outputs

[d,lablist,map,k,c,v,par] = mapping(w) Retrieves the parameters from a mapping w.

2 Objetivos de la práctica 1

- Los objetivos de la presente práctica consisten en familiarizarse con el software prtools, con matlab y con el entorno de trabajo en general.
- Generar bases de datos Gaussianas y evaluar parámetros de las mismas.
- Aplicar clasificadores MAP (Lineales y Cuadráticos) sobre las clases generadas.

3 Laboratorio: Creación de Bases de datos Gaussianas.

3.1 PARTE 1:

Ejecute “prac1_gauss3.m”

Se trabaja con vectores de dimensión $d=3$ y $C=2$ clases. Las 3 coordenadas son estadísticamente independientes tal como describen las matrices de covarianza (Caso 1)

$$\mathbf{y}_i : N(\mathbf{s}_i, \mathbf{\Sigma}); \quad \mathbf{\Sigma} = \sigma^2 \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

Observe las probabilidades de error obtenidas mediante los clasificadores

ldc: Fronteras de decisión lineales. Presupone clases equiprobales y idéntica matriz de covarianza.

qdc: Fronteras de decisión cuadráticas. Presupone clases equiprobales y estima diferentes matrices de covarianza.

Anote las probabilidades de error anteriores en fichero Word **G***_Prac1.doc**:

$$\text{distancia}=1, \quad \text{SNR}=3,0,-3,-10 \text{ dB}, \quad \text{SNR} = 10 \log_{10} \left(\frac{\text{Energia promedio}}{\sigma^2} \right)$$

Observe las gráficas de la ROC para , $\text{SNR}=3,0,-3,-10$ dB y comente los resultados.

3.2 PARTE 2:

Se propone utilizar la modulación QPSK como base de trabajo. *Prac1_QPSK.m*

Por tanto los vectores de características son de dimensión $d=2$ y se tienen $C=4$ clases. Inicialmente se contemplan matrices de covarianza iguales para todas las clases (Caso 2) pero no diagonales.

$$\mathbf{y}_i : N(\mathbf{s}_i, \mathbf{\Sigma}); \quad \mathbf{\Sigma} = \sigma^2 \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}$$

Se pide analizar para esta constelaciones:

- Mapas de Señal y fronteras de decisión mediante criterios ldc y qdc
- Distancia de Mahalanobis Inter-clases

La evaluación de las anteriores características se propone realizar para:

- Relación señal a ruido: SNR=10dB
- Distancia entre clases: dist=1
- Parámetro $\rho = 0, 0.5, -0.5$

Observe que apenas hay diferencias entre ambos clasificadores.

Evalúe el mapa de señal al aplicar ldc y qdc, para el siguiente caso (Caso 3). Compare la forma de los clusters con los autovalores de las distintas matrices de covarianza, que puede obtener llamando a la subrutina “eig” de matlab.

SNR=5dB, 0dB

- Símbolo 1: $\rho = +0.5$
- Símbolo 2: $\rho = 0$
- Símbolo 3: $\rho = -0.5$
- Símbolo 4: $\rho = +0.8$

Para calcular autovalores, por ejemplo de la clase i:

$$\begin{aligned} \text{Autoval} &= \text{eig}(\text{squeeze}(G_AI(:, :, i))) \quad \% \text{Exact} \\ \text{Autoval} &= \text{eig}(\text{squeeze}(\text{Cov}(:, :, i))) \quad \% \text{Estimated} \end{aligned}$$

Puede guardar los resultados anteriores en el documento Word y comentar los resultados.

A continuación reparta la potencia de ruido ($\rho=0$) entre las 4 clases proporcionalmente a $[1.4 \ 0.5 \ 0.05 \ 0.05]/2$ y observe las diferencias producidas sobre las fronteras de decisión al aplicar clasificador lineal (ldc) o cuadrático (qdc). Note en el programa que esta instrucción se halla programada pero comentada %.

3.3 PARTE 3:

Se propone utilizar como base de trabajo BPSK aunque en dos dimensiones.
Prac1_BPSK.m

Por tanto los vectores de características son de dimensión $d=2$ y se tienen $C=2$ clases. Inicialmente se contemplan matrices de covarianza iguales para todas las clases (Caso 2) pero no diagonales.

$$\mathbf{y}_i : N(\mathbf{s}_i, \mathbf{\Sigma}); \quad \mathbf{\Sigma} = \sigma^2 \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}; \rho = -0.5, \text{SNR}=5\text{dB}$$

Se pide analizar para esta constelación:

- Mapas de Señal y fronteras de decisión mediante criterios ldc y qdc.
- Errores de decisión mediante criterios ldc y qdc.
- Autovalores de las matrices de covarianza.

Posterior se propone analizar el siguiente caso (Caso 3).

$$\mathbf{y}_i : N(\mathbf{s}_i, \boldsymbol{\Sigma}_i); \boldsymbol{\Sigma}_i = \sigma^2 \begin{pmatrix} 1 & \rho_i \\ \rho_i & 1 \end{pmatrix}$$

SNR=5dB

- Símbolo 1: $\rho = -0.8$
- Símbolo 2: $\rho = +0.8$

Se pide analizar para esta constelación:

- Mapas de Señal y fronteras de decisión mediante criterios ldc y qdc.
- Errores de decisión mediante criterios ldc y qdc.
- Autovalores de las matrices de covarianza.

Puede guardar los resultados anteriores en un documento Word y comentar los resultados.

Optative:

Adicionalmente puede cambiar, para este tercer caso, las probabilidades a priori de las dos clases, para ello cambie el número de muestras de las dos clase, ya que las probabilidades a priori se obtienen a partir de las proporciones de muestras de cada clase.

3.4 PARTE 4: OPCIONAL (Clasificador Cuadrático)

Ejecute `prac1_QPSK_qdcr`. Ver las diferencias de los parámetros que se guardan del clasificador entre las subrutinas. Interpretar a partir de la información obtenida del `help` de `prtools`. (`help qdc`; `help quadrc`);

- `Qdc`
- `Quadrc`

3.5 PARTE 5: OPCIONAL (Curva ROC para 2 distribuciones gaussianas monodimensionales)

Ejecute `P1_ROC`.

4 Subrutinas a Utilizar

Prac1_gauss3.m:

Prac1_QPSK.m:

Prac1_BPSK.m:

Prac1_QPSK_qdcr.m (OPCIONAL).

P1_ROC.m (OPCIONAL).

GAUSS Generation of multivariate Gaussian dataset.

$$A = \text{gauss}(n,U,G)$$

Generation of n k -dimensional Gaussian distributed vectors with covariance matrices G (size $k*k*c$) and with means, labels and prior probabilities defined by the dataset U with size $(c*k)$.
Alternatively n can be a vector with length c .

Default:

G : eye(k)

U : zeros($1,k$)

LDC Linear Discriminant Classifier

$$W = \text{ldc}(A,r,s)$$

Computation of a linear discriminant between the classes of the dataset A assuming normal densities with equal covariance matrices. The joint covariance matrix is the weighted (by apriori probabilities) average of the class covariance matrices.

r and s ($0 \leq r,s \leq 1$) are regularization parameters used for finding the covariance matrix by

$$G = \text{inv}((1-r-s)*G+r*\text{diag}(\text{diag}(G)))+$$

$$s*\text{mean}(\text{diag}(G))*\text{eye}(\text{size}(G,1))$$

So, $r = 0$: (default) no regularization

$r = 1$: don't use data

QDC Quadratic Bayes Normal Classifier

$$W = \text{qdc}(A,r,s)$$

Computation of the quadratic classifier between the classes of the dataset A assuming normal densities. r and s ($0 \leq r,s \leq 1$) are regularization parameters used for finding the covariance matrix by

$$G = (1-r-s)*G + r*\text{diag}(\text{diag}(G)) + s*\text{mean}(\text{diag}(G))*\text{eye}(\text{size}(G,1))$$

Default: $r = 0, s = 0$.

The classification $A*W$ is computed by `normal_map`. See there for details.

See also `datasets`, `mappings`, `nmc`, `nmcs`, `ldc`, `udc`, `quadrc`, `normal_map`

ROC Receiver-operator curve

$$e = \text{roc}(D,k)$$

Computes k points of the receiver-operator curve of the classifier W for the labeled data set D , which is typically the result of $D = A*W*\text{class}$. The curve is computed for k thresholds of the aposteriori probabilities stored in D . The resulting error frequencies for the two classes are stored in the two columns of e , which may conveniently be plotted by `plot2`. Default $k = 100$

See also `datasets`, `mappings`, `reject`, `plot2`

DISTMAHA Mahalanobis distance

$$D = \text{dismaha}(A,U,G)$$

Computation of the Mahalanobis distances of all vectors in the dataset A to a dataset of points U , using the covariance matrix G . G should be either a 2-dimensional square matrix of the right size or a 3-dimensional matrix containing a covariance matrix for each point in U . If A contains m vectors and U n vectors, the size of D is $m*n$.

$$D = \text{dismaha}(A)$$

Estimation of the Mahalanobis distance matrix between all classes in the set of data vectors in A defined by labels.

See also `datasets`