

# Analysis of transient states in EMG signals with applications to robotic prostheses

Martina Giacobbe

Università di Bologna

23 Marzo 2018

Relatrice: Prof.ssa Giovanna Citti

Correlatori: Prof. Davide Barbieri

Dott. Emre Baspinar

Ing. Emanuele Gruppioni




# Obiettivo della tesi

**Oggetto di studio:** Segnale EMG, ovvero la manifestazione elettrica di un'attivazione neuromuscolare associata ad una contrazione muscolare.

⇒ In particolare siamo interessati allo *stato transiente* del segnale.

**Obiettivo:** Ottimizzare i tempi di risposta del controllo protesico per amputati transradiali.



# Principal component analysis

Dati  $T$  campioni di un vettore random  $x = (x_1, \dots, x_n)$  di componenti correlate tale che  $E[x] = 0$ , definiamo

$$y_1 = \sum_{k=1}^N w_{k1} x_k = w_1^T x$$

è detta prima componente principale di  $x$  se  $\text{Var}(y_1)$  è massima.

**Obiettivo:** Massimizzare

$$J(w_1) = \text{var}(y_1) = w_1^T C_x w_1$$

sotto il vincolo  $\|w_1\| = 1$ .

Si ottiene  $w_1 = e_1 \Rightarrow y_1 = e_1^T x$  prima componente principale.

**Generalizzando:** se  $y_m = m$ -esima componente principale  $\Rightarrow$  la condizione di scorrelazione con le componenti principali precedenti porta ad un problema di ottimizzazione analogo al precedente in  $\text{span}\{e_1, \dots, e_{m-1}\}^\perp$

$$w_m = e_m \Rightarrow y_m = e_m^T x$$



# Principal component analysis

## Osservazione

Massimizzare  $\text{Var}(y_1)$   $\Leftrightarrow$  Minimizzare il MSE tra  $x$  e  $\bar{x}$

ove  $\bar{x} = \sum_{i=1}^M (w_i^T x) w_i$ .

Infatti

$$J_{MSE} = E[\|x - \bar{x}\|^2] = \sum_{i=M+1}^N w_i C_x w_i \Rightarrow J_{MSE} = \sum_{i=M+1}^N \lambda_i$$

affinché  $J_{MSE}$  sia minimizzato  $\lambda_{M+1}, \dots, \lambda_N$  devono essere gli autovalori più piccoli.  $\Rightarrow x$  viene proiettato nello spazio generato da  $e_1, \dots, e_m$ . Dunque:

$$w_i = e_i \quad e \quad \text{Var}(y_i) = E[e_i^T x x^T e_i] = d_i.$$



# Support vector machine: caso linearmente separabile

$\{(x_i, d_i)\}$  training set, ove  $x_i$  campione e  $d_i = \pm 1$  etichetta.

**Obiettivo:** Trovare  $w_o$  vettore dei pesi e  $b_o$  bias affinché l'iperpiano

$$w_o^T x_i + b_o = 0$$

massimizzi il margine di separazione  $\rho$ , ove  $\rho$  rappresenta la distanza tra l'iperpiano e il punto del dataset più vicino. La separabilità lineare si riassume con la condizione

$$d_i(w_o^T x_i + b_o) \geq 1 \quad \text{per } i = 1, \dots, N \quad (1)$$

I punti del dataset che soddisfano (1) con l'uguaglianza sono detti *support vectors*.



# Support vector machine: caso linearmente separabile

Definisco  $g(x) = w_o^T x + b_o$  e riscrivo  $x = x_p + r \frac{w_o}{\|w_o\|}$ , ove  $x_p$  è la proiezione ortogonale di  $x$  sull'iperpiano. Usando  $g(x_p) = 0$  si ottiene

$$g(x) = w_o^T x + b_o = w_o^T \left( x_p + r \frac{w_o}{\|w_o\|} \right) + b_o = r \|w_o\|$$

$$\Rightarrow r = \frac{g(x)}{\|w_o\|}$$

Chiamo  $x^{(s)}$  un *support vector* con etichetta  $d^{(s)}$ , vale  $g(x^{(s)}) = w_o^T x^{(s)} + b_o = \pm 1$ , per  $d^{(s)} = \pm 1$ . Dunque

$$r = \frac{g(x^{(s)})}{\|w_o\|} = f(n) = \begin{cases} \frac{1}{\|w_o\|} & \text{if } d^{(s)} = +1 \\ -\frac{1}{\|w_o\|} & \text{if } d^{(s)} = -1. \end{cases}$$

Infine  $\rho = 2r = \frac{2}{\|w_o\|}$ .

## Osservazione

Massimizzare  $\rho \Leftrightarrow$  Minimizzare  $\|w_o\|$



# Support vector machine: caso linearmente separabile

## Teorema (Problema primario)

Dato il training set  $\{(x_i, d_i)\}$ , il problema primario si occupa di trovare i valori di ottimo di  $w$  e  $b$  tali che soddisfino il vincolo  $d_i(w^T x_i + b) \geq 1$  e  $w$  minimizzi  $\phi(w) = \frac{1}{2} w^T w$ .

## Teorema (Problema duale)

Dato il training set  $\{(x_i, d_i)\}$ , il problema duale si occupa di trovare i valori di ottimo dei moltiplicatori di Lagrange  $\{\alpha_i\}_{i=1}^N$  tali che soddisfino i vincoli  $\sum_{i=1}^N \alpha_i d_i = 0$  e  $\alpha_i \geq 0, \forall i = 1, \dots, N$  e massimizzino  $Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j x_i^T x_j$

$$\Rightarrow w_o = \sum_{i=1}^{N_s} \alpha_{o,i} d_i x_i$$

$$\Rightarrow b_o = 1 - w_o^T x^{(s)} = 1 - \sum_{i=1}^{N_s} \alpha_{o,i} d_i x_i^T x^{(s)} \quad \text{con } d^{(s)} = 1$$



# Support vector machine: caso non linearmente separabile

## Definizione

Il margine di separazione  $\rho$  è detto essere soft se almeno un punto del dataset  $(x_i, d_i)$  non soddisfa

$$d_i(w^T x_i + b) \geq 1 \quad \text{for } i = 1, \dots, N.$$

Si introducono delle variabili di slack  $\{\xi_i\}_{i=1}^N$ , tali che

$$d_i(w^T x_i + b) \geq 1 - \xi_i \quad i = 1, \dots, N. \quad (2)$$

$0 < \xi_i \leq 1 \Rightarrow$  classificazione corretta

$\xi_i > 1 \Rightarrow$  classificazione errata

## Teorema (Problema primario)

*Dato il training set  $\{(x_i, d_i)\}$ , il problema primario si occupa di trovare i valori di ottimo  $w_o$  e  $b_o$  tali che soddisfino il vincolo in (2) e  $\xi_i \geq 0, \forall i$ , inoltre le variabili di slack  $\{\xi_i\}_{i=1}^N$  e  $w$  minimizzino la funzione*

$$\Phi(w, \xi) = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i$$



# SVM come kernel machine

Sia  $x$  vettore nello spazio di input di dimensione  $m_0$ , sia poi  $\{\phi_j(x)\}_{j=1}^{\infty}$  un setting di funzioni non lineari. Attuando tale trasformazione, l'equazione dell'iperpiano diventa

$$\sum_{j=1}^{\infty} w_j \phi_j(x) = 0 \quad \Leftrightarrow \quad w^T \phi(x) = 0,$$

ove  $\{w_j\}_{j=1}^{\infty}$  setting di pesi.

Adattando la soluzione del problema primario al nostro caso si ha  $w = \sum_{i=1}^{N_s} \alpha_i d_i \Phi(x_i)$


$$\Rightarrow \sum_{i=1}^{N_s} \alpha_i d_i \Phi^T(x_i) \Phi(x) = 0.$$

Si definisce

$$k(x, x_i) = \Phi^T(x_i) \Phi(x) = \sum_{j=1}^{\infty} \phi_j(x_i) \phi_j(x) \quad \text{per } i = 1, \dots, N_s$$



# Registrazione del segnale



**Registrazione del segnale:**  $P = 5$ ,  $R = 10$ ,  $T = 4s$ ,  $Fr = 500Hz$

Ripetizione: matrice  $T \cdot Fr \times 6 \rightarrow 2000 \times 6$

Campione: vettore  $1 \times 6$

Dataset: matrice  $P \cdot R \cdot Fr \cdot T \times 6$



# Eliminazione dei picchi

## Definizione

Un valore discreto del segnale all'istante  $t$  è detto un picco se la differenza tra il valore discreto in  $t$  e il valore discreto in  $t - 1$  è maggiore di  $10^4$ .

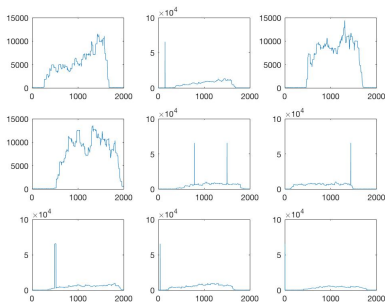


Figura: Posa 1, sensore 1, rappresentazione al variare delle ripetizioni.



# Preprocessamento del segnale

Calcoliamo le soglie di riposo di ogni sensore

$$TH = [79, 149, 103, 818, 190, 363].$$

**Pose 1,2,3,4:** Enumero le ripetizioni e salvo l'indice temporale di troncamento in un vettore  $D$   $40 \times 1 \Rightarrow$  estraggo  $\max(D)$ .

Ridimensiono una ripetizione  $Datum_i$   $2000 \times 6$  con troncamento all'istante  $D(i)$

Se  $D(i) = \max(D) \Rightarrow Datum_i = Datum_i(\max(D) : end - 1, :)$

Altrimenti  $\Rightarrow Datum_i = Datum_i(D(i) : end - \max(D) + D(i) - 1, :)$

**Posa 5:** Una ripetizione  $Datum_{rest}$   $2000 \times 6$  viene ridimensionata come

$$Datum_{rest} = Datum_{rest}(1 : end - \max(D), :)$$



# Preprocessamento del segnale

Le nuove dimensioni per ogni ripetizione sono  $1471 \times 6$ .




Figura: Posa 1, ripetizione 3, segnale preprocessato nei 6 sensori.



# Riduzione della dimensionalità

Osservando gli autovalori della matrice di covarianza del dataset

$$EIG = [2.67 \cdot 10^7, 2.79 \cdot 10^6, 9.61 \cdot 10^5, 3.90 \cdot 10^5, 1.4 \cdot 10^5, 9.73 \cdot 10^{-24}]$$

ricaviamo l'informazione totale

$$\text{Tot} = \sum_{i=1}^6 EIG(i).$$

L'informazione di ogni componente principale si ricava

$$\text{Tot} : 100 = EIG(i) : \text{information}(i) \quad i=1, \dots, 6.$$


$$\Rightarrow \text{information} = [0.86, 0.09, 0.031, 0.012, 0.0045, 3.14 \cdot 10^{-31}].$$



# Riduzione della dimensionalità

Siano  $y_1$  e  $y_2$  le prime due componenti principali

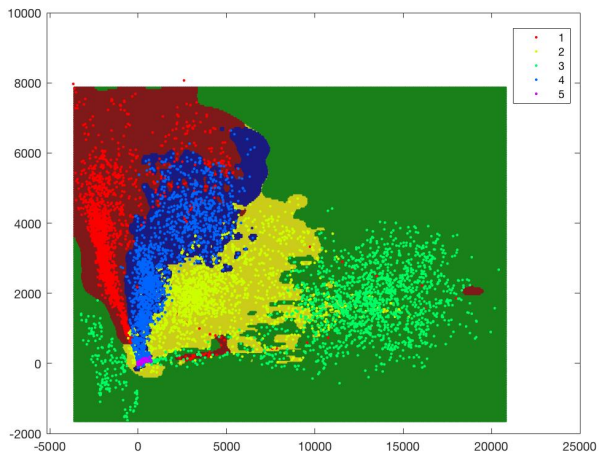
$\text{span}\{y_1, y_2\} \Rightarrow 95\%$  di Tot (informazione totale).



# Classificazione: primo approccio

**Algoritmo:** SVM con kernel gaussiano

⇒ **Randomizzazione del dataset**





## Classificazione: primo approccio

$pos = [4903, 4614, 5032, 4461, 4400],$

$falspos = [72, 310, 251, 229, 801],$

$falsneg = [217, 587, 140, 633, 23].$

$$acc(i) = \frac{pos(i)}{pos(i) + falspos(i) + falsneg(i)} \quad i = 1, \dots, 5.$$


class	accuracy
1	94%
2	84%
3	93%
4	84%
5	84%



# Classificazione: secondo approccio

⇒ **Struttura matriciale delle ripetizioni viene mantenuta**

	1st interval	2nd interval	3rd interval	4th interval
gesture 1	6 (7%)	64 (80%)	80 (100%)	80(100%)
gesture 2	34 (43%)	13 (16%)	0	0
gesture 3	0	0	0	0
gesture 4	0	0	0	0
gesture 5	40 (50%)	3 (4%)	0	0
voting	abstension	1	1	1



## Classificazione: secondo approccio

Fissata una posa, considero le  $\binom{10}{6} = 210$  combinazioni di 10 elementi presi 6 alla volta (analoghe combinazioni per le altre pose).

- In ognuno di questi 210 casi seleziono le ripetizioni per il training, le complementari 4 sono usate per il test.
- Addestro il classificatore 210 volte e predico i risultati.
- Per ogni posa conto il numero di ripetizioni correttamente classificate e divido per il numero totale dei casi  $210 \cdot 4$ .

I risultati di tale statistica sono riportati nella tabella a sinistra. Nella tabella a destra invece sono riportati i risultati di corretta classificazione del transiente in uno dei primi due intervalli di 80 punti.

class	accuracy
1	90%
2	55%
3	90%
4	51%
5	99%

class	accuracy
1	91%
2	55%
3	88%
4	68%
5	100%

