

Análisis comparativo de métodos basados en subespacios aplicados al reconocimiento de caras

Director: Francesc J. Ferri i Rabasa, Autor: Marcelo Armengot Iborra

ferri@uv.es , marcelo.armengot@uv.es

Universidad de Valencia

Presentación del problema

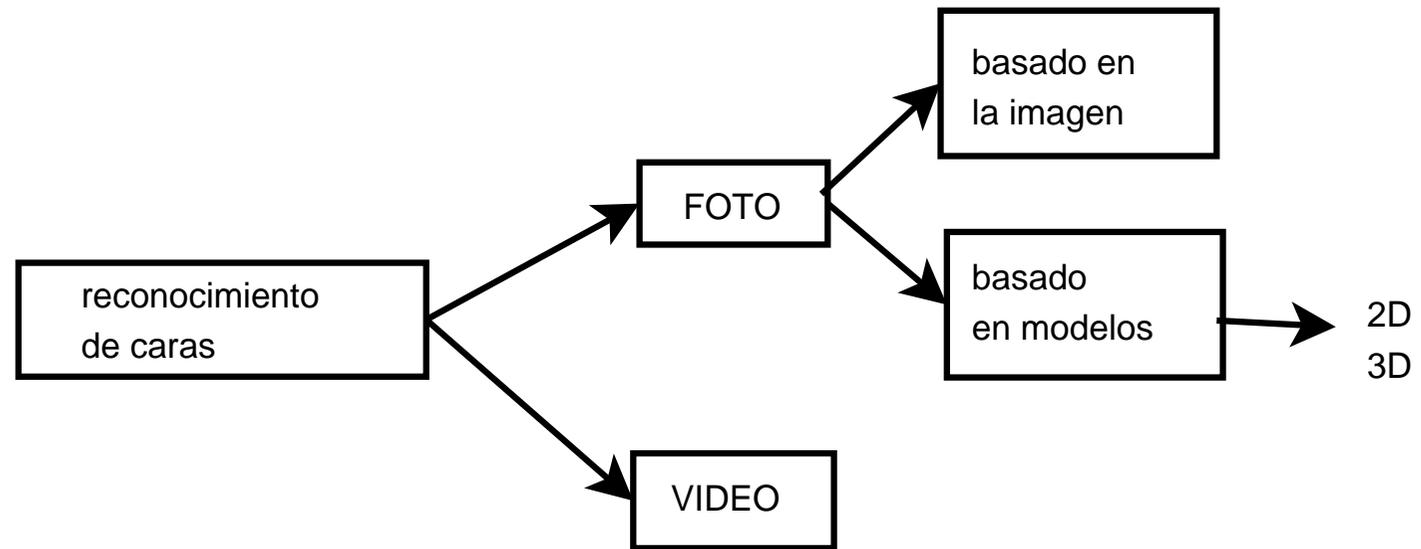
Reconocimiento de caras. Estructura compleja.
Factores subjetivos.



Aplicaciones

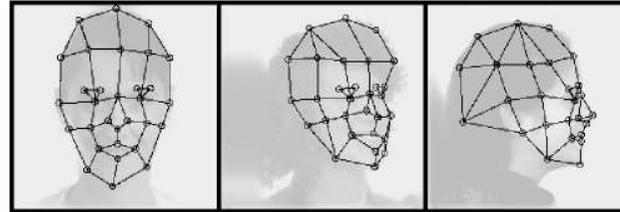
- Vigilancia.
- Control de acceso. DNI, pasaporte, etc.
- Videoconferencia.
- Interfaces hombre-máquina. *Log in*.
- Detección de expresiones faciales.
- Base de datos multimedia.

Taxonomía

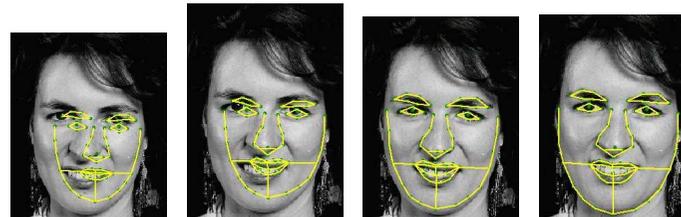


Taxonomía

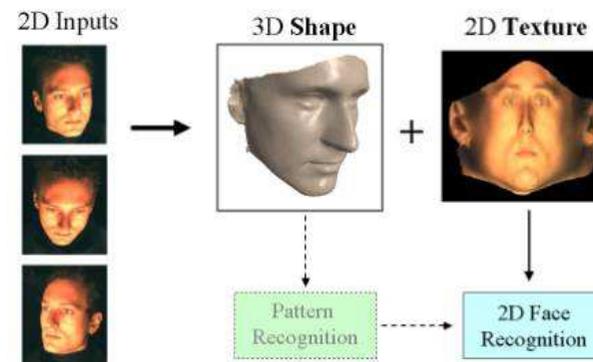
- *Elastic bunch graph*



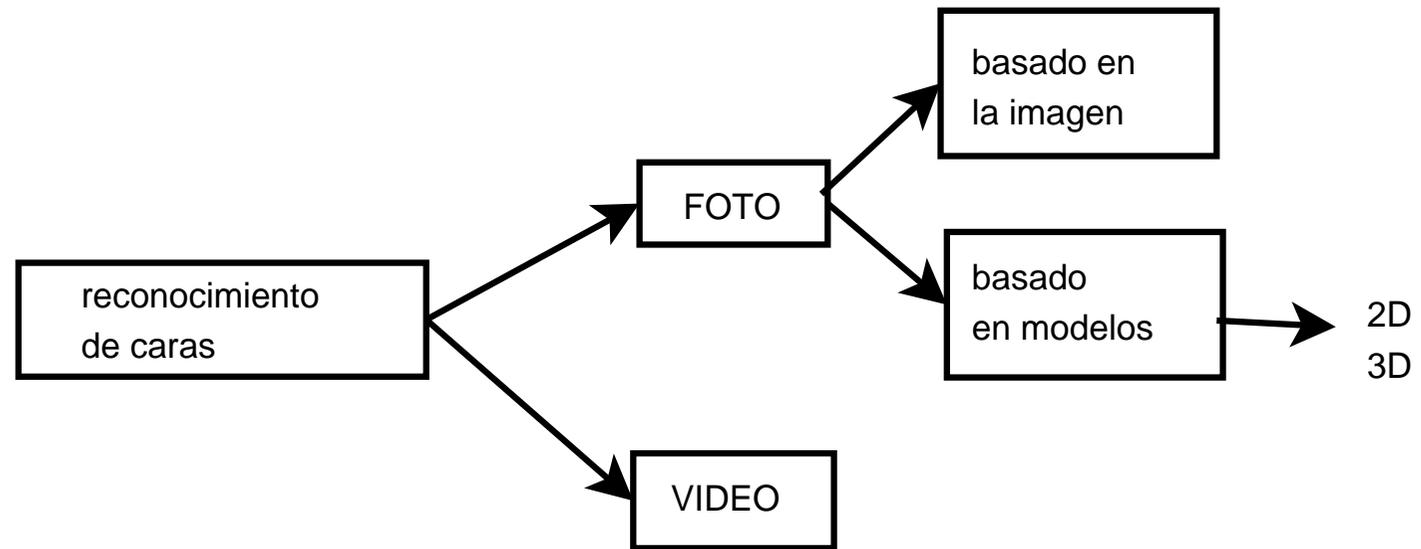
- Modelo de forma activa.



- *3d morphable model*



Taxonomía



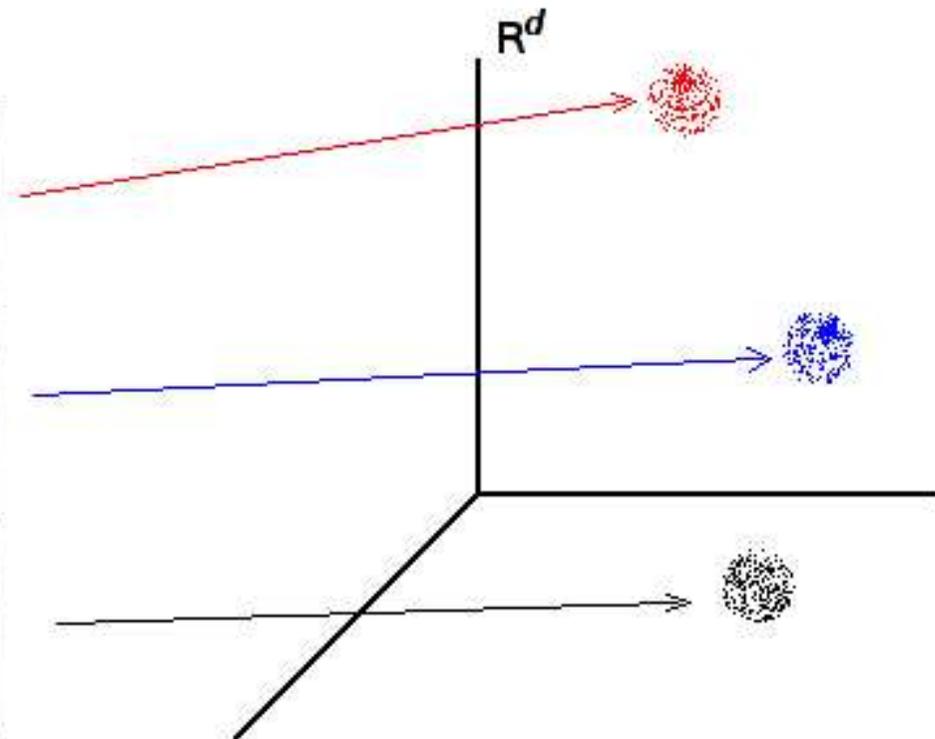
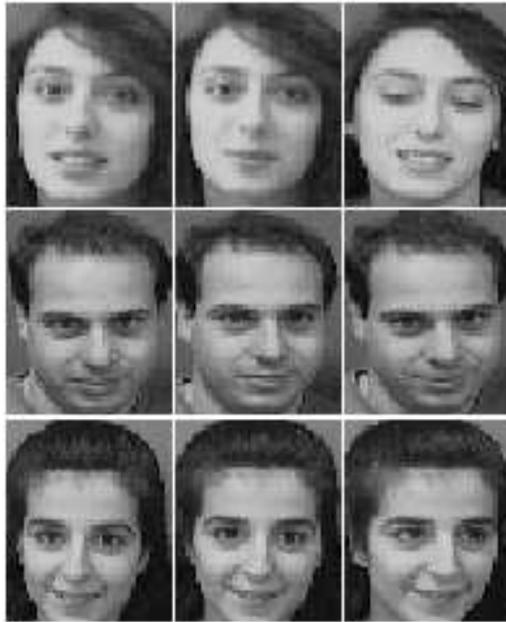
Subespacios

¿Tiene sentido trabajar directamente con la imagen?



Cambios de luz, expresión facial, punto de vista.
+ Alta dimensión de los datos.

Subespacios



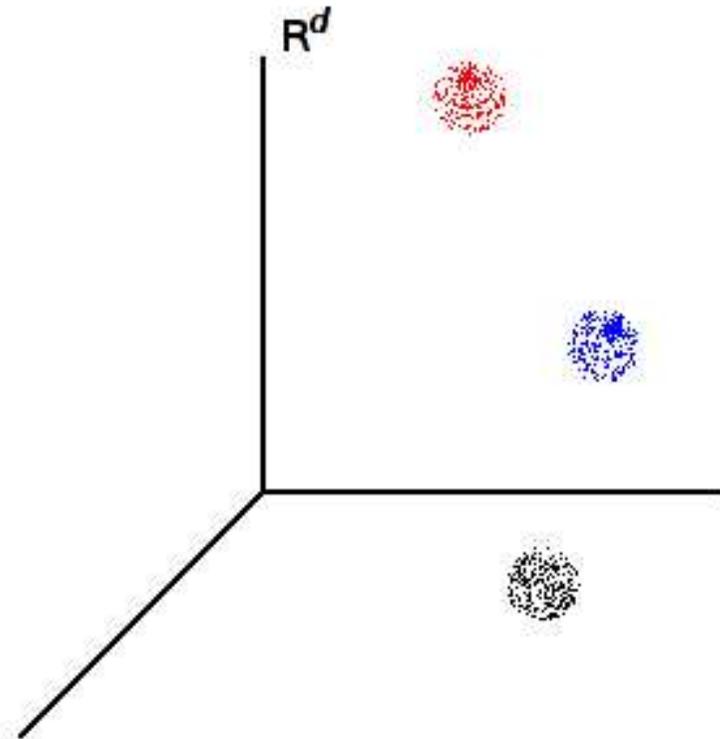
Subespacios



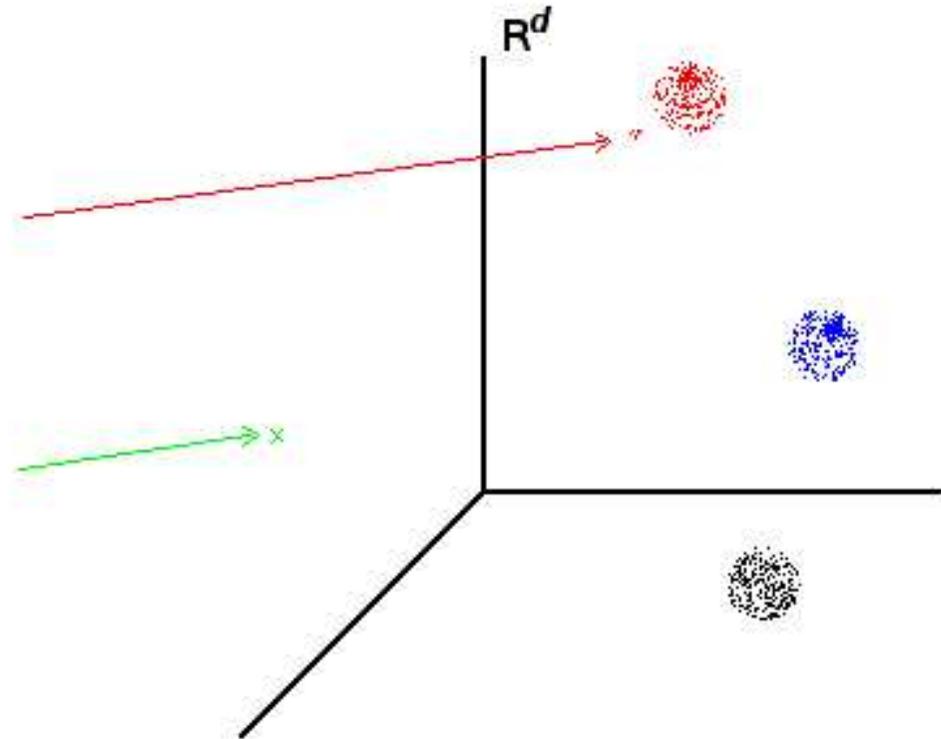
?



?



Subespacios



Subespacios

Imagen de $d = n \times m$ píxeles.

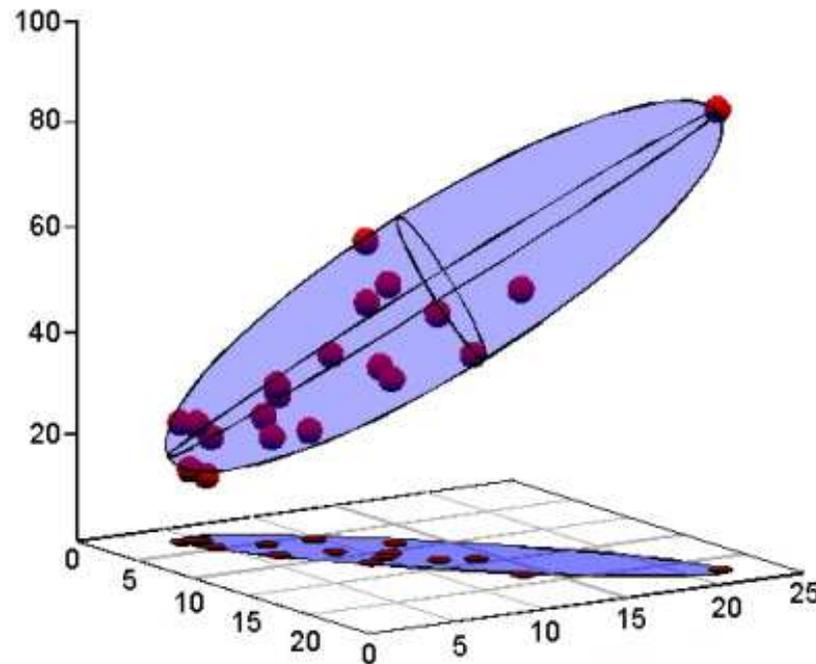


Vector con d valores en el espacio \mathbb{R}^d

¿Qué proyección $f : \mathbb{R}^d \rightarrow \mathbb{R}^{d'}$ me interesa?

Subespacios: Eigenfaces

$$S = \frac{1}{M} \sum_{i=1}^M (x_i - \mu)(x_i - \mu)^T$$



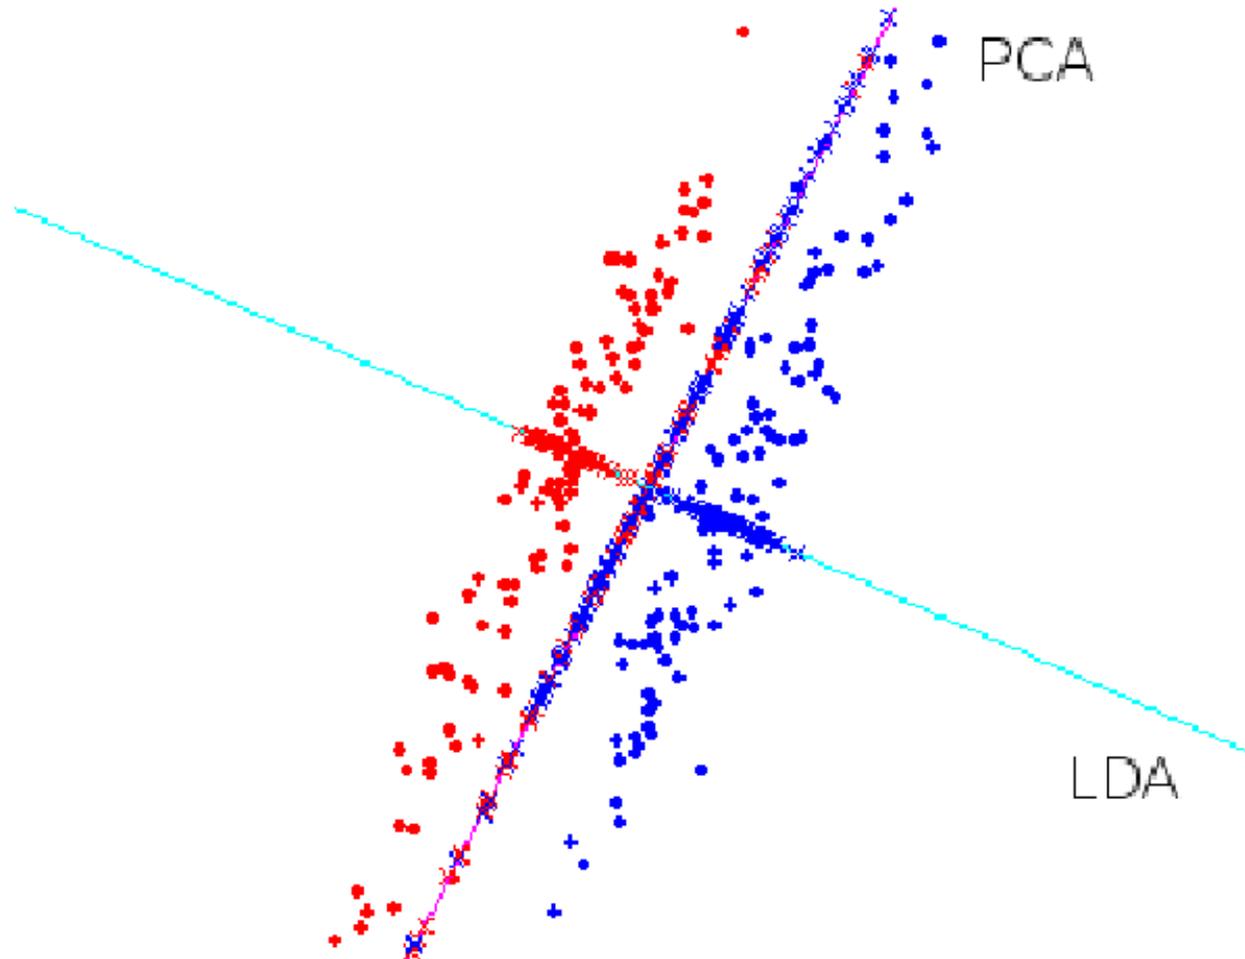
Subespacios: Fisherfaces

$$J_{lda}(w) = \frac{w^T S_B w}{w^T S_W w}$$

$$S_B = \sum_{i=1}^C N (\mu_i - \mu) (\mu_i - \mu)^T$$

$$S_W = \sum_{i=1}^C \sum_{m=1}^N (x_m^i - \mu_i) (x_m^i - \mu_i)^T$$

Fisherfaces



Subespacios: Vector común

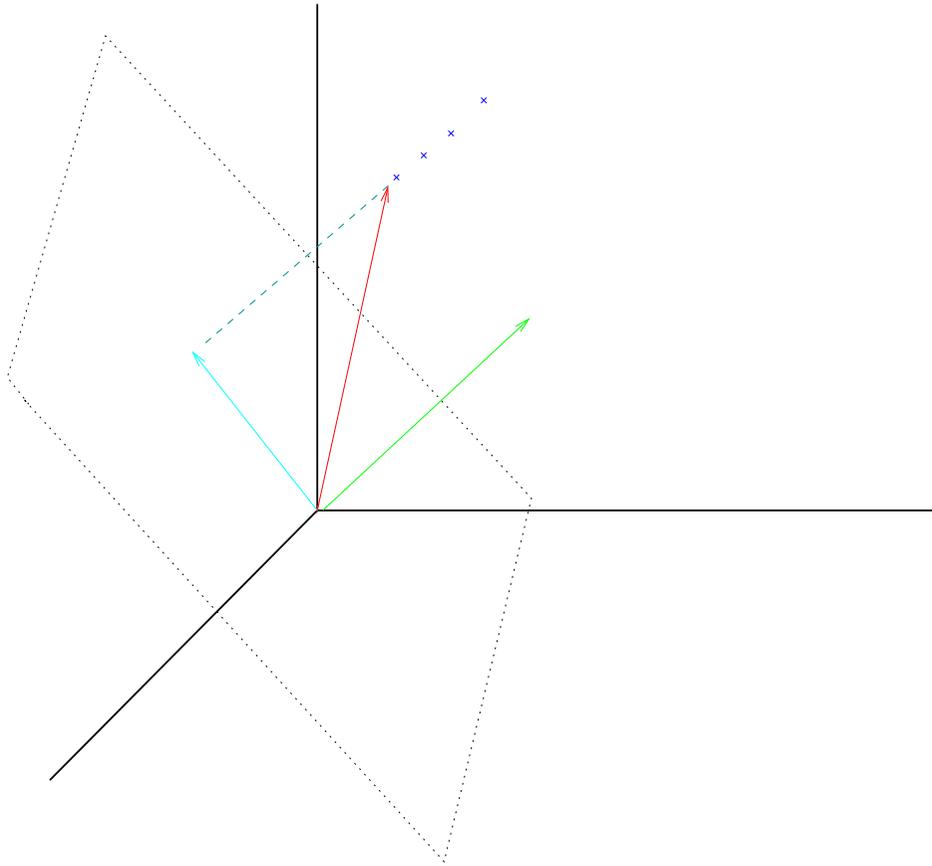
¿Existe una proyección para representar todas las muestras de una misma clase por medio de un único *vector común*?

M. B. Gülmezoğlu, V. Dzhafarov, M. Keskin and A. Barkana

A novel approach to isolated word recognition

IEEE Trans. Speech and audio processing, 7 (6), 1999

Subespacios: Vector común



$$a_1 = c + a_{1,dif}$$

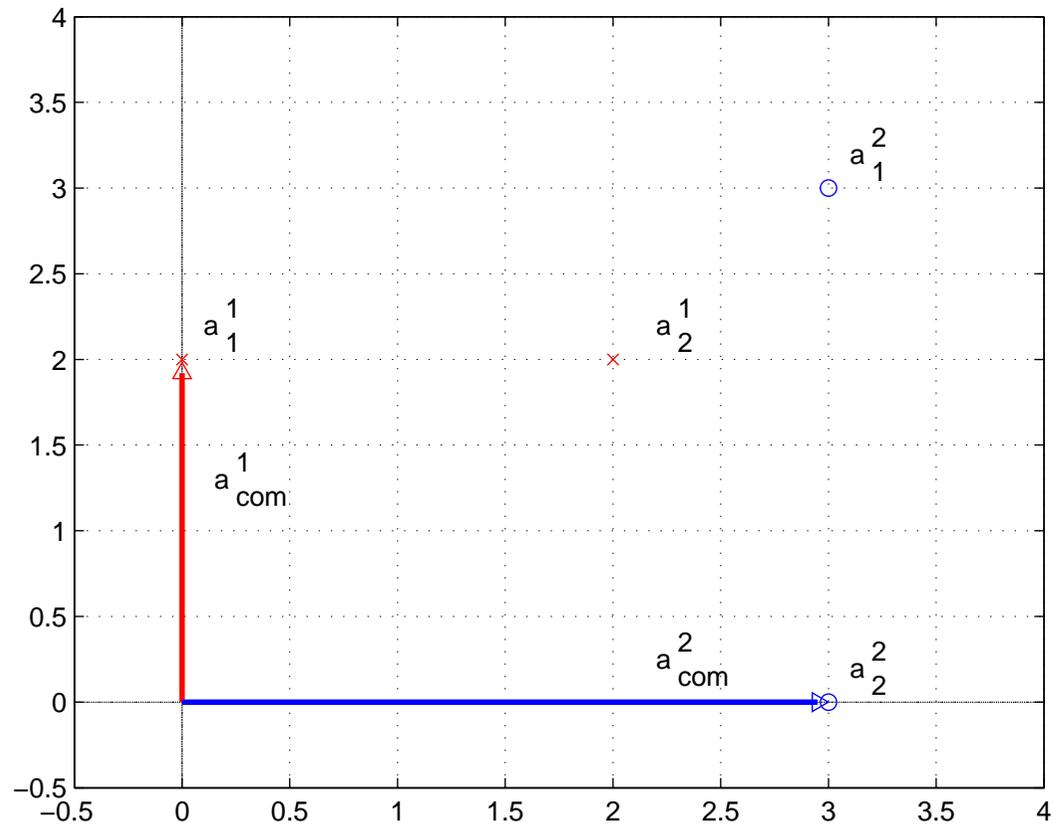
$$a_2 = c + a_{2,dif}$$

⋮

$$a_m = c + a_{m,dif}$$

$$\ker(S) = \{x \in \mathbb{R}^{d \times 1} : Sx = 0\} \longrightarrow Sc = 0$$

Subespacios: Vector común



Vector común discriminante

¿Existe una proyección para proyectar todas las muestras de todas las clases de manera que todas las muestras de la misma clase estén representadas por medio de un único *vector común discriminante*?

H. Cevikalp, M. Neamtu, M. Wilkes and A. Barkana
Discriminative common vectors for face recognition
IEEE Trans. Pattern analysis and machine intelligence
Vol. 27 no 1 January 2005

Vector común discriminante

$$\mathbb{R}^d = V + V^\perp$$

$$V = \text{span} \{ \alpha_k \mid S_W \alpha_k \neq 0 \quad k = 1 \dots r \}$$

$$V^\perp = \text{span} \{ \alpha_k \mid S_W \alpha_k = 0 \quad k = r + 1 \dots d \}$$

$$x_m^i = y_m^i + z_m^i$$

Vector común discriminante

Objetivo:

$$z_m^i = \bar{P} x_m^i = \bar{Q} \bar{Q}^T x_m^i$$

Dimensión $d - r$!!

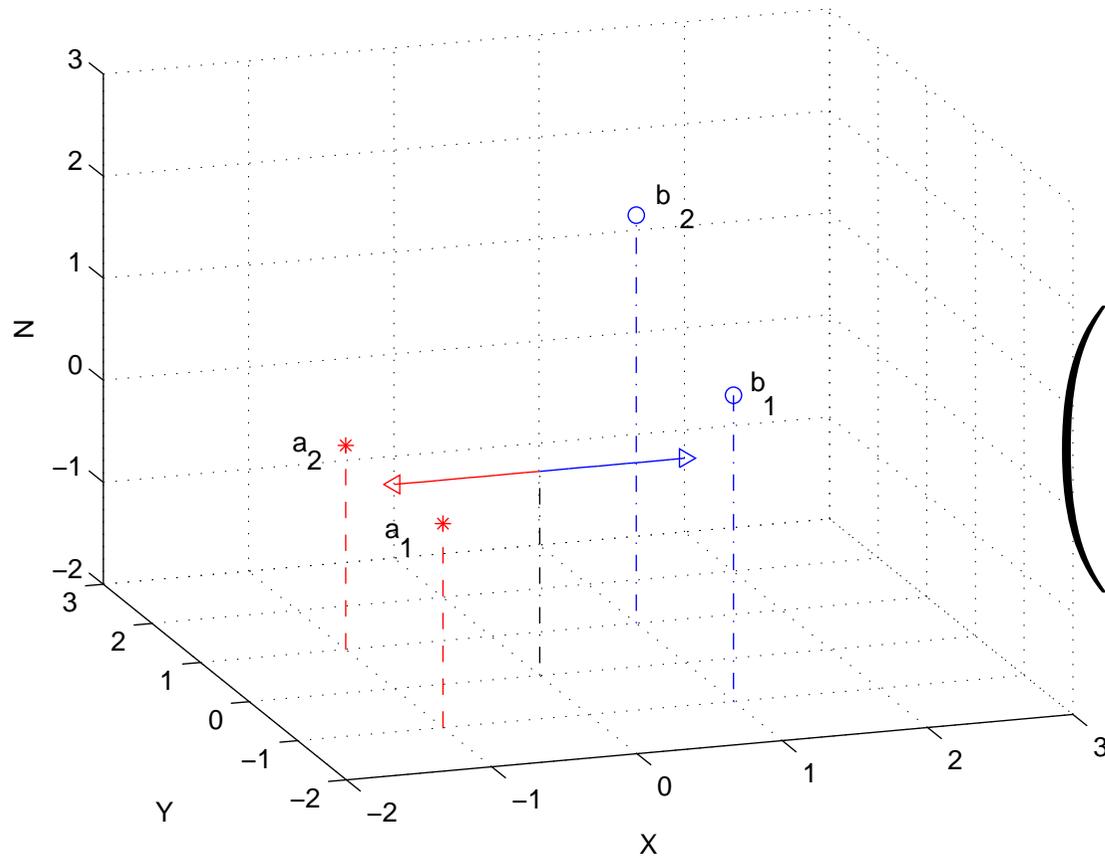
Alternativa:

$$y_m^i = P x_m^i = Q Q^T x_m^i \in V$$

P y \bar{P} son los operadores de proyección ortogonal sobre V y V^\perp , respectivamente.

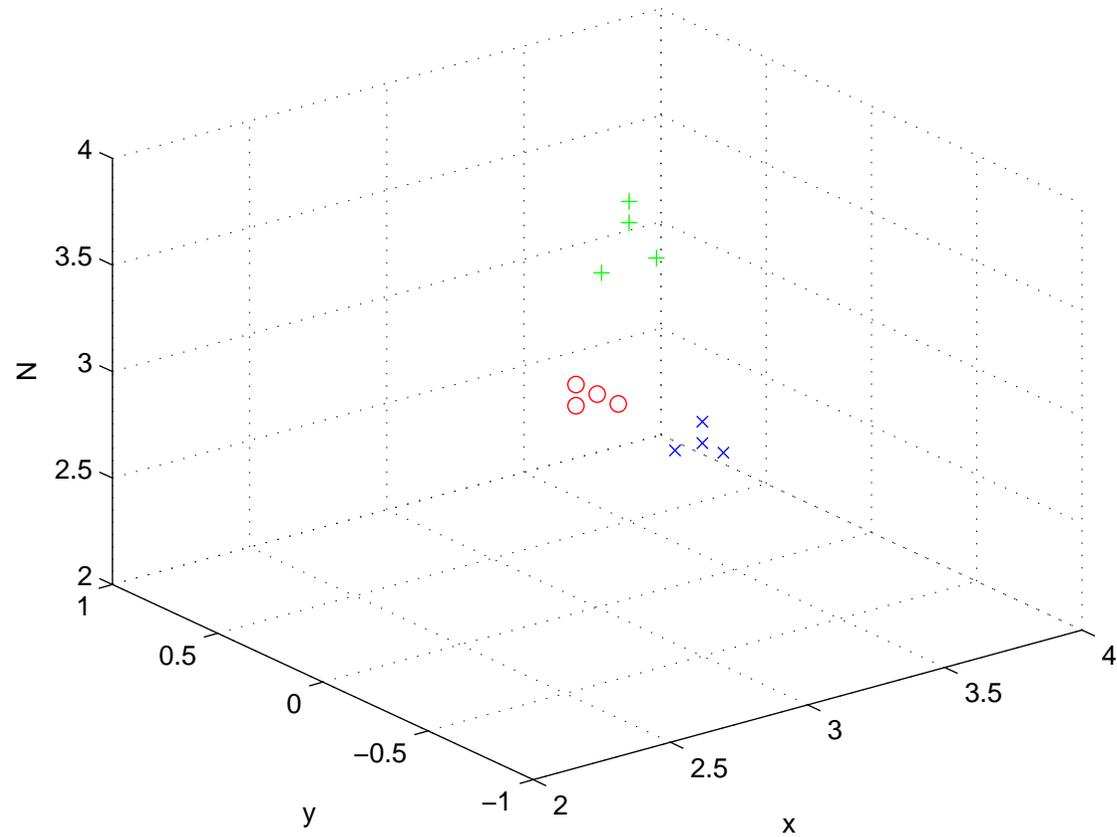
$$x_{com}^i = x_m^i - y_m^i = x_m^i - P x_m^i$$

Vector común discriminante

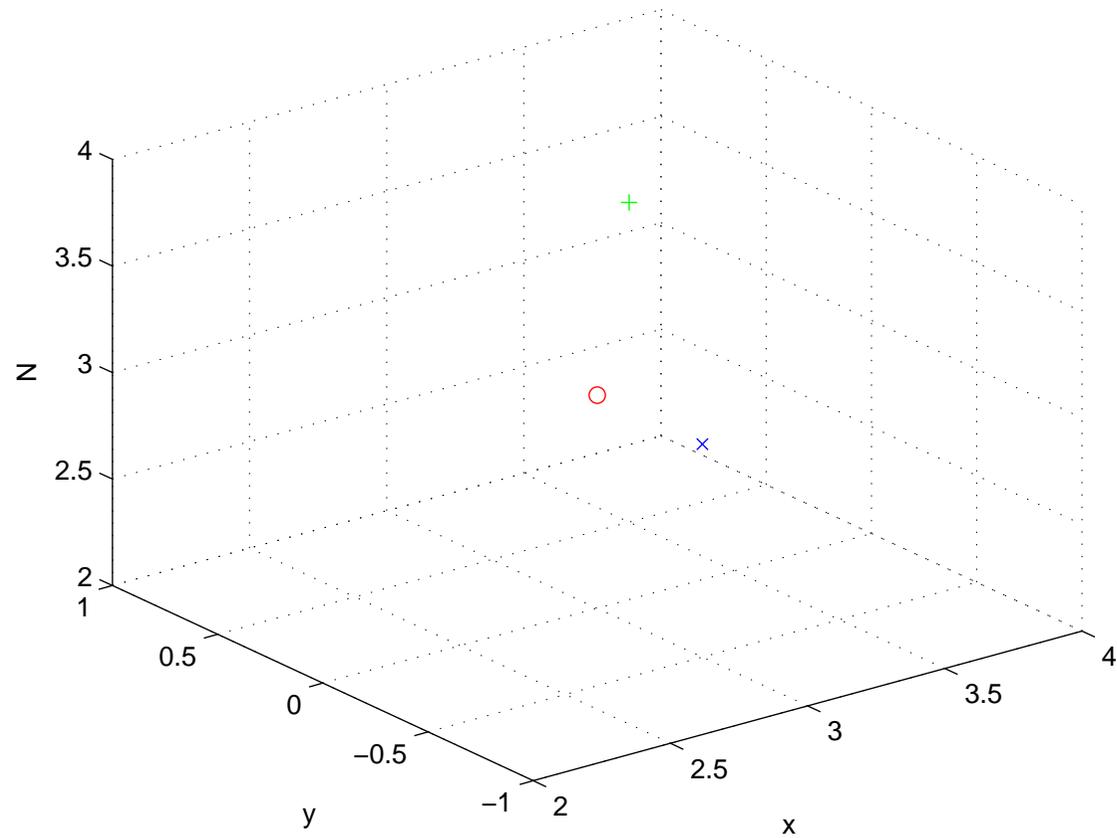


$$\begin{pmatrix} -1 & -1 & 1 & 1 \\ -1 & 1 & -1 & 1 \\ 0 & 0 & 1 & 2 \end{pmatrix}$$

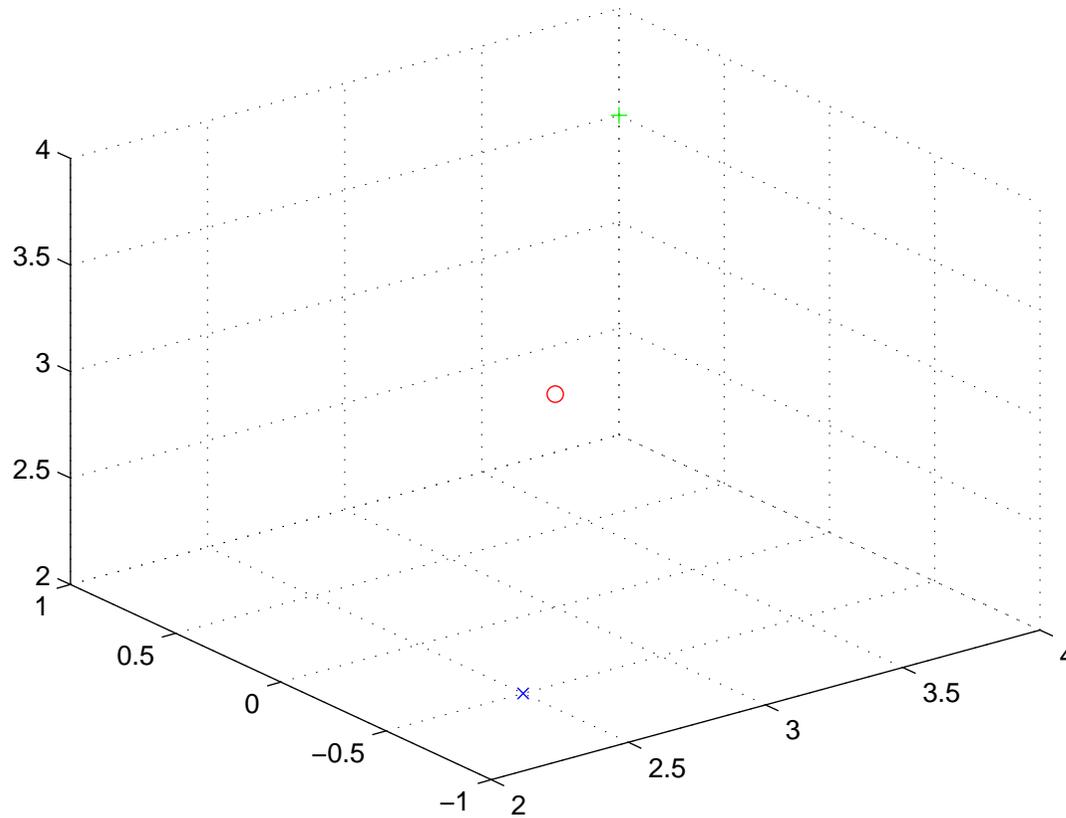
Vector común discriminante



Vector común discriminante



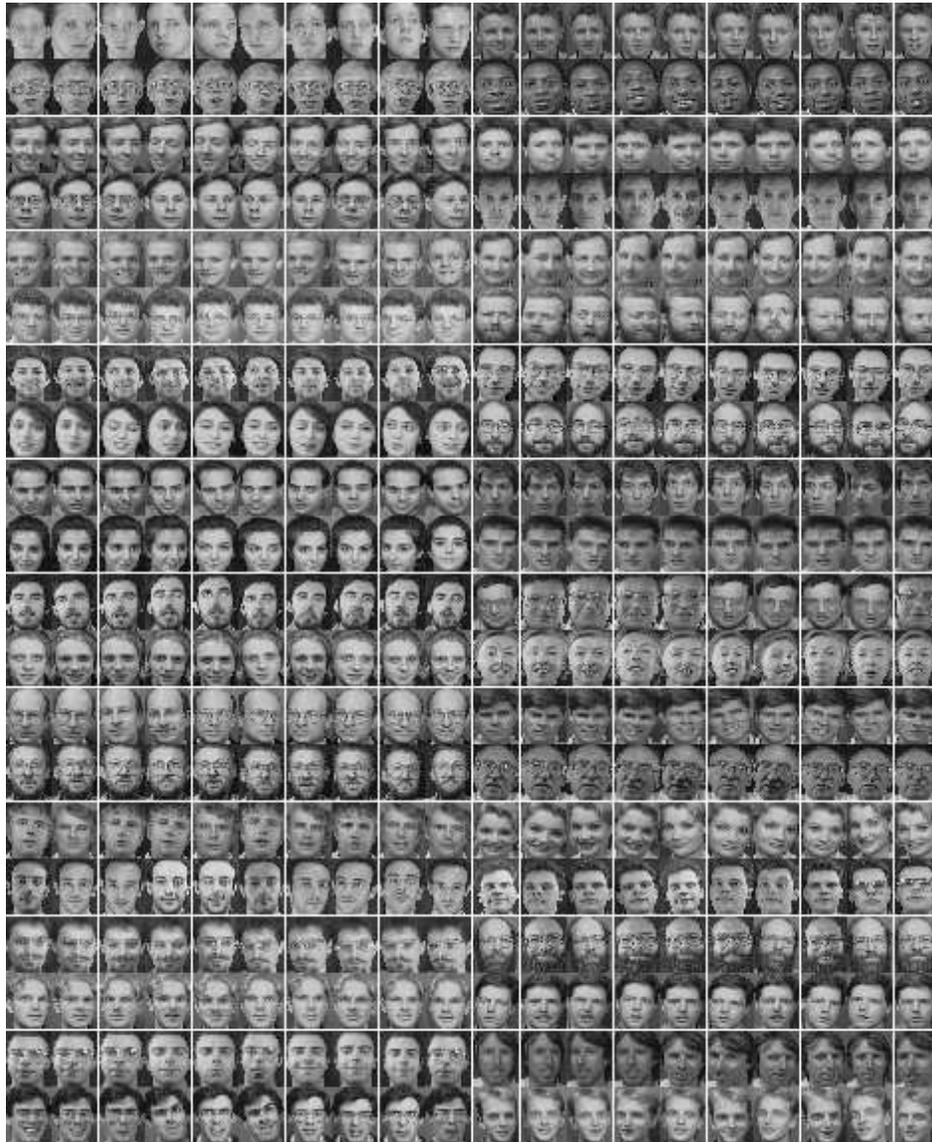
Vector común discriminante



DCV: Algoritmo

1. Eigenanálisis de S_W . Vectores propios no nulos en $Q \longrightarrow P = QQ^T$.
2. Obtener los $x_{com}^i = x_m^i - Px_m^i$ con un x_m^i de cada clase i . Construir con ellos S_{com} .
3. Obtener los vectores propios w_k de S_{com} correspondientes a los valores propios no nulos.
4. Construir con ellos (como mucho $C - 1$) la matriz de proyección w .
5. Con un vector por cada clase proyectado con w , obtener un vector de clasificación.
6. Componer P y w en una sola matriz que aplicaremos a los vectores de prueba.

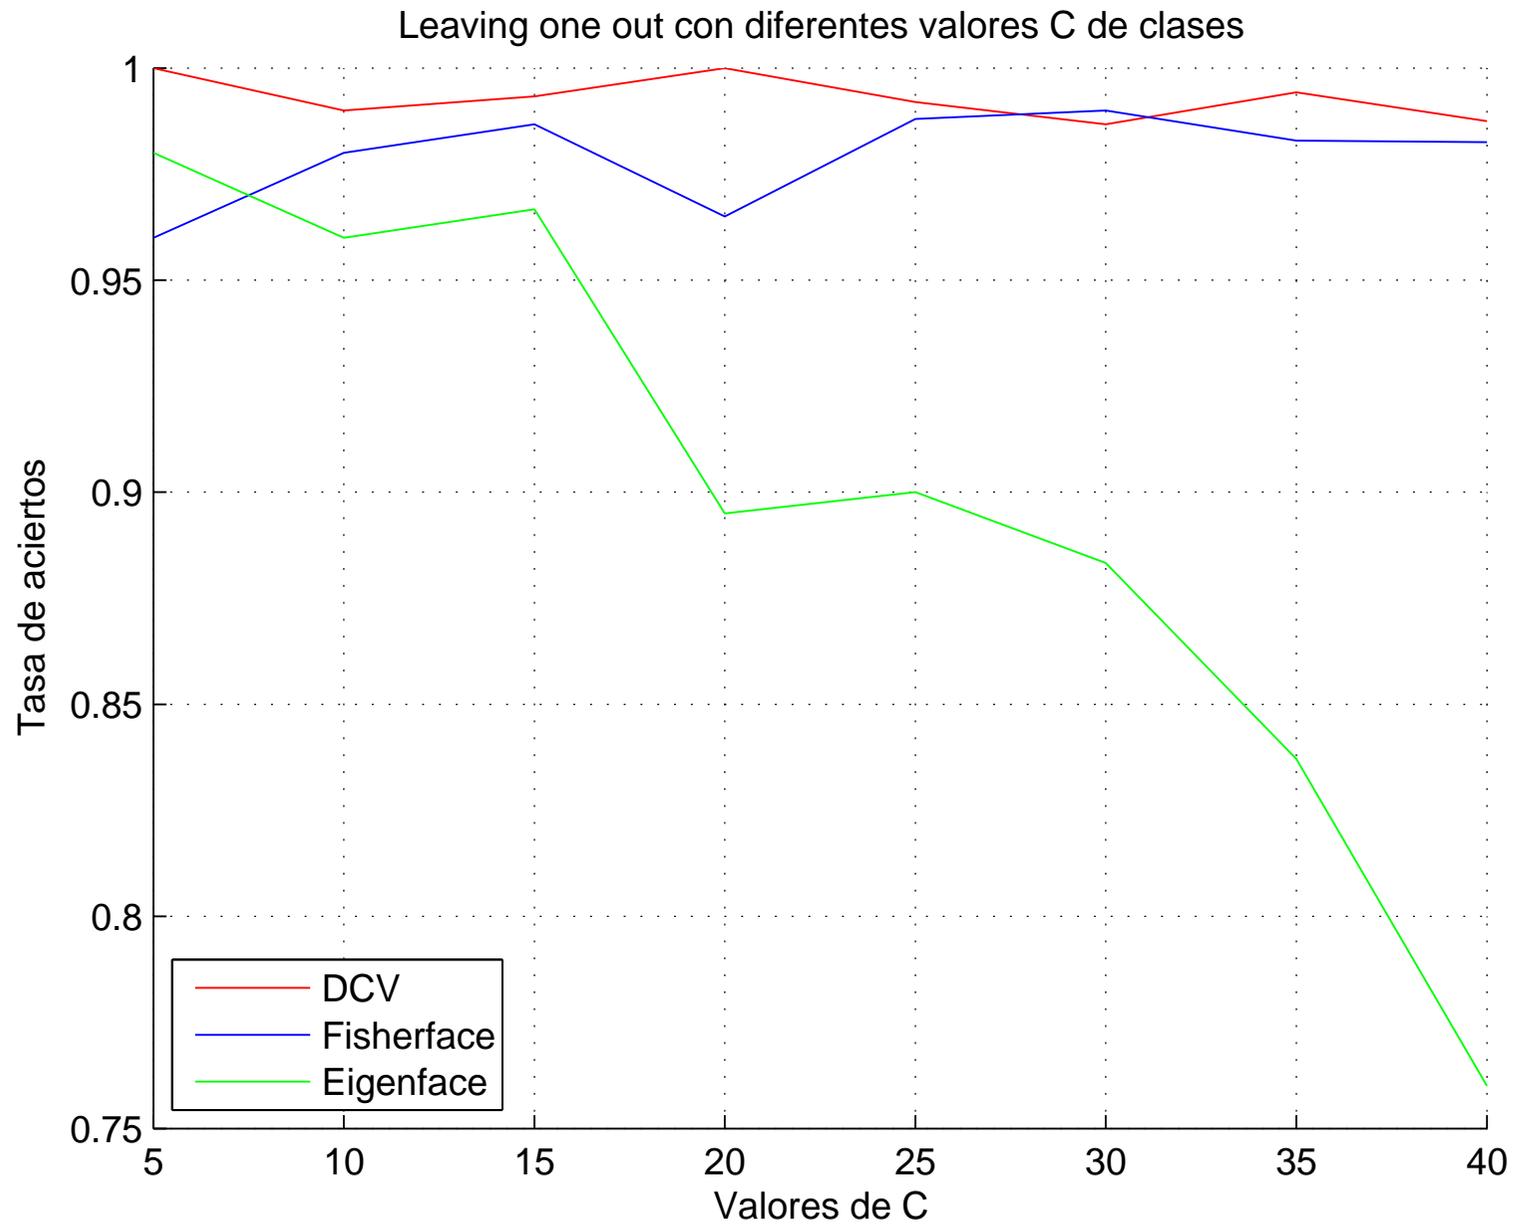
Experimentos



Leaving one out

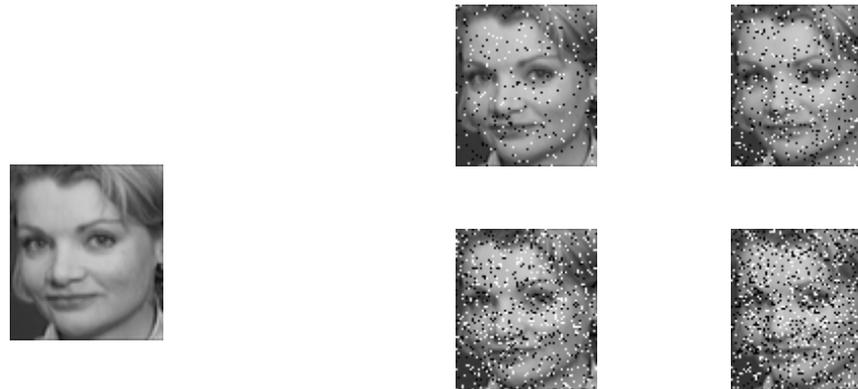
- Base de datos AT&T
- Dimensiones: 80×70
- $d = 5600$
- $C = 40$ individuos (Clases)
- $N = 10$ fotos por individuo
- $M = C \times N = 400$ muestras

Leaving one out



Ruido

Sal y pimienta: Densidad 5 %, 10 %, 15 % y 20 %.

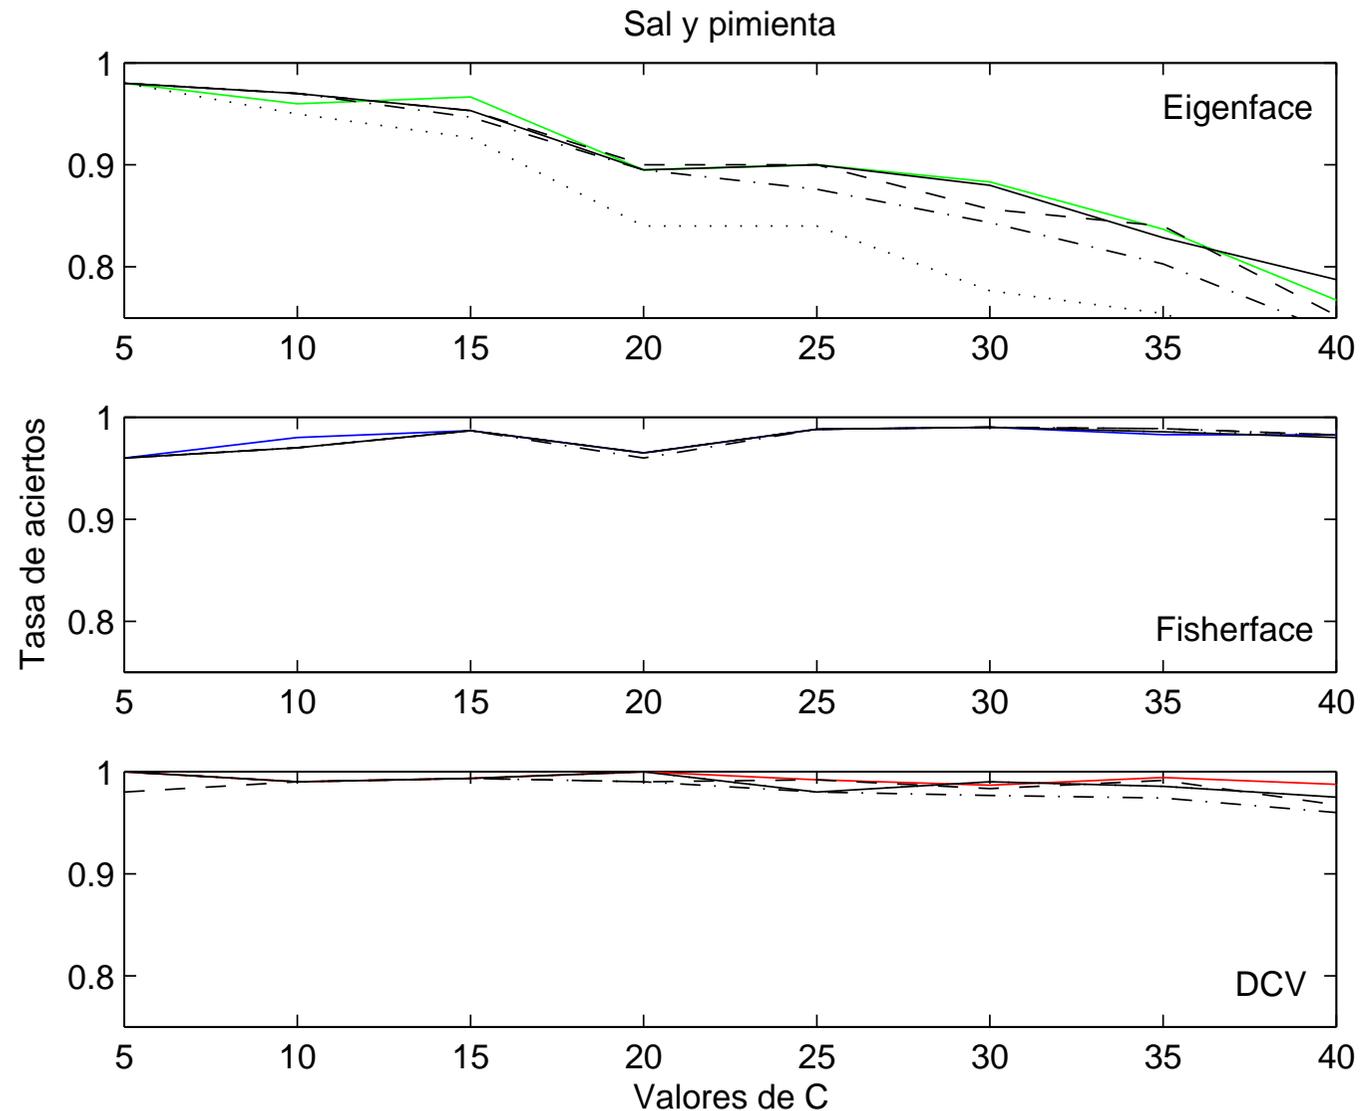


Gaussiana: Media 0 y varianza 0.005, 0.010, 0.015, 0.020 y 0.025.



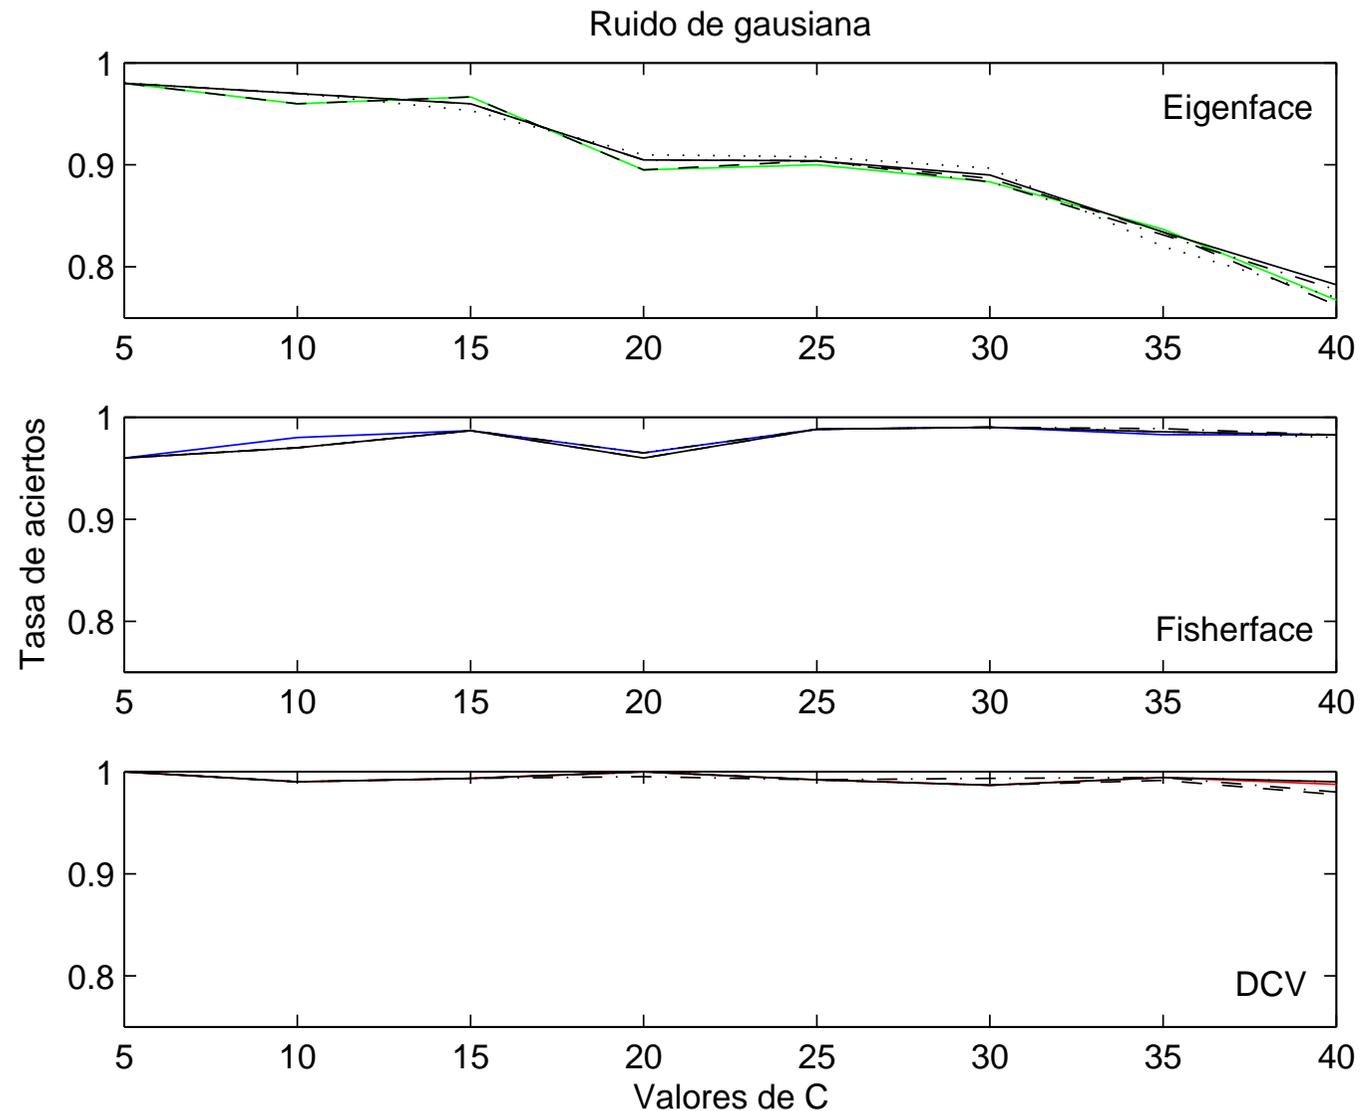
Ruido: *Sal y pimienta*

Eigen sin ruido, **Fisher** sin ruido y **DCV** sin ruido.



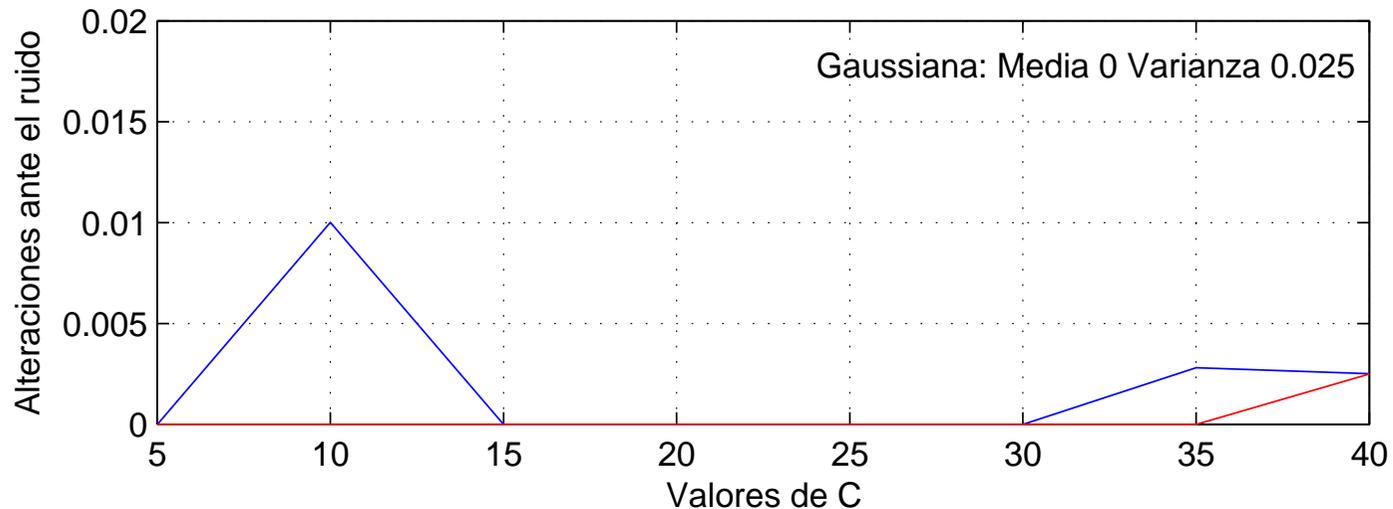
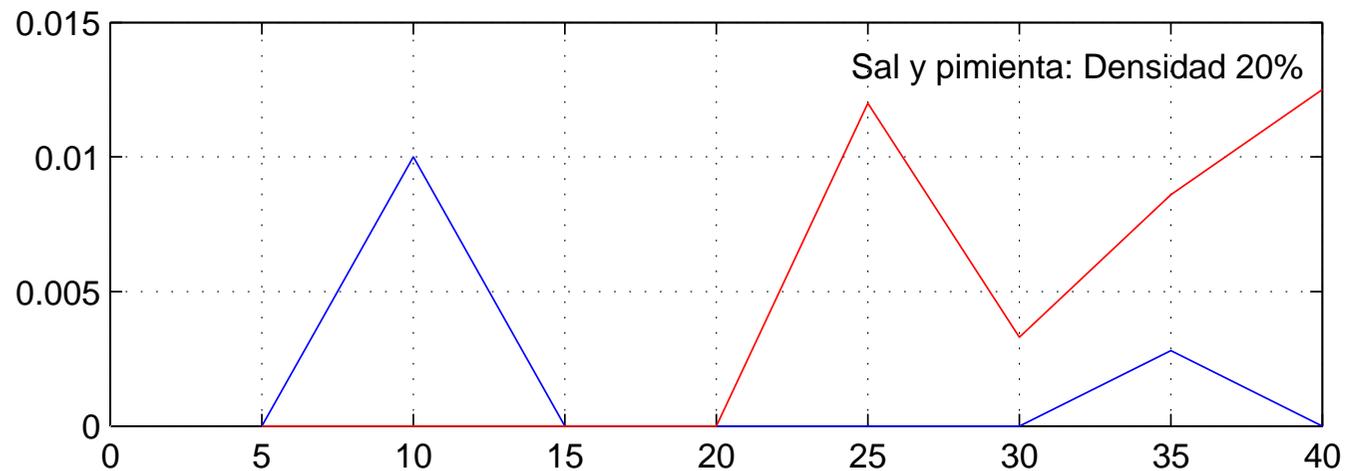
Ruido: *gaussiano* aditivo

Eigen sin ruido, **Fisher** sin ruido y **DCV** sin ruido.



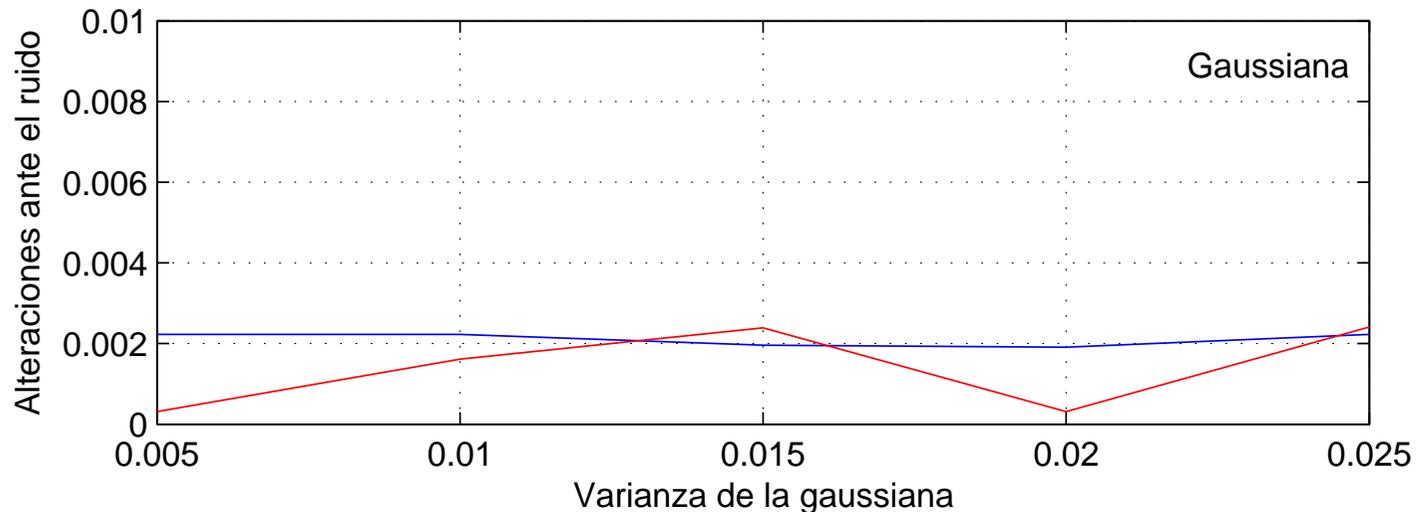
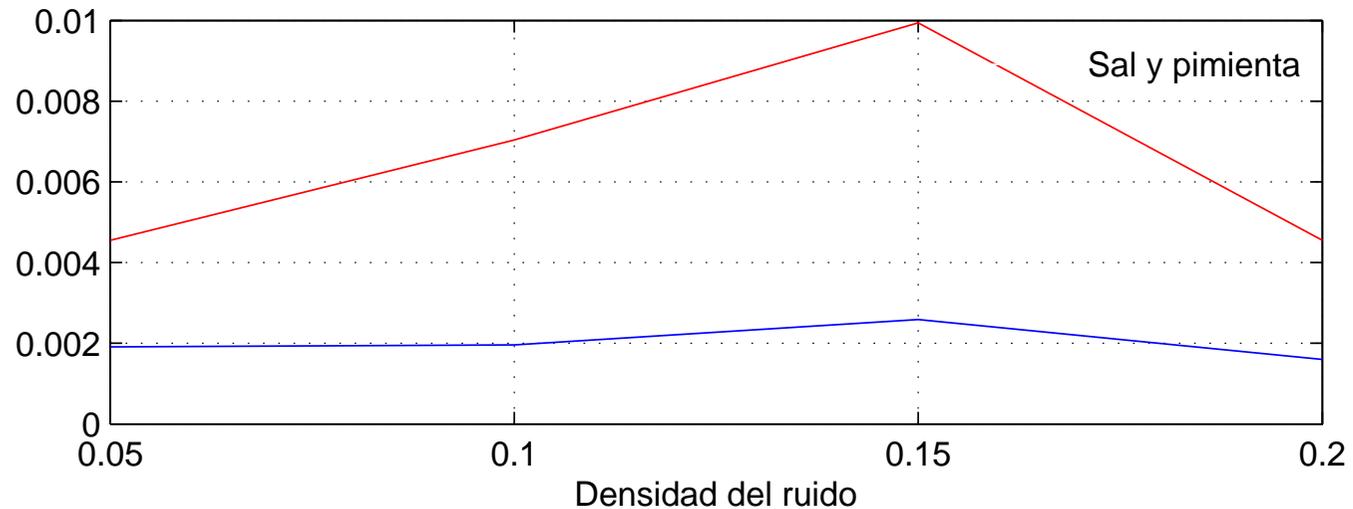
Fisher vs DCV (*sal y pimienta*)

Fisher tasa de aciertos sin ruido menos tasa con ruido.
DCV tasa de aciertos sin ruido menos tasa con ruido.



Fisher vs DCV (*gaussiana*)

Fisher tasa de aciertos sin ruido menos tasa con ruido.
DCV tasa de aciertos sin ruido menos tasa con ruido.



Conclusiones

- Se ha desarrollado, implementado, probado y comparado un clasificador para un problema de alta dimensionalidad.
- Se ha comprobado para leaving one out la superioridad de DCV con respecto a otros métodos y sus altas tasas de reconocimiento.
- Se ha probado este tipo de métodos en condiciones ruidosas, en particular se ha sometido DCV a ruido.
- Los resultados de Fisher en condiciones de ruido de sal y pimienta han sido mejores que los resultados de DCV.
- Se ha iniciado un estudio para caracterizar la capacidad de generalización de DCV.

Futuro

- Comparar el método DCV con CV y con otros métodos.
- Estudiar la implementación para mejorar la eficiencia.
- Implementar el método de DCV en una aplicación real, añadiendo la parte de detección y encuadre.
- Estudiar el diseño de un clasificador que combine DCV y CV.
- Aplicar a otros problemas de clasificación en alta dimensionalidad.

