

# Fundamentos de Aprendizaje Automático y Reconocimiento de Patrones

Actividades en clase: Práctico 6

Graciana Castro, Martín Schmidt, Federico Lecumberry, Guillermo Carbajal


Instituto de Ingeniería Eléctrica

2024

# Temario


- Ejercicio 1: Formulación de C-SVM
- Ejercicio 2: Separando sonidos con características intuitivas
- Ejercicio 3: SVM en un problema de mediana escala multiclase
- Ejercicio 4: Resolviendo SVM con un paquete de optimización

# Support Vector Machines (SVM)




$$\{(\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n)\} \quad \vec{x}_i \in \mathbb{R}^m, y_i \in \{-1, +1\}$$


# Support Vector Machines (SVM)




# Support Vector Machines (SVM)



# Support Vector Machines (SVM)



# Support Vector Machines (SVM)




Decision rule:  $\vec{\omega} \cdot \vec{u} + b \geq 0 \Rightarrow \vec{u} \in \oplus$

# Support Vector Machines (SVM)

- Inner product (dot product) between two vectors

$$\vec{u} \cdot \vec{v} = \langle \vec{u}, \vec{v} \rangle = \vec{u}^T \vec{v} = \vec{v}^T \vec{u} = \sum_i u_i v_i = u_1 v_1 + u_2 v_2 + \cdots + u_m v_m$$

- Geometric interpretation:
  - Angle between vectors
  - Projection



$$\vec{u} \cdot \vec{v} = \|\vec{u}\| \|\vec{v}\| \cos \theta$$




# Support Vector Machines (SVM)

- The regions are defined by

$$\vec{\omega} \cdot \vec{x}_+ + b \geq 0$$

$$\vec{\omega} \cdot \vec{x}_- + b \leq 0$$



# Support Vector Machines (SVM)

- The regions are defined by


$$\vec{\omega} \cdot \vec{x}_+ + b \geq 0$$

$$\vec{\omega} \cdot \vec{x}_- + b \leq 0$$

- Increase the gap to the decision boundary

$$\vec{\omega} \cdot \vec{x}_+ + b \geq 1$$

$$\vec{\omega} \cdot \vec{x}_- + b \leq -1$$



# Support Vector Machines (SVM)

- The regions are defined by

$$\vec{\omega} \cdot \vec{x}_+ + b \geq 0$$

$$\vec{\omega} \cdot \vec{x}_- + b \leq 0$$

- Increase the gap to the decision boundary


$$\vec{\omega} \cdot \vec{x}_+ + b \geq 1$$

$$\vec{\omega} \cdot \vec{x}_- + b \leq -1$$

- Using


$$y_i = \begin{cases} +1 & \vec{x}_+ \in \oplus \\ -1 & \vec{x}_- \in \ominus \end{cases}$$

$$y_i(\vec{\omega} \cdot \vec{x} + b) - 1 \geq 0$$




and the equality holds for the samples in the “gutter” of this “street”

# Support Vector Machines (SVM)



# Support Vector Machines (SVM)



# Support Vector Machines (SVM)

- For these two samples


$$y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0 \quad \Rightarrow \quad \begin{aligned} \vec{\omega} \cdot \vec{x}_+ &= 1 - b \\ \vec{\omega} \cdot \vec{x}_- &= -(1 + b) \end{aligned}$$

- The width of the gap can be computed by

$$\begin{aligned} (\vec{x}_+ - \vec{x}_-) \cdot \frac{\vec{\omega}}{\|\vec{\omega}\|} &= ((1 - b) + (1 + b)) \frac{1}{\|\vec{\omega}\|} \\ &= \frac{2}{\|\vec{\omega}\|} \end{aligned}$$

...and we want it as big as possible.

$$\max \frac{1}{\|\vec{\omega}\|}$$



# Support Vector Machines (SVM)

$$\max \frac{1}{\|\vec{\omega}\|}$$

# Support Vector Machines (SVM)

$$\min \|\vec{\omega}\|$$



# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

- Classical constrained optimisation: Lagrange multipliers!

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

- Classical constrained optimisation: Lagrange multipliers!

$$\mathcal{L} = \frac{1}{2} \|\vec{\omega}\|^2 - \sum_i \lambda_i [y_i(\vec{\omega} \cdot \vec{x} + b) - 1]$$

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

- Classical constrained optimisation: Lagrange multipliers!

$$\mathcal{L} = \frac{1}{2} \|\vec{\omega}\|^2 - \sum_i \lambda_i [y_i(\vec{\omega} \cdot \vec{x} + b) - 1]$$

$$\frac{\partial \mathcal{L}}{\partial \vec{\omega}} = \vec{\omega} - \sum_i \lambda_i y_i \vec{x}_i = 0 \Rightarrow \vec{\omega}^* = \sum_i \lambda_i y_i \vec{x}_i$$

$$\frac{\partial \mathcal{L}}{\partial b} = \sum_i \lambda_i y_i = 0$$

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

- Classical constrained optimisation: Lagrange multipliers!

$$\mathcal{L} = \frac{1}{2} \|\vec{\omega}\|^2 - \sum_i \lambda_i [y_i(\vec{\omega} \cdot \vec{x} + b) - 1]$$

$$\frac{\partial \mathcal{L}}{\partial \vec{\omega}} = \vec{\omega} - \sum_i \lambda_i y_i \vec{x}_i = 0 \Rightarrow \vec{\omega}^* = \sum_i \lambda_i y_i \vec{x}_i$$

$$\frac{\partial \mathcal{L}}{\partial b} = \sum_i \lambda_i y_i = 0$$

# Support Vector Machines (SVM)

$$\min \frac{1}{2} \|\vec{\omega}\|^2$$

With some constraints  $y_i(\vec{\omega} \cdot \vec{x} + b) - 1 = 0$

- Classical constrained optimisation: Lagrange multipliers!

$$\mathcal{L} = \frac{1}{2} \|\vec{\omega}\|^2 - \sum_i \lambda_i [y_i(\vec{\omega} \cdot \vec{x} + b) - 1]$$

$$\frac{\partial \mathcal{L}}{\partial \vec{\omega}} = \vec{\omega} - \sum_i \lambda_i y_i \vec{x}_i = 0 \Rightarrow \vec{\omega}^* = \sum_i \lambda_i y_i \vec{x}_i$$

$$\frac{\partial \mathcal{L}}{\partial b} = \sum_i \lambda_i y_i = 0$$

- The optimal  $\vec{\omega}^*$  (hyperplane) is a linear combination of some ( $\lambda_i \neq 0$ ) of the sample vectors (the *support vectors*).

# Temario

- Ejercicio 1: Formulación de C-SVM
- Ejercicio 2: Separando sonidos con características intuitivas
- Ejercicio 3: SVM en un problema de mediana escala multiclase
- Ejercicio 4: Resolviendo SVM con un paquete de optimización

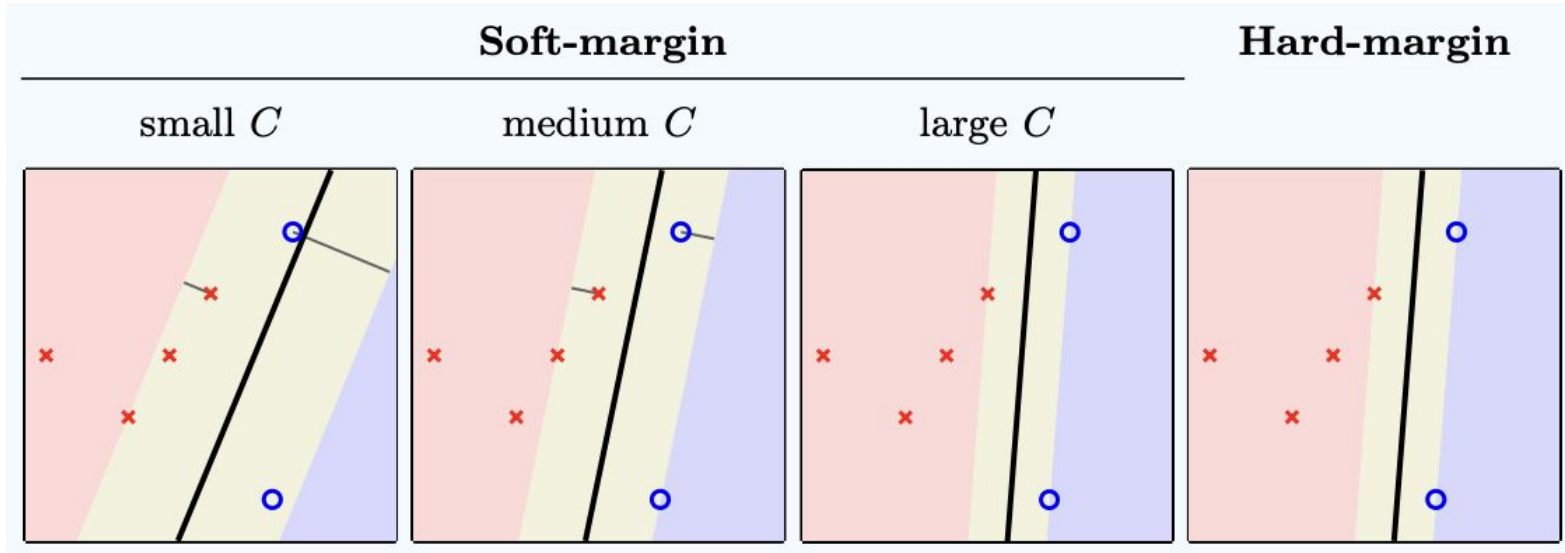


## Ejercicio 1: formulación de C-SVM

El algoritmo C-SVM da lugar al siguiente problema de optimización:

$$\left\{ \begin{array}{l} \min_{\mathbf{w}, b, \xi} \\ \text{sujeto a} \end{array} \right. \quad f(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \longrightarrow \text{margin violation}$$
$$\left\{ \begin{array}{l} y_n (\mathbf{w}^T \Phi(x_n) + b) \geq 1 - \xi_n \quad \forall n = 1, \dots, N \\ \xi_n \geq 0 \end{array} \right.$$

# Ejercicio 1: formulación de C-SVM



## Ejercicio 1: formulación de C-SVM

El algoritmo C-SVM da lugar al siguiente problema de optimización:

$$\left\{ \begin{array}{l} \min_{\mathbf{w}, b, \xi} \quad f(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \\ \text{sujeto a} \\ y_n (\mathbf{w}^T \Phi(x_n) + b) \geq 1 - \xi_n \quad \forall n = 1, \dots, N \\ \xi_n \geq 0 \end{array} \right.$$

### Parte (1a)

Escribir el Lagrangiano del problema.

$$\mathcal{L}(\mathbf{w}, b, \xi, \alpha, \beta) = \dots$$

## Ejercicio 1: formulación de C-SVM

El algoritmo C-SVM da lugar al siguiente problema de optimización:

$$\left\{ \begin{array}{l} \min_{\mathbf{w}, b, \xi} \quad f(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \\ \text{sujeto a} \\ y_n (\mathbf{w}^T \Phi(x_n) + b) \geq 1 - \xi_n \quad \forall n = 1, \dots, N \\ \xi_n \geq 0 \end{array} \right.$$

### Parte (1a)

Escribir el Lagrangiano del problema.

$$\mathcal{L}(\mathbf{w}, b, \xi, \alpha, \beta) = \frac{1}{2} \|\mathbf{w}\|^2 + \sum_n C \xi_n - \sum_n \alpha_i [y_n (\mathbf{w}^T \Phi(\mathbf{x}_n) + b) - 1 + \xi_n] - \sum_n \beta_n \xi_n$$

con  $\alpha_i, \beta_i \geq 0$

## Ejercicio 1: formulación de C-SVM

El algoritmo C-SVM da lugar al siguiente problema de optimización:

$$\left\{ \begin{array}{l} \min_{\mathbf{w}, b, \xi} \quad f(\mathbf{w}, \xi) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n \\ \text{sujeto a} \\ y_n (\mathbf{w}^T \Phi(x_n) + b) \geq 1 - \xi_n \quad \forall n = 1, \dots, N \\ \xi_n \geq 0 \end{array} \right.$$

### Parte (1a)

Escribir el Lagrangiano del problema.

$$\mathcal{L}(\mathbf{w}, b, \xi, \alpha, \beta) = \dots$$

### Parte (1b)

Argumentar que el valor del Lagrangiano  $\mathcal{L}$  está acotado superiormente por la función de costo original  $f$ .

## Ejercicio 1: formulación de C-SVM

Se define la función

$$\theta_{\mathcal{P}}(\mathbf{w}, b, \boldsymbol{\xi}) = \max_{\boldsymbol{\alpha}, \boldsymbol{\beta}; \alpha_n \geq 0, \beta_n \geq 0} \mathcal{L}(\mathbf{w}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}, \boldsymbol{\beta})$$

### Parte (1c)

Argumentar que resolver

$$\min_{\mathbf{w}, b, \boldsymbol{\xi}} \theta_{\mathcal{P}}(\mathbf{w}, b, \boldsymbol{\xi})$$

es equivalente a encontrar el mínimo de  $f(\mathbf{w}, \boldsymbol{\xi})$   
con las restricciones del problema.

## Ejercicio 1: formulación de C-SVM

Se define ahora la función *dual*

$$\theta_{\mathcal{D}}(\boldsymbol{\alpha}, \beta) = \min_{\mathbf{w}, b, \boldsymbol{\xi}} \mathcal{L}(\mathbf{w}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}, \beta)$$

En general se cumple para el óptimo del problema dual  $d^*$  que

$$d^* = \max_{\boldsymbol{\alpha}, \beta} \theta_{\mathcal{D}}(\boldsymbol{\alpha}, \beta) \leq \min_{\mathbf{w}, b, \boldsymbol{\xi}} \theta_{\mathcal{P}}(\mathbf{w}, b, \boldsymbol{\xi}) = p^*$$

(*dual gap*)

### Parte (1d)

Mostrar que el problema dual puede escribirse como

$$\left\{ \begin{array}{l} \min_{\boldsymbol{\alpha}} \quad \frac{1}{2} \boldsymbol{\alpha}^T \mathbf{Q} \boldsymbol{\alpha} - \mathbf{1}^T \boldsymbol{\alpha} \\ \text{sujeto a} \\ 0 \leq \alpha_n \leq C \\ \sum_n \alpha_n y_n = 0 \end{array} \right.$$

con  $Q_{ij} = y_i y_j K(x_i, x_j)$

# Temario

- Ejercicio 1: Formulación de C-SVM
- Ejercicio 2: Separando sonidos con características intuitivas
- Ejercicio 3: SVM en un problema de mediana escala multiclase
- Ejercicio 4: Resolviendo SVM con un paquete de optimización




## Ejercicio 2: separando sonidos con características intuitivas

En los ejercicios 2 y 3 de este práctico se trabajará con la base de datos **Urban Sound**. Los sonidos pertenecientes a las siguientes 10 categorías:


1. aire acondicionado (air\_conditioner)
2. bocina de auto (car\_horn)
3. niños jugando (children\_playing)
4. ladrido de perros (dog\_bark)
5. taladrado (drilling)
6. motor moderando (engine\_idling)
7. disparo de arma de fuego (gun\_shot)
8. martillo neumático (jackhammer)
9. sirena (siren)
10. música callejera (street\_music)

## Ejercicio 2: separando sonidos con características intuitivas

Audio Original - Desconocido



4 segundos




Fragmento - Conocido

car\_horn

Etiqueta


## Ejercicio 2: separando sonidos con características intuitivas

Audio Original - Desconocido



2 segundos

4 segundos



car\_horn


Fragmento - Conocido

Etiqueta

## Ejercicio 2: separando sonidos con características intuitivas

Cada fragmento se divide en ventanas solapadas en un 50% de 2048 muestras y para cada ventana se calculan las siguientes características:


- **ZCR** (Zero-Crossing-Rate): la cantidad de cruces por cero de las muestras de la señal.
- **RMS** (Root-Mean-Square): la raíz del valor cuadrático medio de las muestras de la señal, también conocida como medida de la energía de la señal.



$$x_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$$

## Ejercicio 2: separando sonidos con características intuitivas

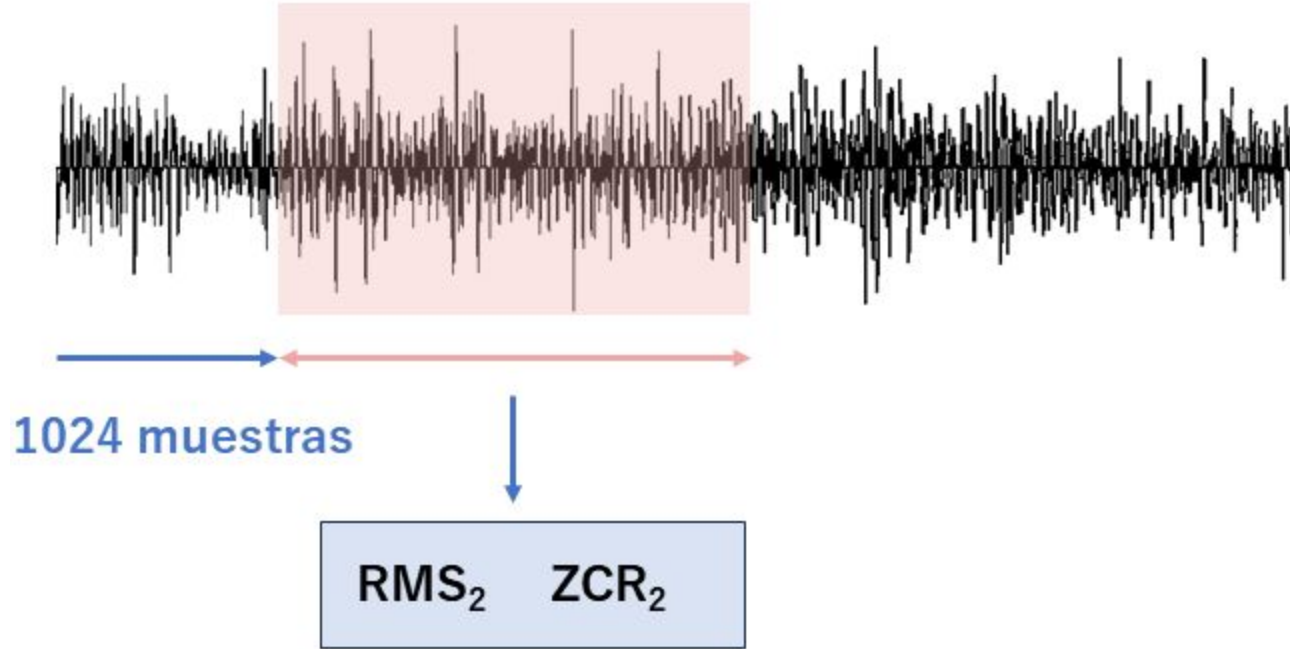
Fragmento – Conocido (4s)



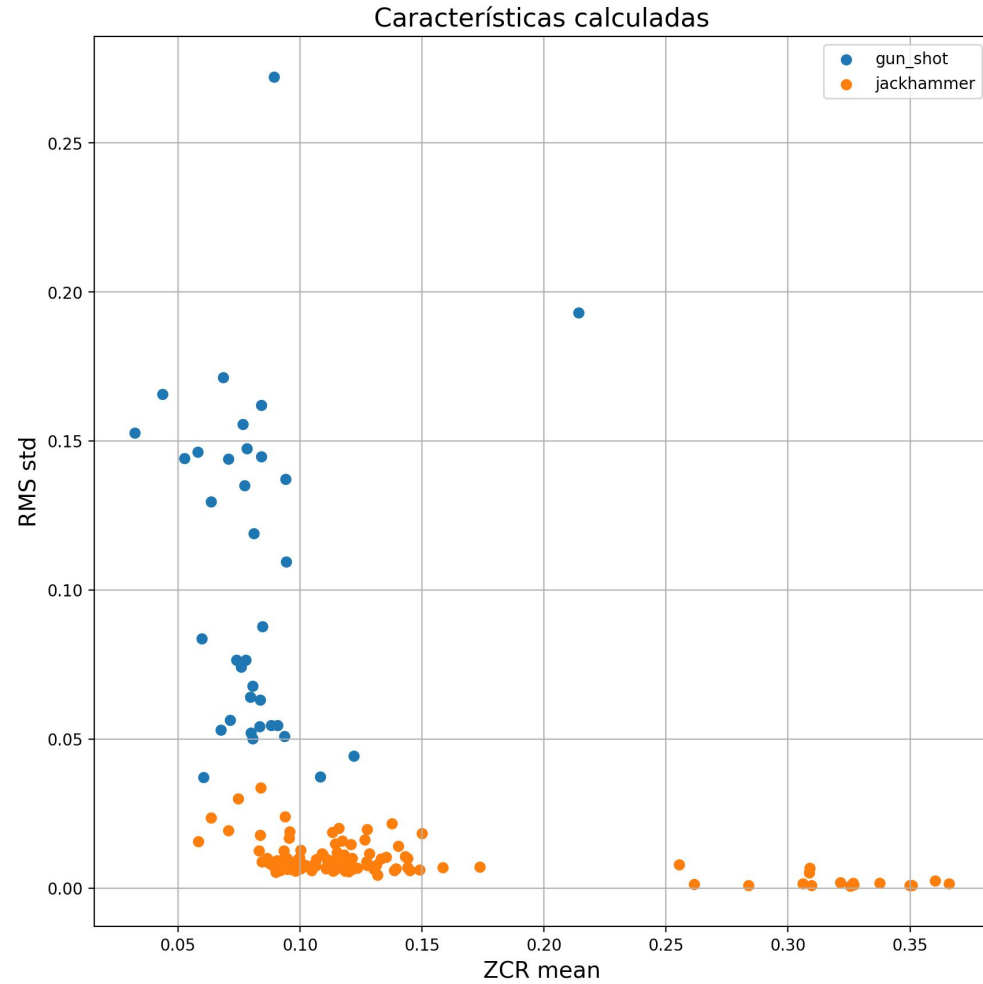
RMS<sub>1</sub> ZCR<sub>1</sub>

## Ejercicio 2: separando sonidos con características intuitivas


Fragmento – Conocido (4s)



## Ejercicio 2: separando sonidos con características intuitivas




## Ejercicio 2: separando sonidos con características intuitivas



Efecto de  $C$  en la solución.  
 $C = 1$




## Ejercicio 2: separando sonidos con características intuitivas



Efecto de C en la solución.


C = 0.1

## Ejercicio 2: separando sonidos con características intuitivas




Efecto de  $C$  en la solución.  
 $C = 10$

## Ejercicio 2: separando sonidos con características intuitivas



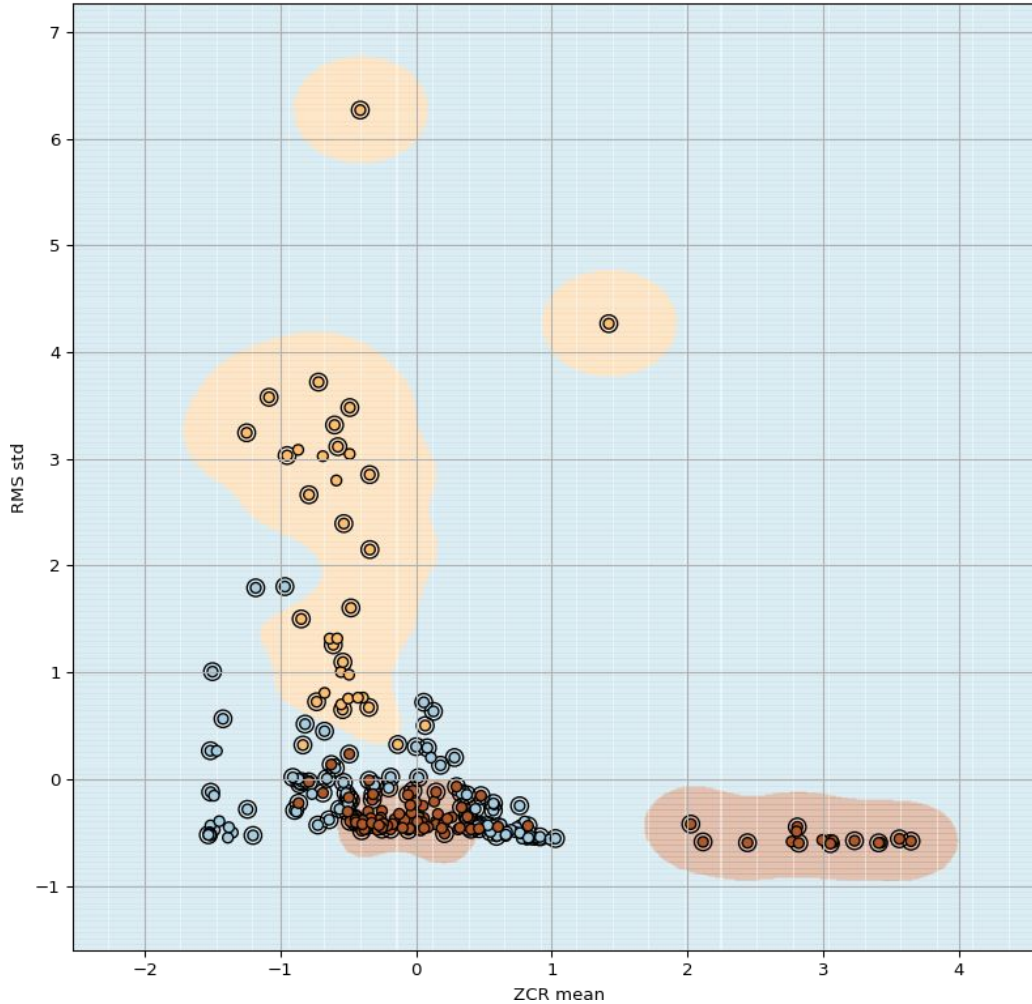
Efecto de  $\gamma$  en la solución.  
 $\gamma = 1$

## Ejercicio 2: separando sonidos con características intuitivas



Efecto de  $\gamma$  en la solución.  
 $\gamma = 0.1$

## Ejercicio 2: separando sonidos con características intuitivas



Efecto de  $\gamma$  en la solución.  
 $\gamma = 10$

## Ejercicio 2: clasificación multiclase en SVM

Dos alternativas principales

### 1. *Uno contra todos*

- se construye un clasificador por clase, etiquetando como positivas las muestras de la clase y negativas el resto
- muy interpretable
- para clasificar la muestra se elige la clase que haya dado positiva con mayor conanza (o probabilidad)

### 2. *Uno contra uno*

- se construye un clasificador por cada par de clases
- para clasificar una muestra se elige la clase que recibió mayor cantidad de votos
- como se construyen  $n(n - 1)/2$  clasificadores suele ser más lento en tiempo de ejecución.
- menos sensible al desbalance de clases.

La implementación SVC de scikit-learn utiliza por defecto uno contra uno

## Ejercicio 2: clasificación multiclase en SVM, kernels

kernel 'linear':  $\langle x, x' \rangle$

- un único parámetro C
- controla el compromiso entre minimizar el error de clasificación con el conjunto de entrenamiento y obtener una superficie de decisión simple.
- un C pequeño favorece las superficies de decisiones suaves mientras que un C grande penaliza fuertemente los errores de entrenamiento

kernel 'rbf':  $\exp(-\gamma\|x - x'\|^2)$

- los parámetros son C y  $\gamma$ .
- la interpretación de C es similar al kernel 'lineal'
- $\gamma$  define la influencia que tiene una muestra de entrenamiento.
- cuanto más grande es  $\gamma$  más rápido se desvanece la influencia de una muestra sobre las demás

## Cuestionario práctico

passwd: 9837




# Temario

- Ejercicio 1: Formulación de C-SVM
- Ejercicio 2: Separando sonidos con características intuitivas
- Ejercicio 3: SVM en un problema de mediana escala multiclase
- Ejercicio 4: Resolviendo SVM con un paquete de optimización


## Ejercicio 3: SVM en un problema de mediana escala multiclase

- Se construirá un clasificador SVM para separar las 10 clases de la base *Urban Sound*
- El conjunto de datos original se lo dividió en:
  - 6 *folds* para entrenamiento
  - 2 *folds* para validación
  - 2 *folds* para test (nos reservamos las etiquetas)
- Como características se utilizarán estadísticas calculadas sobre los coeficientes *MFCC*.


MFCC del martillo neumático



MFCC del disparo de arma de fuego




## Ejercicio 3: Cálculo de los coeficientes MFCC




## Ejercicio 3: Propuesta

- Entrenar un clasificador SVM por defecto
- Evaluar el desempeño en el **conjunto de entrenamiento** y en el **conjunto de validación**
- Estimar el desempeño del clasificador utilizando **validación cruzada**.
  - *6 folds* por defecto
  - *6 folds* con *ShuffleSplit*
  - *6 folds* con *PredefinedSplit*
- Optimizar los parámetros del clasificador utilizando *GridSearch*

# Ejercicio 3: matriz de confusión (kernel lineal)



# Ejercicio 3: matriz de confusión (kernel RBF)



# Temario

- Ejercicio 1: Formulación de C-SVM
- Ejercicio 2: Separando sonidos con características intuitivas
- Ejercicio 3: SVM en un problema de mediana escala multiclase
- Ejercicio 4: Resolviendo SVM con un paquete de optimización

## Ejercicio 4: Resolviendo SVM con un paquete de optimización

El algoritmo SVM con *kernel lineal* resuelve el siguiente problema de optimización:

$$\left\{ \begin{array}{l} \min_{\mathbf{w}, b} \quad f(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{sujeto a} \\ y_n (\mathbf{w}^T \mathbf{x}_n + b) \geq 1 \\ \forall n = 1, \dots, N \end{array} \right.$$

En su formulación dual da lugar a la optimización

$$\left\{ \begin{array}{l} \min_{\alpha} \quad \frac{1}{2} \alpha^T \mathbf{Q} \alpha - \mathbf{e}^T \alpha \\ \text{sujeto a} \\ \alpha_i \geq 0 \\ \sum_i \alpha_i y_i = 0 \end{array} \right.$$

con  $Q_{ij} = y_i y_j \mathbf{x}_i^T \mathbf{x}_j$



## Ejercicio 4: Resolviendo SVM con un paquete de optimización

Se puede encontrar  $\alpha$  utilizando el paquete *scipy.optimize*.

Una vez encontrado  $\alpha$  se encuentran los parámetros del modelo SVM:  $\mathbf{w}$ ,  $\mathbf{b}$ , *vectores de soporte*

### Sequential Least Squares Programming (SLSQP) Algorithm (`method= 'SLSQP'`)

The SLSQP method deals with constrained minimization problems of the form:

$$\begin{aligned} \min_x \quad & f(x) \\ \text{subject to:} \quad & c_j(x) = 0, \quad j \in \mathcal{E} \\ & c_j(x) \geq 0, \quad j \in \mathcal{I} \\ & \text{lb}_i \leq x_i \leq \text{ub}_i, \quad i = 1, \dots, N. \end{aligned}$$

Where  $\mathcal{E}$  or  $\mathcal{I}$  are sets of indices containing equality and inequality constraints.