

Politecnico di Milano
Scuola di Ingegneria dei Sistemi
Corso di Laurea Magistrale in Ingegneria Biomedica



Classificazione del segnale sEMG tramite Pattern
Recognition per il controllo del giunto della spalla di una
protesi attiva di arto superiore

Relatori: Prof. **Carlo Albino Frigo**

Prof.ssa **Giuseppina Gini**

Correlatori: Ing. **Esteban Pavan**

Ing. **Paolo Belluco**

Tesi di Laurea Magistrale di:

Diletta RIVELA Matr. 755756

Alessia SCANNELLA Matr. 771025

Anno Accademico 2012-2013

Alle nostre famiglie

Sommario

La perdita dell'arto superiore, o la sua assenza congenita, rappresentano un notevole disagio nella vita di un individuo, in quanto viene ad essere impedito lo svolgimento di un'ampia varietà di attività che fanno parte della sua vita quotidiana. La protesizzazione risulta essere, ad oggi, la soluzione più diffusa per tale problema e, quanto più è alto il livello del danno, tanto più è fondamentale avere l'ausilio di una protesi attiva.

Sono state svolte numerose ricerche al fine di sviluppare dei sistemi di controllo mioelettrico per protesi di arto superiore, che hanno principalmente preso in considerazione i livelli di amputazione più diffusi, ovvero il trans-radiale ed il trans-omerale.

Il presente lavoro di tesi, svolto presso il Laboratorio di Biomeccanica del Movimento e Controllo Motorio e il Dipartimento di Elettronica, Informazione e Bioingegneria del Politecnico di Milano, prende, invece, in considerazione la disarticolazione della spalla, e si pone come obiettivo quello di individuare la migliore tecnica di elaborazione di segnale sEMG da adoperare per poter attuare un controllo di tale giunto di una protesi attiva di arto superiore.

Dopo aver studiato l'anatomia, la cinematica della spalla e le tecniche di rilevazione del segnale mioelettrico di superficie, si è passati a tracciare lo stato dell'arte delle protesi di arto superiore esistenti in commercio ed in fase di sviluppo, concentrandosi maggiormente sui dispositivi a controllo mioelettrico.

In letteratura, i metodi di controllo mioelettrico basati sulla Pattern Recognition si sono dimostrati migliori per quanto concerne la naturalezza e l'intuitività del controllo.

A seguito di un'approfondita ricerca relativa ai passi che compongono la Pattern Recognition e al modo in cui essi sono stati sviluppati da diversi autori, si è scelto di proseguire con l'implementazione in MATLAB dei procedimenti che avevano mostrato avere, in letteratura, i migliori risultati in termini di accuratezza di classificazione di un movimento all'interno di un più ampio set di classi di movimento. I metodi di elaborazione implementati sono stati in seguito applicati a segnali sEMG acquisiti sperimentalmente da otto soggetti sani.

Per ogni percorso sono state testate diverse combinazioni di lunghezza della finestra di segmentazione e di incremento temporale tra finestre.

I risultati hanno mostrato che la miglior performance si ha in corrispondenza dell'utilizzo di finestre di lunghezza 500 ms con un incremento tra loro di 62 ms e in corrispondenza del percorso di elaborazione che prevede *feature extraction* di *Sample Entropy* (SampEn), *Cepstral Coefficients* di ordine 4 (CC), *Root Mean Square* (RMS) e *Waveform Length* (WL), *feature reduction* tramite Principal Component Analysis (PCA) e classificazione basata sulla Linear Discriminat Analysis (LDA).

Infine, è stata sperimentata la riduzione del numero di canali di acquisizione sEMG, per misurare le variazioni delle performance di classificazione. Si è notato che, eliminando i due canali che apparivano fornire l'informazione meno discriminante, l'accuratezza di classificazione subisce solo un lieve peggioramento.

Abstract

The upper limb loss, or its congenital absence, represents a remarkable disease for an individual's life, as it prevents from carrying out a wide variety of activities that are part of his daily life. Nowadays, prosthesis results to be the most common solution to this problem, and the higher level of the damage, the more it is crucial to have the aid of an active prosthesis.

In literature it is possible to find many researches in order to develop an upper-limb prosthetic control system. However, they have considered the most widespread levels of amputation, i.e. transradial and transhumeral levels.

The present work, carried out at the Movement Biomechanics and Motor Control Laboratory and at The Department of Electronics, Computer Science and Bioengineering of Politecnico di Milano University, takes into account the shoulder disarticulation, and aims to identify the best sEMG signal processing technique to be used to be able to implement the control of such a joint in an active upper limb prosthesis.

After studying the anatomy, kinematics of the shoulder and the techniques of surface myoelectric signal detection, we outline the state of the art of upper limb prostheses available on the market and in development focusing on myoelectric controller devices.

In literature, the myoelectric control methods based on the Pattern Recognition, have been revealed as the best one in terms of naturalness and intuitive control.

Following extensive research relative to the steps that comprise Pattern Recognition and the way in which they were developed by different authors, it was decided to continue with the implementation in MATLAB of procedures that had shown to have, in literature, the best results in terms of classification accuracy of a movement within a broader set of classes of movement. The methods of processing implemented were subsequently applied to sEMG signals acquired experimentally from eight healthy subjects.

For each path, different combination of segment length and increment have been tested.

The results showed that the best performance is in correspondence of the use of windows with a length of 500 ms, with an increase of 62 ms between them and in correspondence

with the processing path which involves feature extraction of Sample Entropy (Sampen), Cepstral Coefficients of order 4 (CC), Root Mean Square (RMS) and Waveform Length (WL), feature reduction by Principal Component Analysis (PCA) and classification based on Linear Discriminat Analysis (LDA).

Finally, a reduction of a number of the acquisition sEMG channels has been tested, in order to measure the variations in the classifications performance. It has been observed, that, by removing the two channels with the less discriminating information, the classification accuracy undergoes a very slight decline.

Indice

Sommario	I
Abstract.....	III
Glossario delle abbreviazioni utilizzate.....	VIII
Indice delle Figure	X
Indice delle Tabelle	XIII
Introduzione.....	1
1. L'Articolazione Della Spalla	4
1.1 Anatomia.....	4
1.2 Movimenti delle superfici articolari	6
1.3 Muscoli attivati durante il movimento.....	8
1.3.1 I muscoli della scapola	8
1.3.2 I muscoli dell'articolazione glenomerale	10
1.4 Cinematica della spalla	14
2. Il Segnale Elettromiografico.....	16
2.1 Origine segnale mioelettrico	16
2.2 Rilevazione segnale EMG	20
2.2.1 Elettrodi	20
2.2.2 EMG di superficie (sEMG)	24
3. Protesi Di Arto Superiore: Stato Dell'Arte.....	27
3.1 Classificazione funzionale delle protesi di arto superiore	29
3.1.1 Protesi Passive	30
3.1.2 Protesi attive	32
3.2 Classificazione per livello di amputazione	39
3.3 Design	40

3.3.1 Invasatura	41
3.3.2 Parti di collegamento	43
3.3.3 Terminal Device	45
3.4 Protesi robotizzate di spalla in via di sviluppo	47
3.4.1 Protesi del gruppo Sistemi Uomo-Macchina (Politecnico di Milano)	47
3.4.2 Protesi INAIL	49
3.4.3 DEKA “Luke” Arm	51
3.4.4 Johns Hopkins APL’s Modular Prosthetic Limb.....	55
4. Controllo basato sull’EMG Pattern Recognition.....	57
4.1 Acquisizione EMG multicanale	58
4.2 Segmentazione dei dati EMG	60
4.3 Feature Representation	64
4.3.1 Feature extraction	65
4.3.2 Feature reduction	86
4.4 Classificazione delle feature	98
4.4.1 Approccio Statistico	99
4.4.2 Approccio basato sulle reti neurali	101
5. Materiali	104
5.1 BTS FREEEMG 300.....	104
5.1.1 Sonde EMG Wireless	105
5.1.2 Unità Ricevente (UR)	106
5.2 Caricatore per le sonde	107
5.3 Personal Computer e Software	108
5.4 Access Point.....	108
5.5 Elettrodi per sEMG.....	109
5.6 Sistema Optoelettronico SMART	109

6. Metodi.....	112
6.1 Definizione del protocollo di acquisizione	112
6.1.1 Reclutamento Soggetti.....	112
6.1.2 Scelta del Movimento.....	113
6.1.3 Scelta dei Muscoli	114
6.1.4 Scelta posizionamento elettrodi.....	115
6.1.5 Scelta posizionamento markers	116
6.2 Fase sperimentale.....	117
6.2.1 Calibrazione del Sistema Optoelettronico	117
6.2.2 Preparazione del soggetto.....	118
6.2.3 Acquisizione del segnale sEMG e dei dati cinematici	119
6.2.4 Creazione del modello cinematico	119
6.2.5 Elaborazione dei dati	120
7. Risultati.....	128
7.1 Percorso di elaborazione 1	128
7.2 Percorso di elaborazione 2	136
7.3 Percorso di elaborazione 3	143
7.4 Valutazione numerosità canali.....	151
8. Conclusioni.....	156
Bibliografia.....	158
Appendice.....	163

Glossario delle abbreviazioni utilizzate

Abbreviazione	Significato
ROM	Range of Motion
CIR	Cebtro di Istantanea Rotazione
sEMG	Elettromiografia di superficie
MES	Myoelectric Signal
SNR	Signal Noise Ratio
AP	Action Potential
MU	Motor Unit
MUAP	Motor Unit Action Potential
CMMR	Common Mode Rejection Ratio
THA	Trans Homeral Amputation
TMR	Target Muscle Reinnervation
MVC	Maximal Voluntary Contraction
IED	Inter Electrodes Distance
BMI	Body Mass Index
FT	Fourier Transform
TFD	Time Frequency Domain
STFT	Short Time Fourier Transform
WT	Wavelet Transform
CWT	Continue Wavelet Transform
DWT	Discrete Wavelet Transform
IDWT	Inverse Discrete Wavelet Transform
WPT	Wavelet Packet Transform
WF	Wavelet Function
MNF	Mean Frequency
MDF	Median Frequency
PKF	Peak Frequency
TTP	Total Power

MNP	Mean Power
TD	Time Domain
ZC	Zero crossing
MAV	Mean Absolute Value
MAVS	Mean Absolute Value Slope
SSC	Slope Sign Changes
RMS	Root Mean Square
WL	Waveform Length
DR	Dimensionality Reduction
PCA	Principal Component Analysis
MDS	Multi Dimensional Scaling
SOFM	Self-Organizing Feature Map
LDA	Linear Discriminant Analysis
ULDA	Uncorrelated Linear Discriminant Analysis
MLP	Multilayer Perceptron
LP	Linear Perceptron
HMM	Hidden Markov Model
GMM	Gaussian Mixture Model
SVM	Support Vector Machine
KNN	K-Nearest Neighbor
DT	Decision Tree
AR	Auto Regressive
PSD	Power Spectral Density
MVN	Multi Variate Normal Distribution
MDL	Minimum Description Length
RES	Ratio of the Euclidean distance to the Standard Deviation
LDB	Local Discriminant Basis

Indice delle Figure

Figura 1: Articolazione glenomerale della spalla.	4
Figura 2: Articolazione glenomerale della spalla.	5
Figura 3: Articolazione sterno-clavicolare della spalla.	6
Figura 4: Muscoli elevatori della scapola.	8
Figura 5: Muscoli depressori della scapola.	9
Figura 6: Muscoli rotatori interni della scapola.	9
Figura 7: Muscoli rotatori esterni della scapola.	9
Figura 8: Muscoli flessori dell'articolazione glenomerale.	10
Figura 9: Muscoli estensori dell'articolazione glenomerale.	11
Figura 10: Muscoli abduttori dell'articolazione glenomerale.	11
Figura 11: Muscoli adduttori dell'articolazione glenomerale.	12
Figura 12: Muscoli rotatori interni dell'omero.	12
Figura 13: Muscoli rotatori esterni dell'omero.	13
Figura 14: Muscoli attuatori dell'estensione nel piano orizzontale.	13
Figura 15: Muscoli attuatori della flessione nel piano orizzontale.	14
Figura 16: Cinematica della spalla.	14
Figura 17: ROM della spalla.	15
Figura 18. Unità Motoria	16
Figura 19: Illustrazione schematica dei processi di depolarizzazione e ripolarizzazione 17	17
Figura 20. Potenziale d'azione muscolare.	17
Figura 21: MUAP 18	18
Figura 22. Reclutamento e frequenza di sparo dei motoneuroni α 20	20
Figura 23: Elettrodi a filo e loro inserimento.	22
Figura 24: Influenza dello spessore tessutale sull'ampiezza del segnale sEMG.	26
Figura 25: Classificazione funzionale protesi di arto superiore.	29
Figura 26: Esempi di protesi lavorative.	31
Figura 27: Esempio di protesi body-powered.	33
Figura 28: Switch.	36
Figura 29: Attuatore slider-type.	37

Figura 30: Esempio di protesi ibrida.	37
Figura 31: Livelli di amputazione di arto superiore.	39
Figura 32: Componenti di una protesi attiva di arto superiore.	41
Figura 33: OPRA® del Sahlgrenska University Hospital.	42
Figura 34: Nudge control unit.	44
Figura 35: Esempi di gomiti body-powered ed electrical-powered.	45
Figura 36: Esempi di polso di protesi attiva di arto superiore.	45
Figura 37: Protesi attiva di arto superiore Dip. Ing. Meccanica del Politecnico di Milano	47
Figura 38: Sistema differenziale relativo all'articolazione della spalla.	48
Figura 39: Giunto di frizione del gomito.	49
Figura 40: Protesi attiva di arto superiore del Centro Protesi INAIL di Vigorso di Budrio.	49
Figura 41: Schema cinematico della protesi INAIL (sinistra) e prototipo (destra).	50
Figura 42: Luke arm® del team DEKA (Manchester, New Hampshire)	52
Figura 43: Componenti della Luke Arm®.	52
Figura 44: Johns Hopkins APL's Modular Prosthetic Limb.	55
Figura 45: Sensori incorporati nella Johns Hopkins APL's Modular Prosthetic Limb.	56
Figura 46: Diagramma del sistema di controllo protesico basato Pattern Recognition	57
Figura 47: Errore di classificazione (%) per 2 e 4 canali sEMG.	58
Figura 48: Finestre adiacenti di lunghezza W e ritardo τ (da Englehart et al., 2001 (20)).	61
Figura 49: Finestre sovrapposte	61
Figura 50: Errore di classificazione (%) in funzione della lunghezza.	62
Figura 51: Confronto classificatori LDA e AR	64
Figura 52: Piano tempo frequenza (a) STFT, (b) WT e (c) WPT.	78
Figura 53: Wavelet decomposition fino a livello 4.	79
Figura 54: Wavelet Reconstruction.	80
Figura 55: Decomposition tree WPT con 3 livelli di scomposizione.	81
Figura 56: Wavelet Packet Tree fino alla scala $J=3$	82
Figura 57: Errore di classificazione feature Selection e PCA.	85
Figura 58: Direzione di la massima dispersione dei dati.	91
Figura 59: Struttura SOFM.	96
Figura 60: Modellizzazione del neurone biologico con un percettrone.	101
Figura 61: Architettura MLP.	102

Figura 62: Metodo della backpropagation.....	103
Figura 63: BTS FREEEMG 300®.....	104
Figura 64: Sonde delettromiografiche.	105
Figura 65: Componenti Unità ricevente BTS FREEEMG300®.	106
Figura 66: Caricatore per le sonde BTS FREEEMG330®.....	107
Figura 67: Schema di funzionamento dell' Access Point.....	109
Figura 68: Elettrodi gel BIELSAN.....	109
Figura 69: Telecamera del sistema SMART-e (BTS).	110
Figura 70: Disposizione telecamere all'interno del laboratorio.....	110
Figura 71: Asta utilizzata in fase di acquisizione.	114
Figura 72: Posizionamento marker.....	117
Figura 73: Risultato della calibrazione del sistema SMART-e®.	118
Figura 74: Disposizione degli elettrodi e dei marker sul soggetto.	119
Figura 75: Modello cinematico.	120
Figura 76: Angolo di elevazione durante il movimento di flessione a 90°.	121
Figura 77: Blocchi principali della Pattern Recognition.	122
Figura 78: Daubechies wavelet function di ordine 7 (a sinistra) e di ordine 5 (a destra).....	124
Figura 79: Symmlet wavelet function di ordine 5	125
Figura 80: Media e SD dei valori di RMS per il canale 1, al variare della classe.....	151
Figura 81: Media e SD dei valori di RMS per il canale 2, al variare della classe.....	152
Figura 82: Media e SD dei valori di RMS per il canale 3, al variare della classe.....	152
Figura 83: Media e SD dei valori di RMS per il canale 4, al variare della classe.....	152
Figura 84: Media e SD dei valori di RMS per il canale 5, al variare della classe.....	153
Figura 85: Media e SD dei valori di RMS per il canale 6, al variare della classe.....	153
Figura 86: Media e SD dei valori di RMS per il canale 7, al variare della classe.....	153
Figura 87: Media e SD dei valori di RMS per il canale 8, al variare della classe.....	154
Figura 88: RMS media per ciascun canale, per ogni classe di movimento.....	154
Figura 89: Accuratezza classificazione (%) sui dati di test variando num classi e canali.	155

Indice delle Tabelle

Tabella 1: Vantaggi e svantaggi degli elettrodi di profondità.....	21
Tabella 2: Principali vantaggi e svantaggi degli elettrodi di superficie.	22
Tabella 3: Specifiche a cui deve rispondere l'arto artificiale.....	29
Tabella 4: Vantaggi e svantaggi delle varie tipologie di protesi.	39
Tabella 5: Codice ISO 9999 per i vari livelli di amputazione di arto superiore.....	40
Tabella 6: Specifiche dei giunti motorizzati della spalla.....	51
Tabella 7: Specifiche della Johns Hopkins APL's Modular Prosthetic Limb a 26 gdl.....	56
Tabella 8: Finestra ottimale individuata in diversi studi.	63
Tabella 9: Feature nel dominio del tempo.....	71
Tabella 10: Principali tipologie delle feature nel dominio del tempo.	74
Tabella 11: Feature nel dominio della frequenza.	77
Tabella 12: Subset di coefficienti e WF ottimali per ciascuna feature,	80
Tabella 13: Parametri ottimali delle Trasformate tempo-frequenza.....	85
Tabella 14: Feature set, metodo di riduzione e classificatore con migliori performance....	85
Tabella 15: Metodi di classificazione usati nella Pattern Recognition.....	99
Tabella 16: Specifiche delle sonde wireless BTS FREEMG300®.	106
Tabella 17: Caratteristiche dell'UR BTS FREEMG330®.	107
Tabella 18: Misure antropometriche, media e deviazione standart per 8 soggetti.	112
Tabella 19: Muscoli scelti per la fase sperimentale di acquisizione.	115
Tabella 20: Scelta del posizionamento degli elettrodi.....	116
Tabella 21: Tipi di finestre usate per la segmentazione del segnale sEMG.....	121
Tabella 22: Diversi percorsi di elaborazione.....	126
Tabella 23: Errore (%) dati di Test al variare della segmentazione	128
Tabella 24: Matrice di confusione L=500 ms, I=62 ms nel caso di 4 classi.	129
Tabella 25: Matrice di confusione L=500 ms, I=62 ms nel caso di 5 classi.	130
Tabella 26: Matrice di confusione L=500 ms, I=62 ms nel caso di 9 classi.	131
Tabella 27: Matrice di confusione L=250 ms, I=250 ms nel caso di 4 classi	132
Tabella 28: Matrice di confusione L=250 ms, I=250 ms nel caso di 5 classi	133
Tabella 29: Matrice di confusione L=250 ms, I=250 ms nel caso di 9 classi.	134
Tabella 30: Matrice di confusione dell'abduzione a 90°	135

Tabella 31: Errore (%) dati di Test, al variare della segmentazione	136
Tabella 32: Matrice di confusione L=500 ms, I=62 ms nel caso di 4 classi.....	137
Tabella 33: Matrice di confusione L=500 ms, I=62 ms nel caso di 5 classi.	137
Tabella 34: Matrice di confusione L=500 ms, I=62 ms nel caso di 9 classi	138
Tabella 35: Matrice di confusione L=250 ms, I=250 ms nel caso di 4 classi	139
Tabella 36: Matrice di confusione L=250 ms, I=250 ms nel caso di 5 classi	140
Tabella 37: Matrice di confusione L=250 ms, I=250 ms nel caso di 9 classi.	141
Tabella 38: Valori di accuratezza per i primi 2 percorsi variando numero delle classi. ...	142
Tabella 39: Errore (%) dati di Test, al variare della segmentazione.....	143
Tabella 40: Matrice di confusione L=500 ms, I=62 ms nel caso di 4 classi.	144
Tabella 41: Matrice di confusione L=500 ms, I=62 ms nel caso di 5 classi	144
Tabella 42: Matrice di confusione L=500 ms, I=62 ms nel caso di 9 classi.	145
Tabella 43: Matrice di confusione L=250 ms, I=62 ms nel caso di 4 classi	146
Tabella 44: Matrice di confusione L=250 ms, I=62 ms nel caso di 5 classi.	147
Tabella 45: Matrice di confusione L=250 ms, I=62 ms nel caso di 9 classi.	148
Tabella 46: Errore di classificazione sui dati di test al variare del numero di classi.....	149
Tabella 47: Valori di accuratezza per 3 percorsi al variare del numero delle classi.	150
Tabella 48: Movimenti peggio e meglio classificati al variare del numero delle classi....	150

Introduzione

Fino ad oggi, sono state svolte molte ricerche relativamente allo sviluppo di sistemi di controllo per protesi attive di mano, polso e gomito, basati sulla *Pattern Recognition* del segnale elettromiografico. Poca attenzione è, invece, stata dedicata al controllo di protesi per disarticolazione della spalla. Questo è dovuto al fatto che la maggior parte delle amputazioni avviene a livello trans-radiale o trans-omeroale. Tuttavia, più aumenta il livello di amputazione, più si rende necessaria una sostituzione funzionale tramite protesi attiva. Le protesi di spalla convenzionali sono controllate da switch, posizionati all'interno dell'imbragatura della protesi, che devono essere attivati dal paziente quando desidera azionare il giunto. Un'altra strategia consiste nell'utilizzare un controllo mioelettrico 'indiretto', dove un muscolo sano è utilizzato per attivare un grado di libertà del giunto artificiale di spalla. Anche se entrambi questi metodi possono restituire una certa funzionalità, nessuno di essi è ideale. Il primo metodo, si basa su un'attivazione meccanica degli switch, che richiede un elevato grado di apprendimento da parte del paziente e, a seconda della complessità del movimento da svolgere, può risultare difficile e lento. Il secondo metodo, sebbene più intuitivo, in quanto sfrutta, al posto dello switch, l'attività elettrica dei muscoli, non permette ancora un controllo sufficientemente naturale.

Mediante l'uso di tecniche di *Pattern Recognition*, le quali si basano sull'assunzione che i pattern EMG contengano informazioni utili al riconoscimento di movimenti intenzionali dell'arto amputato. Quindi, diversamente da quanto avviene con il controllo mioelettrico convenzionale, il soggetto contrae il muscolo corrispondente al grado di libertà che vuole controllare. Ne risulta così un controllo più intuitivo da parte del soggetto e una selezione rapida di ogni funzione. Questo controllo permette, inoltre, al soggetto di far muovere più facilmente la protesi con molteplici gradi di libertà, come richiesto nelle amputazioni di arto di alto livello.

Questo lavoro di tesi, svolto presso il Laboratorio di Biomeccanica del Movimento e Controllo Motorio e il Dipartimento di Elettronica, Informazione e Bioingegneria del Politecnico di Milano, si colloca all'interno di un più ampio progetto, svolto in collaborazione con il Dipartimento di Meccanica del Politecnico di Milano. Lo scopo finale

del progetto è quello di realizzare un sistema completo, a basso costo, in grado di pilotare una protesi di arto superiore durante la fase di avvicinamento e presa di vari oggetti posti su un piano frontale alla protesi.

La protesi che è stata tenuta in considerazione come linea guida per il progetto di tesi è stata realizzata dal gruppo Meccanica dei Sistemi Uomo-Macchina del Dipartimento di Meccanica del Politecnico di Milano. Essa ed è munita di: due gradi di libertà attivi a livello della spalla, che consentono di compiere i movimenti di flessione-estensione sul piano sagittale, di abduzione-adduzione sul piano frontale e loro combinazioni; un grado di libertà passivo a livello dell'omero, che impedisce danni alla protesi in caso di urto; un grado di libertà attivo in corrispondenza del gomito, che ne permette il movimento di flessione-estensione; e di una mano commerciale Otto Bock® a due gradi di libertà.

Il progetto definisce un controllo della protesi basato su un sistema visivo, per quanto riguarda il riconoscimento del tipo di oggetto e del suo orientamento nello spazio; e su un sistema di classificazione del segnale mioelettrico di superficie acquisito tramite elettrodi posti in corrispondenza dei muscoli residui dell'arto ipsilaterale.

Il sistema visivo fa uso del Microsoft Kinect®, un dispositivo munito di due sensori ottici: un sensore in grado di catturare un'immagine RGB e di associare ad ogni pixel percepito le relative informazioni di profondità, rilevate tramite il secondo sensore a raggi infrarossi e salvate in una *depth map*. Tale mappa viene utilizzata per calcolare una serie di punti di via attraverso i quali il braccio dovrà transitare per raggiungere la posizione di presa corretta, senza generare collisioni.

Il sistema di classificazione del segnale mioelettrico di superficie fornisce la classe di movimento che il soggetto è intenzionato a svolgere a livello della spalla. Tale informazione viene impiegata per generare la sequenza di punti di via.

Per semplificare il testing del sistema di calcolo della traiettoria, la protesi è stata riprodotta all'interno di v-rep, una piattaforma virtuale di sperimentazione robotica.

Questo lavoro di tesi si focalizza sull'acquisizione, l'elaborazione e sulla progettazione e implementazione di un sistema di classificazione del segnale mioelettrico di superficie sopra descritto e ha più obiettivi. Il primo è di fornire una panoramica dello stato dell'arte delle soluzioni protesiche di arto superiore, sia a livello generale, sia più specificatamente per la disarticolazione della spalla. Il secondo obiettivo è quello di presentare un'ampia descrizione di quanto è esistente in letteratura circa il metodo di classificazione basato sulla

Pattern Recognition per il controllo di protesi di arto superiore; ciò è funzionale al terzo obiettivo, che consiste nel valutare la migliore tecnica di elaborazione del segnale sEMG, tra diversi metodi estrapolati da quelli che hanno presentato i migliori risultati in letteratura. Tale valutazione viene effettuata in termini di accuratezza della discriminazione tra un dato set di classi di movimento, per la specifica applicazione. Il quarto e ultimo obiettivo consta nel valutare se la riduzione del numero di canali di acquisizione sEMG comporti delle variazioni nelle performance di classificazione.

Il seguente lavoro di tesi si compone di otto capitoli.

Il Capitolo 1 descrive l'articolazione della spalla, in particolare ne espone l'anatomia, i movimenti delle superfici articolari, la muscolatura attivata durante i principali movimenti svolti dall'articolazione e la sua cinematica: tutti aspetti funzionali alla fase sperimentale di acquisizione del segnale sEMG.

Il Capitolo 2 tratta l'origine e la rilevazione del segnale elettromiografico, dando una panoramica degli elettrodi esistenti in commercio e fornendo i criteri di scelta in base all'applicazione. Il capitolo riporta, inoltre, i fattori che influenzano il segnale sEMG.

Il Capitolo 3 riporta lo stato dell'arte delle protesi di arto superiore esistenti in commercio e in fase di sviluppo.

Il Capitolo 4 espone in dettaglio il controllo mioelettrico basato sulla *Pattern Recognition*, riportando tutti gli step necessari ad estrarre dal segnale EMG l'informazione relativa alla classe di movimento che il soggetto è intenzionato a compiere. Per ciascuno di questi step, sono riportati i metodi migliori presentati in letteratura.

Il Capitolo 5 espone i materiali impiegati nella fase sperimentale nel presente lavoro di tesi.

Il Capitolo 6 spiega i metodi adoperati, a partire dalla definizione del protocollo di acquisizione fino alla fase sperimentale vera e propria di acquisizione ed elaborazione dei dati.

Il Capitolo 7 riporta e discute i risultati per ciascuno dei metodi di elaborazione implementati, effettuando un confronto al fine di individuare il metodo migliore, in termini di accuratezza della classificazione.

Il Capitolo 8 fornisce le conclusioni del lavoro svolto e alcune osservazioni che possono risultare utili per sviluppi futuri del presente lavoro.

Capitolo 1.

L'Articolazione Della Spalla

La spalla è l'articolazione più complessa del corpo umano in quanto comprende quattro articolazioni separate:

1. l'articolazione glenomerale,
2. l'articolazione sternoclavicolare,
3. l'articolazione acromioclavicolare,
4. l'articolazione scapolo-toracica.

Le prime tre sono di tipo sinoviale, mentre la quarta è del tipo osso-muscolo-osso.

Alla spalla compete anche la più ampia mobilità articolare del corpo umano.

1.1 Anatomia

L'articolazione glenomerale (Fig. 1, Fig. 2) è quella dotata di maggiore mobilità all'interno del corpo umano.

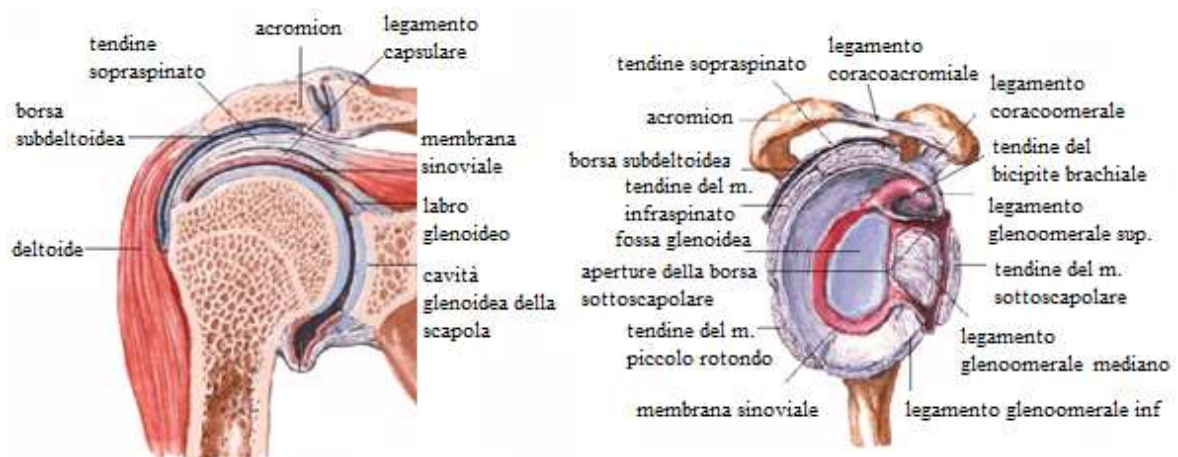


Figura 1: Articolazione glenomerale della spalla.

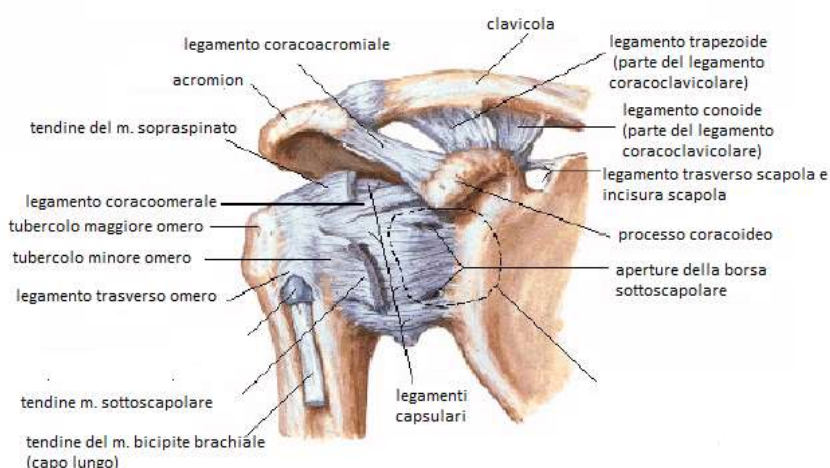


Figura 2: Articolazione glenomerale della spalla.

La testa quasi emisferica dell'omero ha una superficie di circa tre o quattro volte la superficie della fossa glenoidea della scapola, sulla quale si articola. La fossa glenoidea è meno incurvata della testa omerale in modo tale da permettere, oltre a movimenti rotatori, anche movimenti traslatori. Il bordo della fossa glenoidea è circondato da un labro composto da parte della capsula articolare, dal tendine del capo lungo del muscolo bicipite brachiale e dai legamenti glenomerali. Il labro rende più profonda la fossa e conferisce maggiore stabilità all'articolazione. L'articolazione glenomerale è dotata di una capsula articolare e numerosi legamenti si imbricano con essa. Sul lato anteriore si trovano i legamenti glenomerale superiore, inferiore e mediano, mentre sul lato posteriore è presente il legamento coracoomerale. Anche i tendini dei muscoli che compongono la cuffia dei rotatori (sottoscapolare, soprascapolato, infrascapolato e piccolo rotondo) concorrono ad unire le due estremità ossee. La tensione di questi muscoli spinge la testa dell'omero nella fossa glenoidea, aumentando significativamente la ridotta stabilità intrinseca dell'articolazione. Come per altre articolazioni sono presenti borse in grado di secernere liquido sinoviale, che funge da lubrificante tra i vari strati di tessuto di collagene.

L'articolazione sternoclavicolare (Fig. 3) è composta dalla terminazione prossimale della clavicola, che si allinea medialmente nella cavità del manubrio dello sterno. La clavicola è collegata alla prima costola da tessuto cartilagineo. L'articolazione sternoclavicolare garantisce l'asse principale di rotazione per i movimenti di clavicola e scapola. Un legamento interclavicolare collega le due clavicole allo sterno assieme al legamento

sternoclavicolare. Il legamento costoclavicolare connette invece la parte distale della clavicola alla prima costola.




Figura 3: Articolazione sterno-clavicolare della spalla.

L'articolazione acromioclavicolare è composta dal processo acromion, appartenente alla scapola, e dalla estremità distale della clavicola. È definita un'articolazione diartrosica irregolare, benché garantisca una limitata mobilità nei tre piani di riferimento. Le maggiori rotazioni di questa articolazione si verificano durante l'elevazione del braccio. La clavicola è collegata all'acromion dal legamento coracoacromiale.

L'articolazione scapolo-toracica è formata dal processo coracoideo della scapola e dalla superficie inferiore della clavicola, che sono collegati dal legamento coracoclaveare, il quale, di fatto, sospende la scapola alla clavicola.

1.2 Movimenti delle superfici articolari

L'articolazione glenomerale evidenzia i tipici movimenti di un'articolazione sferica in cui sono presenti rotazioni, rotolamento e scivolamento:

- Durante le rotazioni, il punto di contatto nella parte concava rimane lo stesso, mentre varia quello della superficie convessa.
- Durante il rotolamento, il punto di contatto si sposta della stessa quantità su ambedue le superfici.
- Infine, nello scivolamento, il punto di contatto rimane lo stesso sulla testa (parte convessa) e si muove sulla fossa (parte concava).

Il movimento principale delle superfici dell'articolazione glenomerale è di rotazione. È stato dimostrato che, in azioni di elevazione delle braccia da 0° a 60°, la testa dell'omero si sposta verso l'alto di circa 3 mm nella fossa glenoidea. Il centro di rotazione dell'articolazione tende a restare posizionato nei pressi del centro della testa dell'omero, come dimostrato dalle escursioni di circa 6 mm misurate in soggetti sani. In soggetti affetti da postumi di lesione o operatori, lo spostamento del centro di istantanea rotazione (CIR) aumenta significativamente, indicando la dominanza di rotolamento e scivolamento rispetto alla rotazione, parzialmente compromessa.

L'ampiezza del movimento dei due segmenti che compongono l'articolazione acromioclavicolare è stata studiata soprattutto su cadaveri. Nei soggetti viventi, il Range of Motion (ROM) è decisamente più ridotto, a causa dei vincoli imposti dal torace e dalla muscolatura: durante l'abduzione e la flessione anteriore della spalla, la clavicola si eleva di circa 20° rispetto alla scapola. L'elevazione ha luogo principalmente nei primi 30° e negli ultimi 45° del movimento delle braccia.

Per quanto concerne l'articolazione sternoclavicolare, sono stati evidenziati scivolamenti anteroposteriori (protrazione e retrazione della clavicola) tra lo sterno ed il menisco articolare; mentre scivolamenti superiori e inferiori (elevazione e depressione della clavicola) sono presenti tra clavicola e menisco. La clavicola può anche ruotare attorno al suo asse principale. Nei movimenti di elevazione del braccio nel piano sagittale e frontale, il ROM relativo all'inclinazione della clavicola è pari a circa 40°, di cui 35° corrispondono ai primi 90° di elevazione. Per quanto concerne la rotazione della clavicola attorno al suo asse principale, sono stati riscontrati ROM di circa 40°.

L'articolazione scapolo-toracica, è una tipica articolazione osso-muscolo-osso in quanto, escludendo le connessioni legamentose con la clavicola, non presenta articolazioni vere e proprie con la parte posteriore del torace. Questa situazione si riflette in una grande libertà di movimento della scapola in relazione ai movimenti del torace, il che incrementa notevolmente la mobilità globale della spalla. Infatti, il ROM della spalla, nel piano sagittale e nel piano frontale, è ottenuto per 2/3 con i movimenti dell'articolazione glenomerale e per 1/3 dall'articolazione scapolotoracica. I circa 60° corrispondenti a quest'ultima componente sono resi possibili grazie al corrispondente movimento delle

articolazioni clavicolari: 40° a carico della acromioclavicolare e 20° a carico della sternoclavicolare.

Nel piano scapolare, è possibile definire il CIR relativo al livello di elevazione del braccio, il quale si muove in modo molto evidente e passa da una posizione centrale della parte inferiore della scapola, all'inizio del movimento, ad una posizione sull'apice prossimale quando viene raggiunta la massima elevazione. Considerando il torace come sistema di riferimento relativo durante i movimenti di elevazione, si rileva che la scapola compie movimenti nel piano frontale: il processo coracoideo tende ad innalzarsi, mentre l'acromion e la fossa glenoidea tendono a rimanere in uno stesso piano orizzontale.

1.3 Muscoli attivati durante il movimento

1.3.1 I muscoli della scapola

I muscoli che si inseriscono sulla scapola hanno diverse funzioni: in primo luogo, stabilizzano la scapola in modo tale che essa rappresenti una solida base per i muscoli della spalla quando questi ultimi sviluppano tensione; in secondo luogo, orientano la scapola in modo tale che i movimenti dell'arto superiore risultino facilitati dall'appropriato posizionamento dell'articolazione glenoumerale.

L'elevazione è da ascrivere ai muscoli trapezio superiore, elevatore scapolare, romboide, omoideo e sternocleidomastoideo (Fig. 4).

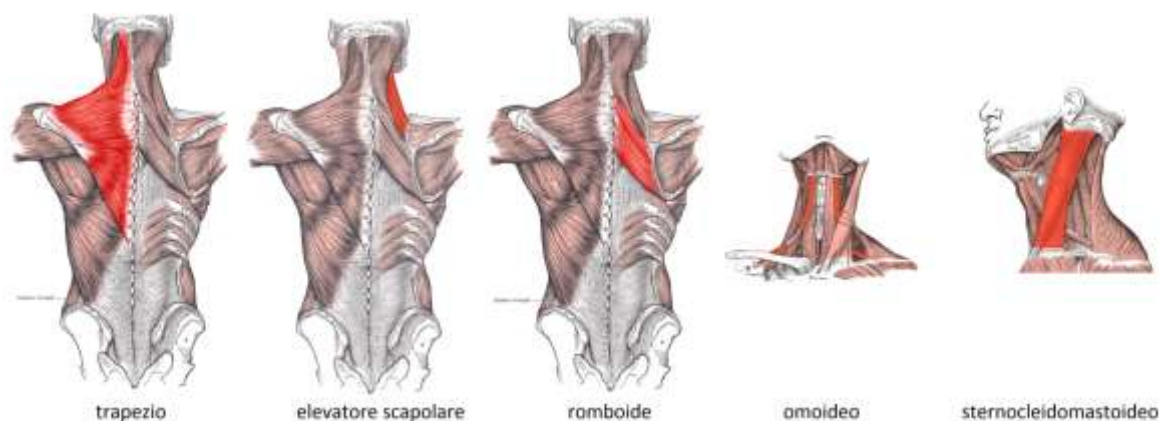


Figura 4: Muscoli elevatori della scapola.

La depressione è demandata ai seguenti muscoli: grande e piccolo pettorale, gran dentato (o serrato anteriore), succlavio e trapezio (Fig. 5).



Figura 5: Muscoli depressori della scapola.

La rotazione interna è legata alla contrazione di: trapezio superiore, trapezio inferiore e serrato anteriore (Fig. 6).




Figura 6: Muscoli rotatori interni della scapola.

La rotazione esterna dipende invece da: elevatore scapolare, romboide, piccolo pettorale e succlavio (Fig. 7).

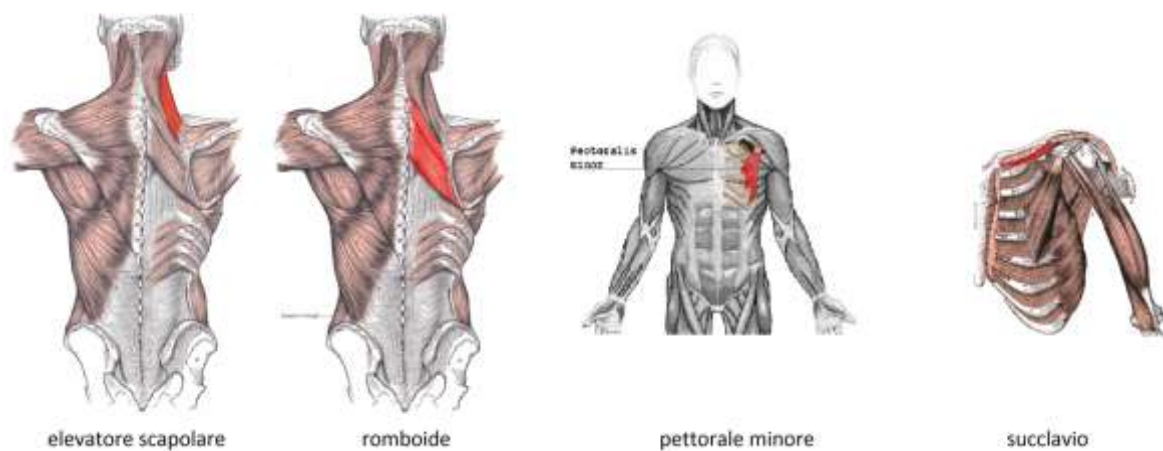


Figura 7: Muscoli rotatori esterni della scapola.

Come si può notare da quanto sopra riportato, molteplici muscoli agiscono sulla scapola e la loro contrazione può contribuire all'esecuzione di movimenti differenziati.

1.3.2 I muscoli dell'articolazione glenomerale

Un numero ragguardevole di muscoli attraversa l'articolazione glenomerale e, grazie ai punti di inserzione e alle linee di azione che li caratterizzano, alcuni di essi contribuiscono simultaneamente a differenti movimenti dell'omero.

La flessione dell'articolazione glenomerale è legata principalmente al deltoide anteriore e alla porzione clavicolare del grande pettorale. Concorrono alla flessione il muscolo coracobrachiale e il capo breve del bicipite brachiale (Fig. 8). L'efficacia dell'azione prodotta dalla tensione del bicipite brachiale (muscolo biarticolare che interessa anche il gomito) è più evidente quando il gomito è completamente esteso.




Figura 8: Muscoli flessori dell'articolazione glenomerale.

L'estensione dell'articolazione glenomerale, in assenza di carico, è prodotta dall'azione della forza di gravità, senza richiesta di azione muscolare. Nel caso sia necessario attuare questo movimento contro una resistenza, intervengono i muscoli che sono situati sulla parte posteriore dell'articolazione. Il gran dorsale, il grande rotondo e la parte sternale del gran pettorale estendono l'omero; la parte posteriore del deltoide interviene nell'estensione soprattutto quando l'omero è ruotato esternamente; il capo lungo del bicipite (muscolo biarticolare) è lievemente più efficace quando il gomito è flesso.

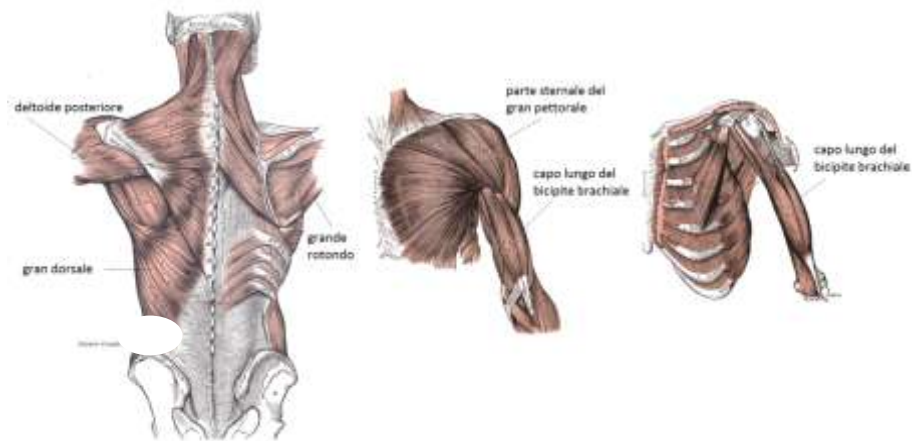


Figura 9: Muscoli estensori dell'articolazione glenomerale.

In abduzione, i principali muscoli coinvolti sono il deltoide e il soprascinato (Fig. 10).




Figura 10: Muscoli abduttori dell'articolazione glenomerale.

Entrambi i muscoli attraversano l'articolazione nella sua parte superiore. L'intervento del soprascinato è generalmente legato ai primi 110° di movimento, mentre il deltoide interviene tra i 90° e i 180°. La notevole componente dislocatoria del deltoide è neutralizzata dalla simultanea contrazione di sottospinato, sottoscapolare e piccolo rotondo.

Come per l'estensione, l'adduzione dell'arto superiore a gomito esteso avviene per mezzo della forza di gravità, con i muscolo abduttori che controllano la velocità del movimento. Se è presente una resistenza da vincere, intervengono i muscoli adduttori (Fig. 11) che, per importanza, sono rappresentati da: gran dorsale, grande rotondo e pettorale (porzione sternocostale). Un supporto secondario al movimento viene fornito dal capo breve del

bicipite e dal capo lungo del tricipite. Quando l'arto è elevato oltre i 90°, anche i muscoli coracobrachiale e sottoscapolare intervengono a supporto dell'azione di adduzione contro resistenza.

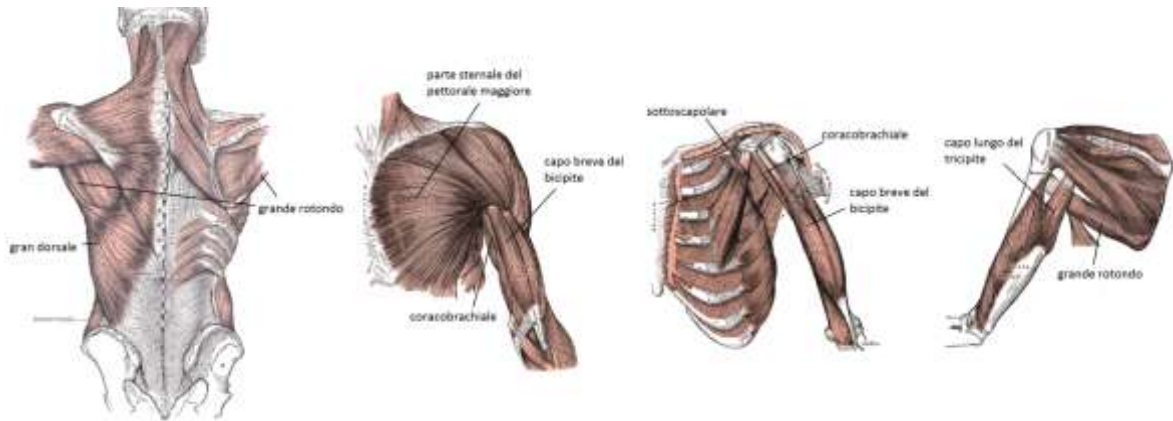


Figura 11: Muscoli adduttori dell'articolazione glenomerale.

La rotazione interna dell'omero dipende principalmente dalla tensione dei muscoli sottoscapolare e grande rotondo (Fig. 12), entrambi con inserzione sulla parte anteriore di quest'osso.

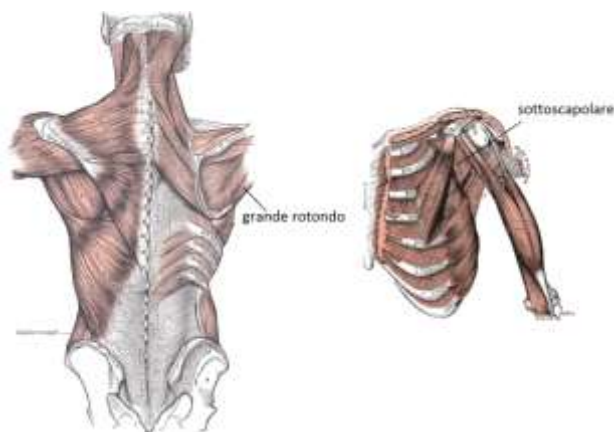


Figura 12: Muscoli rotatori interni dell'omero.

La rotazione esterna dell'omero è attuata dai muscoli che si inseriscono sulla parte posteriore (Fig. 13): l'infraspinato (o sottospinato), il piccolo rotondo, il deltoide (il quale contribuisce parzialmente a quest'azione).




Figura 13: Muscoli rotatori esterni dell'omero.

Nel piano orizzontale, l'articolazione glenomerale permette movimenti di flessione ed estensione orizzontale dell'omero. Per quanto concerne l'estensione orizzontale, i principali attuatori del movimento sono: la parte mediana e posteriore del muscolo deltoide, l'infraspinato, il piccolo rotondo, il grande rotondo e il gran dorsale (Fig. 14).

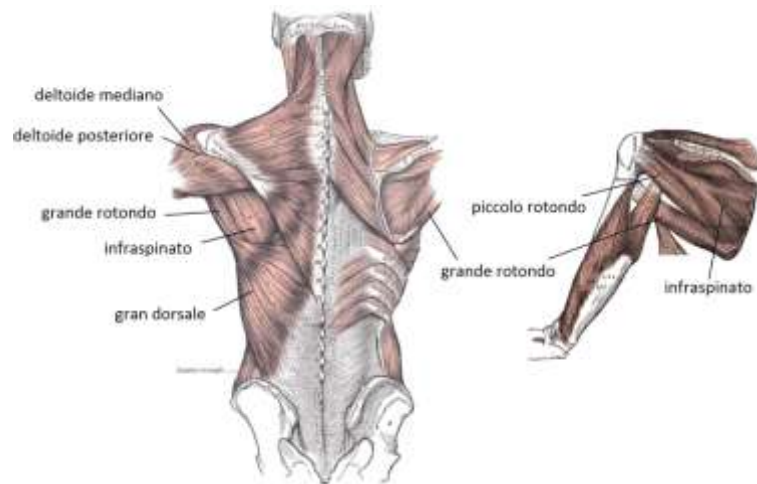


Figura 14: Muscoli attuatori dell'estensione nel piano orizzontale.

La flessione orizzontale è invece realizzata per mezzo dei muscoli che attraversano anteriormente l'articolazione (Fig. 15): il grande pettorale, il deltoide anteriore, il coracobrachiale e il capo breve del bicipite brachiale (il quale assiste all'azione).

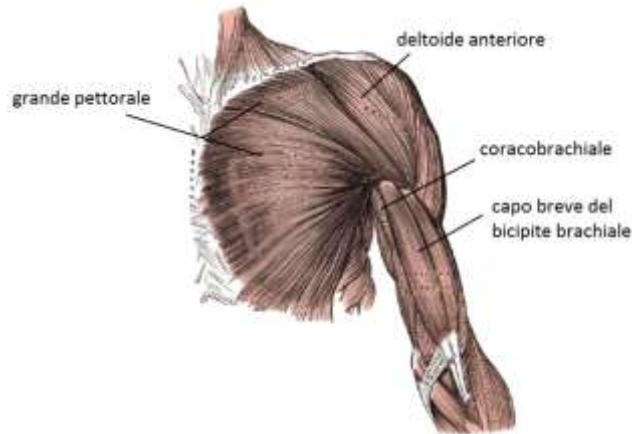


Figura 15: Muscoli attuatori della flessione nel piano orizzontale.

1.4 Cinematica della spalla

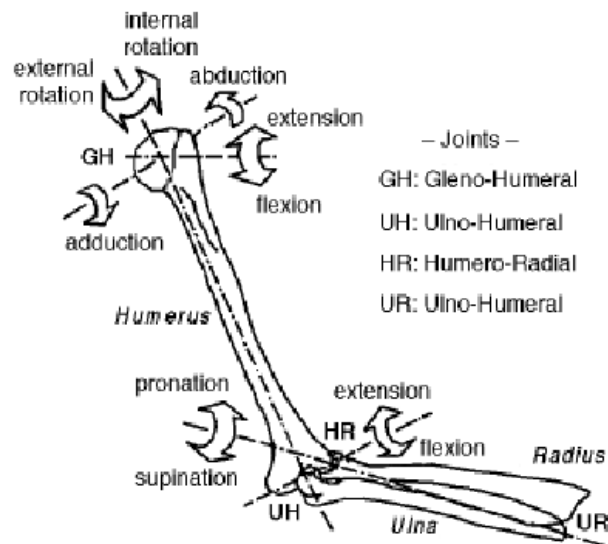


Figura 16: Cinematica della spalla.

Si definisce elevazione della spalla il movimento che allontana l'arto superiore dal torace in qualsiasi piano. Questo movimento viene misurato in gradi rispetto alla verticale che approssima l'atteggiamento dell'arto superiore in posizione anatomica di riferimento. In relazione ai piani considerati, si identificano differenti elevazioni della spalla (Fig.17).

La flessione (o elevazione anteriore nel piano sagittale) è nei soggetti normali pari a 180° e tende a diminuire con l'invecchiamento, anche se l'attività motoria contrasta in modo significativo la riduzione di mobilità di questa articolazione.

L'abduzione del braccio presenta lo stesso ordine di grandezza della flessione, pari cioè a 180°.

I movimenti di elevazione nel piano scapolare sono di interesse, in quanto corrispondono ad una condizione in cui la capsula glenomerale non è torta ed i muscoli deltoide e soprascapolare sono allineati in modo ottimale per l'elevazione dell'arto. In base alle denominazioni convenzionali precedentemente introdotte, l'elevazione nel piano scapolare è una combinazione di flessione anteriore e abduzione, infatti tale piano è ruotato internamente di circa 30° ÷ 45° rispetto al piano frontale. L'ampiezza media di questo movimento è compresa tra i 160° e i 180° gradi, ed è lievemente superiore per le donne, grazie alle minori masse muscolari ed alla tendenza ad una maggiore lassità legamentosa. La rotazione dell'omero, sul suo asse principale, è un'altra importante funzione della spalla. Rotazione interna ed esterna possono essere attuate a diversi gradi di elevazione dell'arto superiore e l'ampiezza totale del movimento, pur essendo funzione del livello di elevazione, è di circa 180°, distribuita equamente tra rotazione interna e rotazione esterna. Altri movimenti della spalla sono l'elevazione posteriore (o iperestensione) che si aggira attorno ai 60° e l'adduzione delle braccia che è più efficace anteriormente al torace (75°) che non posteriormente ad esso (20°).

La flessione orizzontale, misurata a partire da una posizione di partenza con il braccio allineato al piano frontale e a 90° di abduzione, raggiunge valori di 135°, mentre l'estensione orizzontale è pari a 45°. Globalmente il ROM della spalla nel piano orizzontale è pari a 180° (1).




Figura 17: ROM della spalla.

Capitolo 2.

Il Segnale Elettromiografico

Per elettromiografia si intende l'insieme delle tecniche per il prelievo, l'elaborazione, la rappresentazione e l'interpretazione dei segnali elettrici generati durante la contrazione volontaria o indotta dei muscoli scheletrici.

2.1 Origine segnale mioelettrico

Il segnale mioelettrico (EMG) è una manifestazione di tipo elettrico derivante dall'attivazione muscolare associata alla contrazione e più precisamente dalle correnti ioniche che scorrono lungo le membrane delle fibre muscolari.

Per descrivere come viene generato il segnale EMG, prendiamo inizialmente in considerazione la più piccola unità funzionale dell'apparato neuromuscolare: l'unità motoria (Fig.18). Essa è composta dal corpo cellulare del motoneurone α , situato nel midollo spinale, dal suo assone, dalle fibre muscolari innervate dal medesimo assone e dalla giunzione neuromuscolare (o placca motrice), che permette la contrazione muscolare a seguito dell'impulso nervoso.

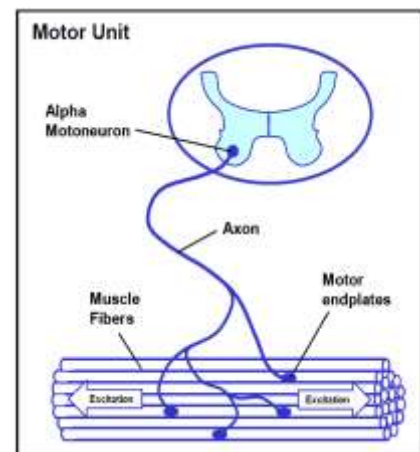


Figura 18. Unità Motoria (2)

In condizioni di riposo, si ha un equilibrio ionico tra l'interno e l'esterno della fibra muscolare; si ha così un potenziale di riposo a livello della membrana della fibra muscolare (tra -80 mV e -90 mV). Questa differenza di potenziale, che è mantenuta dai processi fisiologici (pompa ionica), provoca una carica negativa all'interno della fibra rispetto all'esterno.

L'attivazione di un motoneurone α (indotta dal sistema nervoso centrale o da un riflesso) genera la conduzione del potenziale d'azione lungo l'assone del medesimo motoneurone alla velocità di circa 100 m/s, permettendo il rilascio di un neurotrasmettitore,

l'acetilcolina, a livello delle placche motrici (*motor endplates*). La presenza di acetilcolina a livello della placca motrice causa l'apertura dei canali transmembranici, attraverso cui iniziano a fluire, all'interno della fibra, gli ioni Na^+ e, più lentamente, verso l'esterno, gli ioni K^+ . Ciò causa una depolarizzazione della membrana a livello della placca motrice, che è immediatamente ripristinata da uno scambio di ioni in senso contrario, all'interno del meccanismo di pompa ionica attiva: la ripolarizzazione (Fig. 19).

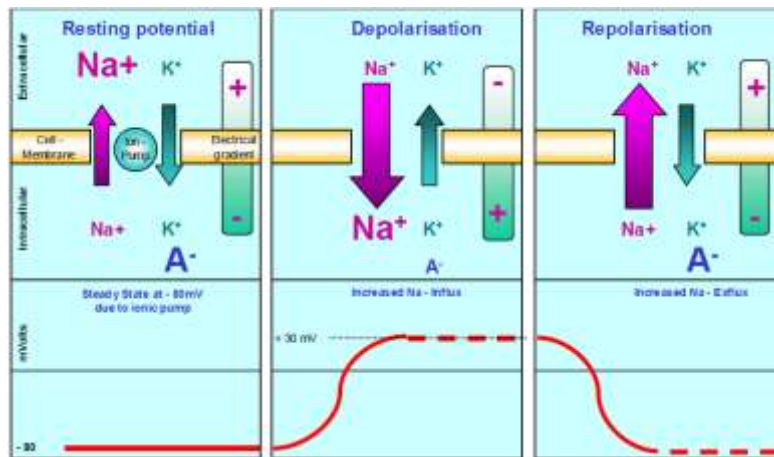


Figura 19: Illustrazione schematica dei processi di depolarizzazione e ripolarizzazione (2).

Se il potenziale di membrana supera un certo valore di soglia, la depolarizzazione genera un potenziale d'azione muscolare, il quale fa variare rapidamente il potenziale da -80 mV fino a +30 mV (Fig. 20). A ciò segue un rapido ripristino del potenziale di membrana tramite una fase di ripolarizzazione, seguita da un periodo di iperpolarizzazione.

A partire dalla placca motrice, il potenziale d'azione muscolare si propaga lungo la fibra muscolare in entrambe le direzioni.




Figura 20. Potenziale d'azione muscolare (2).

Questa eccitazione porta al rilascio degli ioni Ca^{++} nello spazio intracellulare. Processi chimici collegati producono infine l'accorciamento degli elementi contrattili della fibra muscolare.

Tipicamente vengono usati, in fase di registrazione del segnale EMG, elettrodi in configurazione bipolare seguiti da un amplificatore differenziale. Poiché la propagazione dei potenziali d'azione muscolari avviene nella direzione delle fibre, sarà lungo tale direzione che si dovranno posizionare gli elettrodi per il rilevamento. Si consideri a titolo di esempio la situazione rappresentata in Fig. 21, dove si ha una coppia di elettrodi (elettrodo positivo a sinistra e elettrodo negativo a destra), posizionata parallelamente alle fibre muscolari, che rileva la tensione che risulta dalle correnti generate dai potenziali d'azione che si propagano verso essa. Con l'ipotesi che tutte le fibre dell'unità motoria (MU) generino lo stesso potenziale d'azione (AP), l'ampiezza del segnale di tensione rilevato dalla coppia di elettrodi, relativo ad una singola fibra, dipende dalla distanza tra il luogo di generazione e propagazione del potenziale e il sito di rilevazione. Con l'ipotesi che l'attivazione di tutte le fibre dell'unità motoria sia pressoché istantanea e che, quindi, la generazione del potenziale d'azione muscolare a livello di ogni placca motrice avvenga quasi nello stesso istante temporale, la relazione temporale tra le diverse tracce dipenderà dalla posizione della placca motrice rispetto ai siti di rilevazione.




Figura 21: MUAP rilevato da una coppia di elettrodi disposta parallelamente alle fibre muscolari (2).

Dalla Fig. 21 si possono fare alcune osservazioni:

1. Il segnale relativo alla singola fibra muscolare ha un profilo bifasico simmetrico. La massima ampiezza si ottiene infatti quando il potenziale d'azione muscolare passa nel punto della fibra più vicino al sito di rilevazione. L'occorrenza positiva o negativa della prima fase dipende dalla polarizzazione del primo elettrodo che il potenziale d'azione muscolare incontra a partire dalla placca motrice. Nell'esempio, i segnali delle fibre 1 ed n hanno la prima semionda negativa in quanto il potenziale d'azione muscolare raggiunge prima l'elettrodo negativo e poi il positivo; mentre, nel caso delle fibre 2 e 3, la situazione è opposta e altrettanto opposti in fase si presentano i segnali.
2. Il ritardo tra l'istante di generazione a livello della placca motrice e l'istante di rilevazione dipende dalla distanza tra questa e il luogo di rilevazione e dalla velocità di conduzione della fibra secondo la relazione: $\tau = \frac{d}{v_c}$. Nell'esempio, considerando la V_c costante per tutte le fibre, vale $\tau_n > \tau_1 > \tau_3 > \tau_2$.
3. L'ampiezza del segnale della singola fibra ha una dipende inversa dalla distanza tra la fibra e il sito di rilevazione, in quanto si ha un'attenuazione del segnale all'interno degli strati adiposi. Nell'esempio, l'ampiezza massima dei segnali relativi alle fibre 3 ed n è la stessa in quanto queste distano ugualmente dai siti di rilevazione. Inoltre, l'ampiezza decresce dalla fibra 3 alla fibra 1, perché aumenta l'attenuazione da parte dei tessuti adiposi.

La coppia di elettrodi vede il contributo di tutte le fibre innervate all'interno dell'unità motoria. La somma dei contributi delle fibre appartenenti ad un'unità motoria dà luogo al segnale denominato *Motor Unit Action Potential* (MUAP), il quale assume tipicamente un profilo trifasico e dipende dalla geometria delle fibre dell'unità motoria e dal posizionamento degli elettrodi. Alla rilevazione di un MUAP corrisponde una contrazione della corrispondente unità motoria, di intensità e durata irrisoria.

I due principali meccanismi che influenzano l'ampiezza e la densità del segnale osservato sono: il reclutamento e la frequenza di sparo dei motoneuroni α (Fig. 22). Queste sono le principali strategie di controllo per regolare il processo di contrazione e per modulare la forza prodotta dal muscolo. Per livelli di contrazione volontaria molto bassi, è possibile distinguere ancora il singolo MUAP all'interno del tracciato, ma quando il livello di

contrazione aumenta, l'incremento della frequenza di attivazione e del numero di unità reclutate causa un'interferenza notevole tra i vari MUAP, dando luogo ad un tracciato interferenziale.




Figura 22. Reclutamento e frequenza di scarica dei motoneuroni α (2).

2.2 Rilevazione segnale EMG

2.2.1 Elettrodi

Gli elettrodi sono dei veri e propri trasduttori che trasformano le correnti ioniche generate nei muscoli in una corrente elettronica che può essere manipolata con circuiti elettronici e memorizzata in forma analogica o digitale come potenziale di tensione.

La classificazione degli elettrodi avviene in base a più criteri, quali: il sito di rilevazione (elettrodi di profondità e di superficie) e il tipo di configurazione (elettrodi monopolari e bipolari).

a. Elettrodi di profondità e di superficie

Gli elettrodi di profondità vengono inseriti all'interno del tessuto muscolare, permettendo così lo studio di muscoli profondi. Sono in grado di rilevare il segnale di un ridotto numero di unità motorie, grazie alla ridotta superficie captante che li rende più

selettivi. Ciò permette, quindi, di indagare aree diverse all'interno dello stesso muscolo. Lo svantaggio principale è dato dalla loro invasività e poca tollerabilità da parte del paziente. La Tabella 1 riporta i principali vantaggi e svantaggi di questa tipologia di elettrodi.

Vantaggi elettrodi di profondità	Svantaggi elettrodi di profondità
Possibilità di analisi dei muscoli profondi	Invasività, dolore
Basso volume di lavoro	Poca tollerabilità da parte del paziente
Alta selettività	Asetticità
Basso cross-talking	Costo

Tabella 1: Vantaggi e svantaggi degli elettrodi di profondità.

Possono essere classificati a loro volta in elettrodi: ad ago e a filo.

I primi sono costituiti da un ago, all'interno del quale si trovano uno o più fili conduttori che terminano sulla sua punta a formare una o più aureole sensibili di diametro dell'ordine del decimo di mm. Il numero di aureole sensibili dipende dalla configurazione dell'elettrodo: una per la configurazione monopolare, due per quella bipolare. Questa tipologia di elettrodi è riutilizzabile in quanto estraibile e sterilizzabile. L'utilizzo è però limitato ad analisi isometriche del muscolo, in quanto il suo accorciamento potrebbe provocare una rottura dell'ago all'interno del tessuto muscolare.

Gli elettrodi a filo (Fig. 23) sono un'evoluzione degli elettrodi ad ago. Sono costituiti da un ago cavo, all'interno del quale si hanno dei fili flessibili, del diametro di 25-100 μm , circondati da materiale isolante (ad eccezione della parte terminale, da cui si rileva il segnale). I fili vengono preventivamente piegati all'esterno dell'ago a formare un uncino in modo che, una volta inseriti nel muscolo tramite l'ago, l'uncino si fissi al muscolo e mantenga in situ il rispettivo filo. Questa tipologia di elettrodi non è riutilizzabile e ha una bassa resistenza meccanica; ha però il vantaggio di poter essere utilizzata in analisi motoria, in quanto la flessibilità dei suoi fili evita la rottura di questi ultimi in fase di contrazione del muscolo.




Figura 23: Elettrodi a filo e loro inserimento (2).

Gli elettrodi di superficie sono dischetti metallici, di diametro inferiore al cm, che vengono applicati sulla cute in corrispondenza del muscolo da esaminare. La loro principale limitazione è che possono essere impiegati solo per analizzare i muscoli superficiali. Al diminuire del diametro dell'elettrodo e della distanza interelettrodica, diminuisce il volume di lavoro e quindi aumenta la selettività della misura e diminuisce il cross-talking. La Tabella 2 riporta i principali vantaggi e svantaggi relativi agli elettrodi di superficie.

Vantaggi elettrodi di superficie	Svantaggi elettrodi di superficie
<p>Nessun invasività</p> <p>Non provocano fastidio al paziente</p>	<p>Maggior volume di lavoro</p> <p>Minor selettività</p> <p>Maggior cross-talking</p> <p>Attenuazione del segnale nel tessuto adiposo</p> <p>Non adatti per muscoli piccoli e profondi</p> <p>Richiedono pulizia pelle</p>

Tabella 2: Principali vantaggi e svantaggi degli elettrodi di superficie.

I più utilizzati sono gli elettrodi di Ag/AgCl dotati di gel, facili da applicare e monouso. Gli elettrodi monouso commerciali sono realizzati con gel umido o gel adesivo. Generalmente l'elettrodo a gel umido permette una miglior conduzione e valori di

impedenza tra elettrodo e pelle più bassi rispetto all'elettrodo a gel adesivo. Quest'ultimo ha però il vantaggio che può essere riposizionato in caso di errori.

b. Elettrodi monopolari e bipolari

Le configurazioni di base per la rilevazione del segnale elettromiografico sono quella monopolare e quella bipolare.

La configurazione monopolare prevede di misurare la differenza di tensione tra l'elettrodo di misura, posizionato in corrispondenza del muscolo sotto analisi, ed un elettrodo di riferimento, posto lontano dal precedente in zona inerte.

La distanza interelettrodica (in questo caso, la distanza tra l'elettrodo di misura e quello di riferimento) risulta essere elevata, e di conseguenza sarà alto anche il volume di lavoro. Il segnale in uscita conterrà quindi il segnale utile, ma anche altri segnali biologici e ambientali, spesso sovrapposti in banda al segnale utile e quindi difficili da eliminare a posteriori con filtri. Questo problema ha portato alla realizzazione della seconda configurazione, utilizzata in tutti i sistemi elettromiografici.

La configurazione bipolare prevede di misurare la differenza di tensione tra due elettrodi di misura, posti vicini tra loro in zona contrattile. Si ha inoltre un elettrodo di riferimento posto lontano dai siti di rilevazione, in zona elettricamente inerte.

I vantaggi di questa modalità di registrazione sono molteplici. Il primo vantaggio è che, mentre prima il volume di lavoro era grande a causa dell'elevata distanza tra l'elettrodo di misura e l'elettrodo di riferimento, qui il volume di lavoro si riduce in quanto la distanza interelettrodica, determinata in questo caso dalla distanza tra i due elettrodi di misura (posti vicini tra loro), è bassa. Il basso volume di lavoro limita il problema del cross-talk (segnale proveniente da altri muscoli vicini che si sovrappone al segnale utile). L'altro grosso vantaggio è quello di poter ritenere che il rumore proveniente da sorgenti distanti dal sito di rilevazione (es. ECG, rumore ambientale) dia un contributo uguale a livello dei due elettrodi di misura, in quanto posti molto vicini tra loro. Misurando quindi la differenza di tensione tra i due elettrodi di misura, gran parte del disturbo viene eliminato, a patto di avere un Common Mode Rejection Ratio (CMRR) superiore a 120 dB.

2.2.2 EMG di superficie (sEMG)

a. Scelta elettrodi di superficie

Alcuni fattori come la dimensione degli elettrodi, la distanza interelettrodica ed il loro posizionamento influenzano il segnale sEMG (3).

La dimensione di un elettrodo è definita come la dimensione della sua area conduttiva. Gli elettrodi di superficie sono disponibili in un'ampia varietà di dimensioni. Secondo la letteratura, la dimensione degli elettrodi per la rilevazione del segnale sEMG usati nella pratica clinica variano da 1 mm² a qualche cm².

Elettrodi di piccole dimensioni permettono di avere una distanza interelettrodica bassa e, di conseguenza, un volume di lavoro piccolo, che si traduce in maggior selettività e minor crosstalk; di contro, il segnale risulta debole e difficile da trattare in quanto annegato nei disturbi.

Diversamente, elettrodi di dimensione elevata consentono di ottenere un segnale ad ampiezza maggiore; di contro, la maggior distanza interelettrodica porta ad avere un volume di lavoro elevato, che si traduce in minor selettività, riduzione del contenuto ad alta frequenza e maggior crosstalk.

La distanza interelettrodica è definita come la distanza tra i centri delle aree conduttive dei due elettrodi bipolari. È stato visto come la distanza interelettrodica incida proporzionalmente sul volume di lavoro.

Il posizionamento degli elettrodi di superficie, in corrispondenza dei gruppi muscolari target, è importante per rendere comparabili le misure intra-individuali e inter-individuali. Gli elettrodi dovrebbero essere posizionati in modo da ottenere un buon segnale stabile. Il fattore che influenza la bontà e la stabilità del segnale è la presenza di placche motrici, di tendini e di altri muscoli attivi vicini.

Bisogna infatti evitare che: il punto centrale tra i due elettrodi sia in corrispondenza di placche motrici; gli elettrodi siano posti sul tendine, e quindi in zona non contrattile; gli elettrodi siano adiacenti ad altri muscoli.

Per quanto riguarda l'orientamento degli elettrodi, si raccomanda di orientarli parallelamente alle fibre muscolari.

b. Contaminazione del segnale sEMG

La registrazione mediante elettrodi dell'attività muscolare si presenta di difficile trattazione in quanto il segnale EMG è di tipo stocastico non stazionario. L'ampiezza varia da qualche μV fino a qualche mV; si tratta quindi di un segnale molto esiguo ed immerso in un rumore ambientale molto più elevato (anche $1\div 2\text{ V}$). La banda del segnale EMG è compresa tra $20\div 500\text{ Hz}$ e le componenti dominanti si situano tra $50\div 150\text{ Hz}$.

Il rumore sovrapposto al segnale sEMG è di varia natura:

- rumore elettronico (dei componenti);
- rumore ambientale (disturbi elettromagnetici e soprattutto interferenza della rete elettrica a 50 Hz);
- artefatti da movimento (dovuti ai movimenti dell'interfaccia elettrodo-cute o ai movimenti dei cavi che connettono gli elettrodi al front-end di amplificazione, con banda principale tra $0\div 20\text{ Hz}$);
- cross-talk (contributo di muscoli vicini; ad esempio, il segnale ECG può interferire con il segnale EMG, specialmente quando si vuole rilevare l'attività dei muscoli della spalla e del tronco superiore).

È quindi importante che l'elettromiografo presenti:

- elevato CMRR, in quanto la misura dell'EMG è di tipo differenziale e, pertanto, qualsiasi rumore abbastanza lontano dal punto di misura si presenta come modo comune e deve essere efficacemente eliminato;
- elevata impedenza di ingresso dello stadio amplificante per evitare perdita e distorsione del segnale: infatti, l'impedenza della pelle può variare da diverse migliaia di Ω fino a qualche $M\Omega$ a seconda delle condizioni (pelle umida, pulita o sporca, etc.);
- adeguato filtraggio analogico per la rimozione di disturbi e di possibili aliasing.

Ulteriori fattori che influenzano il segnale sEMG sono: le caratteristiche del tessuto, i cambiamenti della geometria tra il ventre muscolare e i siti di rilevazione, e l'affaticamento muscolare.

Il corpo umano è un buon conduttore elettrico, ma sfortunatamente la conduttività elettrica varia a seconda del tipo di tessuto, dello spessore (Fig. 24), dai cambiamenti fisiologici e dalla temperatura. Queste condizioni possono variare molto tra diversi soggetti e spesso anche intrasoggetto.

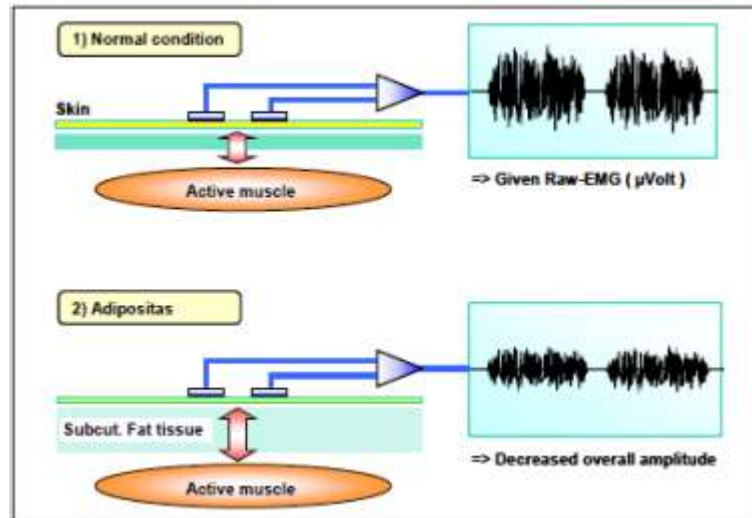


Figura 24: Influenza dello spessore tissutale sull'ampiezza del segnale sEMG.

L'affaticamento muscolare genera sul segnale EMG un incremento in ampiezza, a causa del reclutamento di nuove unità motorie al fine di compensare la riduzione della frequenza di sparo delle unità motorie già reclutate. La fatica muscolare influenza anche lo spettro del segnale, che presenta una compressione verso frequenze più basse, legata ad una riduzione della velocità di propagazione del potenziale d'azione motorio.

Capitolo 3.

Protesi Di Arto Superiore: Stato Dell'Arte

L'arto superiore può essere descritto come un sistema il cui principale organo effettore è la mano, grazie alla quale l'uomo è in grado di compiere un'ampia varietà di funzioni che vengono utilizzate nelle diverse attività della vita quotidiana e lavorativa.

Le condizioni che possono richiedere una protesizzazione di arto superiore comprendono sostanzialmente le amputazioni e le malformazioni congenite.

L'amputazione acquisita e l'assenza congenita a livello glenomerale hanno diverse implicazioni cliniche e presentano, quindi, una distinta gestione protesica. Nel caso di assenza congenita, la clavicola e la scapola presentano mancanza di forma e possono essere fuse. Solitamente vengono ridisegnate tramite osteomioplastica, e le strutture laterali vengono spostate verso l'alto in modo da creare uno sperone osseo molto mobile e assicurare un buon equilibrio tra la forza estrinsecata dai muscoli agonisti e antagonisti, così da assicurare una corretta funzionalità della protesi. La rimanente area della spalla è carnosa e ha quindi il potenziale per sostenere il peso, ma la mancanza di ossa crea un problema per la stabilità. Il profilo della spalla cede abbastanza all'improvviso dal punto osseo dell'area glenomerale, e il giunto della spalla protesica può essere incorporato senza alcuna difficoltà tecnica o cosmetica (4). Nel caso di amputazione acquisita, deve essere valutato, caso per caso, il livello di quest'ultima per decidere quale sia la miglior soluzione protesica. La scelta della protesi da applicare al soggetto deve tener conto di alcuni fattori determinanti, quali la spinta motivazionale del paziente e gli obiettivi che questo si prefigge di raggiungere a seguito di protesizzazione. I fattori predittivi più rilevanti sulla prognosi funzionale risultano essere il livello di amputazione e la mono o bilateralità. In generale, per un paziente con patologia monolaterale di arto superiore, l'arto residuo diviene quello dominante e la protesi si considera come un elemento di aiuto, completamento estetico ed equilibrio. In soggetti con patologia bilaterale, invece, la protesi diventa un elemento imprescindibile per lo svolgimento di funzioni della vita quotidiana.

Altri fattori che influenzano la scelta protesica sono l'età e la capacità di apprendimento del soggetto.

Dalla norme ISO 9999 la protesi può essere definita come un “ausilio ortopedico che vicaria o sostituisce, seppur parzialmente, l'arto mancante sia sotto l'aspetto funzionale che estetico” (5).

Ad una protesi sono richieste, quindi, delle caratteristiche specifiche di funzionalità, affidabilità, peso e ingombro contenuti, associate ad una cosmesi quanto più accettabile. Le caratteristiche basilari cui deve rispondere l'arto artificiale sono riportate nella Tabella 3:

Caratteristica	Descrizione
Funzionalità	<p>Maggior destrezza possibile</p> <p>Buone performance (in termini di velocità e forza/torsione)</p> <p>Solidità appropriata</p> <p>Controllo efficiente</p>
Indossabilità	<p>Estetica quanto più simile a quella umana</p> <p>Peso contenuto</p> <p>Taglia e proporzioni appropriate</p> <p>Confortevole quando indossata</p> <p>Stabilità del socket</p> <p>Semplicità nell'indossare e togliere la protesi</p> <p>Facilità di controllo da parte dell'utente</p>
Specifiche tecnologiche	<p>Elevata affidabilità di ogni componente del sistema artificiale</p> <p>Basso rumore</p> <p>Facilità di riparazione di eventuali danneggiamenti</p>

	Energia sufficiente a garantire un' autonomia di funzionamento della protesi per tutto il giorno
Costo	Prezzo accessibile

Tabella 3: Specifiche a cui deve rispondere l'arto artificiale.

La principale finalità di un braccio protesico è di mimare l'aspetto e sostituire la funzione di un arto mancante. Anche se l'ideale sarebbe una protesi che abbia sia un'estetica naturale che elevata funzionalità, la maggior parte degli arti artificiali che esistono oggi sacrificano un aspetto per l'altro: infatti, determinate performance funzionali implicano spesso l'utilizzo di attuatori che poco si adattano all'ottenimento di un aspetto naturale.

Per questo motivo, è presente un ampio spettro di protesi che vanno da quelle passive, puramente cosmetiche, a quelle attive, più funzionali. In particolare le protesi di arto superiore possono essere classificate in vari modi, a seconda che si utilizzino come discriminanti le caratteristiche funzionali, il tipo di energia utilizzata o il livello di amputazione.

3.1 Classificazione funzionale delle protesi di arto superiore

Considerando le caratteristiche funzionali delle protesi per arto superiore si evidenzia la distinzione in protesi passive ed attive, tenendo conto in un secondo momento delle caratteristiche costruttive e delle modalità di controllo dell'arto (Fig. 25).

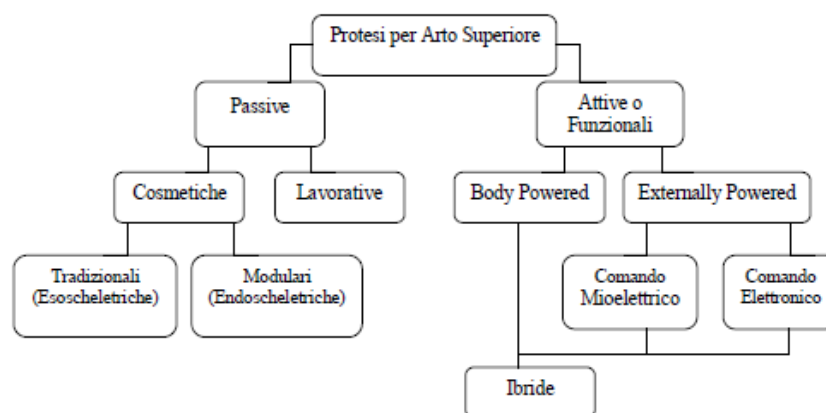


Figura 25: Classificazione funzionale protesi di arto superiore.

Prima di descrivere nel dettaglio le varie tipologie di protesi, bisogna ricordare che una delle opzioni che può essere scelta dal paziente è quella di non adoperare la protesi per determinate attività o di non indossarla affatto. Soggetti che hanno subito una perdita completa del braccio, o che sono nati con questa assenza, possono trovare l'utilizzo di una protesi di alto livello un ostacolo insormontabile. Fattori che contribuiscono al rigetto del device da parte del paziente includono: l'iniziale inesperienza nell'utilizzo del dispositivo, il fastidio causato dal design protesico o dal peso e la mancanza di sensazione tattile (4) (6). Alcuni soggetti con amputazioni di alto livello ritengono che una protesi attiva offra dei limitati vantaggi funzionali. L'accettazione e l'utilizzo dell'ausilio aumentano radicalmente quando il paziente viene coinvolto in un programma che comprende la cura della protesi e terapia professionale (7). Una conseguenza della scelta di non utilizzare una protesi di arto superiore è la sindrome da sovrautilizzo di altre parti del corpo per sopperire alla mancanza dell'arto.

3.1.1 Protesi Passive

a. Protesi Cosmetiche

Le protesi cosmetiche mirano alla ricostruzione estetica dell'arto, o del segmento di arto, mancante volta a ripristinare l'integrità corporea. Possono essere applicate a tutti i livelli di amputazione e vengono utilizzate soprattutto nei casi in cui non possa essere usata con successo una protesi funzionale (ad esempio nella maggior parte delle amputazioni parziali di mano) o quando sia il paziente a rinunciare alla funzionalità dell'arto. Le cause più comuni per cui un soggetto con un'amputazione di alto livello opti per utilizzare una protesi passiva invece di una attiva sono: il peso ridotto, la migliore estetica e la minor richiesta di impegno energetico e cognitivo per l'utente. Inoltre, i costi iniziale di mantenimento e di riparazione sono minori rispetto agli altri tipi di protesi (4).

Questa tipologia di protesi può essere a sua volta suddivisa in (5): protesi cosmetiche tradizionali (o esoscheletriche) e protesi cosmetiche modulari.

Le protesi cosmetiche tradizionali (o esoscheletriche) presentano pareti, costruite con materiali rigidi e che svolgono una funzione strutturale e portante nonché estetica. Trovano applicazione a partire dall'amputazione parziale di dito sino all'amputazione transomerale.

Le protesi cosmetiche modulari (o endoscheletriche) sono costituite da componenti tubolari e modulari che realizzano la funzione portante e strutturale, lasciando ad una copertura di materiale espanso, sagomata con riferimento all'arto residuo, il ruolo cosmetico. Il risultato estetico ottenuto è ottimo, anche grazie al fatto che la protesi risulta morbida al tatto. Si applicano tali protesi per amputazioni transradiali, disarticolazione di gomito e amputazione transomerale.

La protesi passive offrono una forza di presa esigua. Alcune presentano dei fili incorporati nella mano che permettono il posizionamento delle dita protesiche manualmente. L'organo di presa di questi ausili generalmente viene mantenuto in posizione di chiusura da un meccanismo a molla, apribile all'occorrenza con l'arto controlaterale (6) (4) (8).

b. Protesi Lavorative

Tali protesi vengono generalmente realizzate per amputazioni a livello delle dita o del carpo della mano e sono costituite da ausili specifici che hanno lo scopo di facilitare l'attività lavorativa (8). Queste protesi permettono al paziente di svolgere attività di suo interesse e di "tornare alla vita normale" in maniera tangibile. Spesso, più di una protesi è necessaria per rispondere alle necessità e ai desideri dell'utente (6). Le protesi lavorative (Fig. 26) richiedono un controllo semplice e poche componenti e quindi, molte volte, risultano meno costose rispetto a quelle con un design più complesso. L'evidente svantaggio di questa tipologia di protesi è la loro utilità limitata ad una determinata attività (4).



Figura 26: Esempi di protesi lavorative.

3.1.2 Protesi attive

a. Protesi Body-powered

Le protesi ad energia corporea sono le protesi cinematiche, che sfruttano, per l'attivazione della mano e/o del gomito protesico, il movimento di una regione corporea ancora attiva, mediante l'utilizzo di cavi che vengono azionati da bretellaggi. Muovendo il corpo in un determinato modo, vengono tirati i cavi e si ottiene l'azionamento della protesi. I movimenti che vengono sfruttati consistono nella flessione, estensione, abduzione, depressione ed elevazione della spalla e abduzione bicipolare (estensione toracica) (9). Risulta evidente che, con queste protesi, diventa fondamentale il trattamento fisiokinesioterapico di preparazione al trattamento protesico stesso, ed altrettanto importante diviene la fase post protesica, in cui si insegna il corretto utilizzo dell'ausilio al paziente. Le protesi cinematiche trovano applicazione a partire dalla disarticolazione di polso fino al terzo medio transomerale. Per livelli di amputazione più prossimali diventa difficile ottenere buoni risultati funzionali, in quanto, la presenza di un moncone molto corto, implica leve molto svantaggiose, tali da rendere difficoltoso l'azionamento della protesi. Con questo tipo di protesi, le funzioni possibili sono limitate all'apertura o chiusura della mano (vincendo la resistenza di una molla che la terrebbe nella posizione opposta) e alla flessione-estensione, blocco-sblocco di un eventuale gomito.

Le protesi ad energia corporea risultano ben tollerate dal paziente per la loro affidabilità, robustezza, assenza di accumulatori di energia elettrica e per il fatto che permettono al paziente di ricevere un buon feedback durante il funzionamento. Esse sono più leggere delle protesi *externally-powered* e il peso risulta meglio distribuito rispetto alla maggior parte dei dispositivi *externally-powered* e ibridi. Inoltre, il sistema a cavi non richiede una batteria che debba essere ricaricata, installata o rimossa, o abilità cognitive particolari. Un altro aspetto da considerare è il costo più contenuto rispetto alle protesi *externally-powered* (4) (5). Tuttavia, oltre ad avere un aspetto non molto naturale, queste protesi sono in grado di generare una limitata forza prensile, richiedono un elevato dispendio energetico a causa dei movimenti necessari a sviluppare abbastanza forza ed escursione per attivare le varie componenti (fattore che limita anche il range di movimento), e possono essere ritenute scomode in corrispondenza dei punti di ancoraggio (4). Inoltre, l'utilizzo prolungato delle protesi *body-powered* può accelerare fenomeni debilitanti per la spalla o il disequilibrio

muscolare e creare fastidio ai nervi (6). Un esempio di protesi body-powered è riportato in Fig. 27.



Figura 27: Esempio di protesi body-powered.

b. Protesi Externally-Powered

Le protesi externally-powered generano una maggiore forza di presa, permettono apertura e chiusura volontarie e, anche se il giunto protesico della spalla permette solo un posizionamento passivo, aumentano il range di movimento possibile riducendo o eliminando totalmente i bretellaggi necessari per una protesi body-powered, minimizzando così il dispendio energetico e il fastidio associato a queste ultime.

Il peso di un sistema completamente elettronico è consistente e bisogna fare attenzione che l'invasatura (o *socket*) dia un sostegno adeguato. Questa tipologia di protesi si avvale di batterie che richiedono operazioni di installazione, rimozione e mantenimento. Inoltre, la tipologia di controllo elettronico primario e secondario necessita di un impegno cognitivo notevole da parte del paziente. Sono ottenibili movimenti di flessione-estensione, al livello del gomito, prono-supinazione a livello del polso e apertura e chiusura a livello della mano (4) (6). Fanno parte di questa categoria di protesi quelle a comando mioelettrico e quelle a comando elettronico.

Le protesi funzionali a comando mioelettrico ed elettronico possono essere applicate a partire dalla disarticolazione del polso fino alla disarticolazione di spalla; alcune aziende propongono soluzioni per amputazioni parziali di mano.

Per le protesi funzionali ad energia extracorporea, uno dei fattori principali dell'innovazione si gioca sul tipo e sulla gestione della fonte di energia utilizzata. Tale sorgente è rappresentata da un accumulatore ricaricabile a circa 6-8 V collocato all'interno del socket. Gli accumulatori al Ni-Cd, che presentano un accettabile compromesso fra

energia erogabile, dimensioni e peso, garantiscono un'autonomia giornaliera di circa 1000-2000 movimenti e fino a 8000 movimenti con una sola ricarica, tramite la modalità di funzionamento a basso consumo. Uno degli aspetti più negativi degli accumulatori al Ni-Cd è la grande tossicità del Cd, che è stata superata grazie alle nuove batterie al Li che, a parità di dimensioni, assicurano una durata maggiore. Anche sul tempo di ricarica delle batterie stesse, si sono fatti notevoli progressi, ottenendo tempi inferiori all'ora.

Le protesi a comando mioelettrico sfruttano, per l'attivazione degli elementi funzionali del dispositivo, segnali elettromiografici generati dalla contrazione della muscolatura del moncone. Il segnale viene registrato tramite degli elettrodi posti sulla cute, processato e convertito in comando per i motori dei giunti al fine di ottenere un movimento funzionale e più naturale dell'arto artificiale, seguendo lo stimolo nervoso dell'utente. Il soggetto può persino controllare la forza, la velocità di movimento e la presa della protesi, variando l'intensità della propria contrazione muscolare. Inoltre, i precisi sensori e i controlli motorizzati permettono una notevole destrezza, consentendo la manipolazione e l'utilizzo di piccoli oggetti, quali chiavi o carte di credito, grazie al funzionamento delle dita. Oltre a questa elevata destrezza, gli arti artificiali a controllo mioelettrico non necessitano alcun sacrificio dell'aspetto estetico: utilizzando una batteria e un sistema elettronico per funzionare, non richiedono ingombranti cinghie o bardature. Al contrario, sono customizzate per adattarsi ed essere fissate alla componente residua tramite tecnologia a suzione. Le versioni più avanzate di queste protesi appaiono esteticamente naturali, all'altezza delle protesi puramente cosmetiche (10).

Presupposti necessari per l'applicazione di una protesi a controllo mioelettrico tradizionale sono: la disponibilità di segnali di ampiezza tale da essere riconosciuti dai sensori, e l'abilità del paziente di azionare in modo isolato e volontario i gruppi muscolari che li generano. Quest'ultima condizione si rende necessaria in quanto, nel controllo mioelettrico tradizionale, si associa ad una coppia di elettrodi un movimento (es. apertura della mano) e ad una seconda coppia quello opposto (es. chiusura della mano). Di conseguenza, il sistema di controllo attua il movimento sulla base del sensore che fornisce un segnale. Il tutto funziona correttamente se viene attivato un muscolo per volta, altrimenti il sistema di controllo si trova a dover eseguire due ordini contrastanti e quindi la protesi ha un funzionamento errato (5).

L'esperienza clinica ha mostrato che la protesi mioelettriche possono prevenire la riorganizzazione corticale e riducono l'incidenza del dolore all'arto fantasma.

I principali svantaggi di questo tipo di protesi sono il loro peso, il loro costo e la fragilità di alcune componenti. Il peso è dovuto al fatto che queste protesi contengono una batteria e un motore. Inoltre, con l'avanzare della tecnologia, il peso di ogni componente andrà diminuendo, minimizzando il problema. L'altro svantaggio è il loro costo: anche se al momento sono più costose delle altre tipologie protesiche, esse offrono la migliore qualità relativamente ad estetica e funzionalità. Come il problema del peso, si stima che anche il costo di questi dispositivi andrà diminuendo con il miglioramento della tecnologia di produzione (10). Altri svantaggi che si riscontrano, rispetto alle protesi body-powered, sono i fallimenti tecnici, maggiore tempo di risposta, minore scelta per quanto riguarda i *terminal devices* intercambiabili, minor feedback sensoriale e il fatto di possedere una batteria che debba essere ricaricata (11).

Esistono tre tipi di controllo mioelettrico (9):

1. Digitale: risponde alla "legge del tutto o nulla", sviluppando una forza prestabilita. Il movimento della protesi avviene per mezzo dell'azione di un muscolo e del suo antagonista, sfruttando una coppia di elettrodi per movimenti opposti;
2. Proporzionale: utilizza un solo elettrodo. L'intensità del segnale registrato funge da discriminante per il movimento che verrà eseguito dall'arto artificiale. Questo tipo di controllo viene impiegato nelle amputazioni più prossimali, spesso bilaterali e con pochi muscoli a disposizione;
3. Multicanale: viene utilizzato qualora vi sia la necessità di attivare diverse componenti protesiche sfruttando una coppia di elettrodi a controllo proporzionale. Una tecnica presentata in letteratura (9), in caso di sei movimenti da comandare, ricorre al funzionamento ciclico, che prevede l'utilizzo di tre elettrodi: due per effettuare il movimento ed un terzo come selettore della funzione attiva. Tale soluzione obbliga di fatto il paziente ad attivare un motore alla volta, rallentando l'effettuazione di movimenti composti, ma con il vantaggio di rendere sicura e precisa la selezione del gesto desiderato.

Le protesi a comando elettronico esistenti sono di diverse tipologie, tra cui: gli *switches* e gli *slider-type input device*.

- **Switches:** attraverso diversi tipi di switch, può essere eseguita una vasta varietà di movimenti. Molti switch sono attivati tirando un cavo, premendo una leva o un pulsante. Essi sono pensati per attivare funzioni multiple. Una tipologia di switch (switch a bardatura) si affida all'escursione o ad altri tipi di tiraggio per attuare la commutazione. Un'ulteriore gamma di switch (push switch) viene attivata premendo con il mento, dita focomeliche, arto residuo o mano controlaterale. Tale switch può essere posizionato, per gli amputati trans radiali, distalmente all'ascella (lungo il torso o sul lato interno dell'avambraccio) ed essere attivato dall'abduzione omerale. Un terzo tipo di switch (switch multi posizione) che offre, a seconda della posizione selezionata una funzione. Inoltre gli switch possono essere momentanei (si ha attuazione finchè lo switch è mantenuto premuto) o "a scatto" (mantengono la funzione finchè la persona non lo ripreme nuovamente) (6). Questi due tipi di switch vengono riportati in figura (Fig. 28).



Figura 28: Switch momentanei (sinistra) e a scatto (destra) per protesi elettriche (Cortesia di Otto Bock®).

- **Slider-type input device:** convertono la distanza di escursione (Fig. 29), la velocità, o la forza in movimenti proporzionali dell'arto protesico.

Gli attuatori slider-type sono di due tipologie: il potenziometro lineare e il controllo *force sensing*. Il primo è un dispositivo servo che traduce il movimento lineare, o l'escursione, in una funzione proporzionale. Esempi di potenziometro lineare sono: il Liberating Technologies Linear Potentiometer® e l'Otto Bock Linear Transducer®. Il secondo è un dispositivo servo che traduce l'informazione acquisita tramite una misura di sforzo per attivare in maniera proporzionale un dispositivo che è stato programmato con un microprocessore o un sistema elettronico. Un esempio è il Motion Control's ServoPro®.



Figura 29: Attuatore slider-type.

Uno degli svantaggi delle protesi a comando elettronico è il loro peso, che può causare affaticamento muscolare o frizione con l'arto residuo. L'umidità che si forma può risultare un problema per la circuiteria elettronica se non vengono utilizzate appropriate tecniche di fabbricazione *water resistant*. Il costo di riparazione di queste protesi è abbastanza elevato ma un appropriato programma di manutenzione può ridurre notevolmente questo inconveniente.

c. Protesi ibride

Le protesi ibride (Fig. 30) combinano componenti ad energia corporea con quelli ad energia extracorporea. La configurazione più comune incorpora un gomito body-powered con un terminal device e polso externally-powered.



Figura 30: Esempio di protesi ibrida.

Le protesi ibride offrono i vantaggi di entrambe le tipologie di protesi e minimizzano i loro svantaggi. L'utilizzo di un terminale elettronico riduce la necessità di bardature in quanto il movimento ad energia corporea è richiesto solo per la flessione del gomito. Il range di movimento aumenta quando è possibile il controllo mioelettrico. Anche la forza di presa è

maggiore quando è disponibile un dispositivo elettronico al posto di un body-powered. Inoltre, un terminal device elettronico permette l'apertura e la chiusura volontarie della mano, generando un movimento più naturale. Si ritiene che l'utilizzo di una mano a controllo mioelettrico migliori il tono muscolare scongiurando il pericolo di atrofia. In caso di utilizzo di un polso elettromeccanico, il peso risulta inferiore ed è assicurata una buona funzionalità. Tali protesi sono disponibili anche per pazienti con amputazioni transomerale o superiori se ci sono forza ed escursioni residue adeguate. I costi iniziale, di mantenimento e di riparazione, sono inferiori per un dispositivo ibrido, in quanto non è presente il gomito elettronico. Altro aspetto molto importante è che l'utilizzo di un sistema di controllo ibrido può incoraggiare a svolgere operazioni che coinvolgano simultaneamente gomito e terminale device (4).

Si riporta nella Tabella 4, una sintesi delle caratteristiche delle varie tipologie di protesi illustrate:

Tipo	Vantaggi	Svantaggi
Cosmetiche	Più leggere Migliore estetica Assenza di bretellaggi	Costi elevate su fatte su misura Minor funzionalità Il guanto low-cost si macchia facilmente
Body Powered	Costi moderati Moderatamente leggere Più duratura Più elevato feedback sensoriale Disponibilità di varie terminazioni prensili per diverse attività	Sono necessari molti movimenti corporei per farla funzionare Presenza di cavi e bretellaggi Estetica meno soddisfacente per il paziente Maggior dispendio energetico
Elettrically Powered (mioelettriche/switch controlled)	Bretellaggi limitati o assenti Necessità di pochi movimenti corporei per il funzionamento Cosmesi accettabile Più funzioni nell'area prossimale	Più pesante e costosa Necessita di un training più lungo prima di poter essere utilizzata Necessita di maggiore manutenzione

	Presenza più forte in alcuni casi	Limitato feedback sensoriale
Ibride	Bretellaggi limitati al movimento del gomito Maggiore range di movimento Maggiore forza di presa Movimento più naturale Minori costi di mantenimento e riparazione	Maggior peso delle battery-powered Terminal device sull'avambraccio (più difficile da sollevare ma migliore per disarticolazioni del gomito o lungo THA) Cosmesi peggiore

Tabella 4: Vantaggi e svantaggi delle varie tipologie di protesi.

3.2 Classificazione per livello di amputazione

Un altro metodo di classificazione delle protesi di arto superiore considera i livelli di amputazione, mostrati in figura (Fig. 31).




Figura 31: Livelli di amputazione di arto superiore.

Per questa suddivisione si richiama la norma ISO 9999 (o EN29999 per la sola Europa) classe 06.18 che individua le categorie riportate in Tabella 5:

Codice ISO 9999	Descrizione
06 18 03	Protesi di dito ed amputazione parziale di mano
06 18 06	Protesi per disarticolazione di polso
06 18 09	Protesi per amputazione transradiale
06 18 12	Protesi per disarticolazione di gomito
06 18 15	Protesi per amputazione transomerale
06 18 18	Protesi per disarticolazione di spalla
06 18 21	Protesi per amputazione interscapolotoracica

Tabella 5: Codice ISO 9999 per i vari livelli di amputazione di arto superiore.

3.3 Design

La perdita o l'assenza di un arto, ad ogni livello, sia per un'amputazione che per una malformazione congenita, affliggono drammaticamente l'immagine che l'individuo ha del proprio corpo e la sua autostima, e questo impatto psicologico deve essere tenuto in grande considerazione durante la progettazione della protesi appropriata. Oltre a questo e agli ovvi aspetti prettamente fisici, nella fase di design si devono considerare anche quelle che sono le aspettative del paziente: individui con livelli simili di assenza dell'arto possono richiedere strategie completamente differenti per raggiungere un risultato soddisfacente. L'esperienza dimostra che un soggetto rifiuta la protesi se questa non risponde alle sue basilari richieste personali legate a funzione, estetica o aspetti psicologici (6).

La protesi di arto superiore è costituita da un'invasatura, da parti di collegamento, eventualmente dotate di articolazioni, e da un terminal device che funge da organo di presa (Fig. 32).




Figura 32: Componenti di una protesi attiva di arto superiore.

Verranno di seguito riportate le caratteristiche e le tipologie presenti sul mercato di ciascuna componente.

3.3.1 Invasatura

L'invasatura è la parte della protesi che va a contatto con il moncone. Deve quindi essere personalizzata per ciascun paziente in modo da garantire una perfetta simbiosi con quest'ultimo e costruita con materiali anallergici (solitamente laminato acrilico o materiale termoplastico). Una buona riuscita del programma protesico è vincolata alle buone condizioni del moncone: esso viene stoffato, evitando eccessi di tessuti molli o salienze ossee prominenti. La corretta conformazione del moncone viene ottenuta applicando quotidianamente dei bendaggi elastici a otto ed intervenendo anche tramite osteomioplastica. Per ridurre al minimo contratture, retrazioni, rigidità articolare e ipertrofia muscolare risultano indispensabili un corretto posizionamento e una mobilizzazione precoce dell'arto in fase post chirurgica. L'invasatura viene realizzata partendo dal modello negativo di gesso del moncone, e deve garantire il perfetto controllo della protesi, anche nel compiere le manovre più complesse. Deve essere aderente al moncone, pur senza causare fastidio o dolore al paziente; per questo motivo tra l'invaso e il moncone viene generalmente interposto un *liner* in silicone che fornisce una migliore sospensione riducendo l'effetto pistone e la traslazione, protegge la pelle riducendo le forze di trazione e limita in parte i cambi di volume fisiologici del moncone (9). Nelle

protesi a comando mioelettrico occorre predisporre nell'invasatura una sede per ospitare gli elettrodi deputati a registrare il segnale elettromiografico e l'accumulatore. Anche questa operazione deve essere fatta con la massima cura per permettere al paziente di controllare bene la protesi stessa. Occorre che gli elettrodi siano posti su muscoli che forniscano un segnale elettromiografico di ampiezza sufficiente e che non interferiscano tra di loro, ed inoltre che non si attivino a seguito di altri movimenti, se non quelli desiderati. Da questa breve descrizione si evidenzia come sia importante, ed allo stesso tempo complesso, costruire una invasatura ottimale e come, nel caso di protesi mioelettriche, sia problematico posizionare correttamente gli elettrodi (5).

Recentemente è stato sviluppato, presso il Sahlgrenska University Hospital, in collaborazione con la Chalmers University, un sistema che permette l'impianto diretto della protesi e che consente di eliminare tutti i problemi connessi alla presenza del socket. Tale protesi (Fig. 33), denominata Osseointegrated Protheses for the Rehabilitation of Amputatees (OPRA®) (12), consta di un impianto in titanio, che permette l'ancoraggio diretto al moncone, e di elettrodi impiantati permanentemente a livello dei nervi e dei muscoli residui di un soggetto amputato per controllare direttamente la protesi di arto. Si può anche fornire al paziente un livello di feedback grazie alla presenza di elettrodi che stimolano opportunamente il percorso neurale afferente.




Figura 33: OPRA® del Sahlgrenska University Hospital.

L'OPRA® fornisce alcuni vantaggi rispetto alle protesi dotate di socket: permette infatti un maggior grado di movimento, aumenta il comfort, evita irritazioni alla pelle e dà una maggior sensazione che la protesi sia parte del corpo. Inoltre, utilizzando elettrodi impiantabili, si possono rilevare più segnali e quindi controllare un maggior numero di movimenti. Il più grande svantaggio dell'OPRA® consiste nell'essere un impianto percutaneo e quindi soggetto ad un elevato rischio di infezione che può portare alla necessità di rimuovere l'impianto e, in alcuni casi, di una amputazione più alta in modo da prevenire un'infezione sistemica.

3.3.2 Parti di collegamento

Le parti di collegamento si interpongono tra l'invasatura e l'organo di presa e, a seconda del livello di amputazione del paziente, possono presentare articolazioni. Tali connessioni possono essere suddivise in esoscheletriche, nel caso in cui le pareti esterne della protesi abbiano un ruolo strutturale, o endoscheletriche, se la componente esterna ha solo funzione estetica e il ruolo portante è svolto da una struttura modulare interna.

Le articolazioni che possono essere presenti in queste parti di collegamento sono: l'articolazione della spalla, l'articolazione del gomito e l'articolazione del polso.

Per l'articolazione della spalla sono presenti 3 opzioni: giunto non articolato, giunto di frizione e giunto di bloccaggio.

- Il giunto non articolato viene utilizzato nei bambini o per pazienti che richiedono una protesi specifica per lo svolgimento di una determinata attività poiché essa minimizza il peso aggiunto, il volume e la complessità di questa porzione di organo artificiale.
- Il giunto di frizione permette al paziente di posizionare il braccio nello spazio, il che è utile per mangiare, prendersi cura di sé e altre attività. È il giunto articolato più semplice ma ha lo svantaggio che l'arto controlaterale deve essere utilizzato per il posizionamento dell'arto artificiale.
- Il giunto di bloccaggio consente al paziente di posizionare e poi bloccare la sezione omerale nello spazio, permettendo un'attività bimanuale. Il meccanismo di bloccaggio può essere attivato spingendo leggermente con il mento una *nudge control unit* (Fig. 34).



Figura 34: Nudge control unit.

L'abduzione biscopolare, l'elevazione della spalla, e i movimenti omerali rimanenti, inclusi flessione, estensione e adduzione, possono essere catturati attraverso un sistema ad imbragatura per attivare un pull switch. La nudge control unit e il pull switch sono offerti sia nella versione meccanica che in quella elettrica. Quest'ultima richiede una minor forza ma risulta essere più complessa.

Per l'articolazione del gomito sono presenti 2 tipologie (Fig. 35): body-powered o electric-powered.

- Il body-powered è più leggero e fornisce un feedback sensoriale ma richiede una maggiore escursione e forza per essere attivato. I gomiti body-powered possono essere flessi più velocemente rispetto a quelli elettronici ma, a questo livello, la leva scheletrica del braccio è così compromessa che molti pazienti trovano difficoltoso, se non impossibile, produrre un'escursione sufficiente per flettere completamente e bloccare un gomito ad energia corporea. Senza l'utilizzo di un gomito multiposizione, l'amputato non può posizionare il dispositivo terminale (end effector) nello spazio per compiere i movimenti della vita giornaliera. In passato, per ovviare a questa limitata escursione, veniva utilizzato un amplificatore di escursione che però richiede al soggetto di produrre una forza molto elevata, cosa che tanti hanno giudicato sgradevole.
- Gli electric-powered sono i più utilizzati in quanto richiedono molto meno sforzo per funzionare rispetto a quelli ad energia corporea. Vengono comandati con appositi sensori. Risultano essere più pesanti rispetto ai body-powered, ma risultano essere la migliore soluzione per monconi risultanti da amputazioni transomerale particolarmente prossimali e per disarticolazioni di spalla. Questi device sono forniti in commercio dalle aziende Utah, Hosmer.



Figura 35: Esempi di gomiti body-powered ed electrical-powered.

L'articolazione del polso (Fig. 36) presenta quattro proprietà basilari: frizione, bloccaggio, flessione e disconnessione rapida. Il polso permette all'utilizzatore di posizionare l'end effector utilizzando la mano controlaterale o movimenti compensatori del corpo. La scelta del polso si basa sulle richieste funzionali del paziente e non sul livello di amputazione o menomazione.



Figura 36: Esempi di polso di protesi attiva di arto superiore.

3.3.3 Terminal Device

Esistono numerosi e vari dispositivi che fungono da organo di presa. Essi si differenziano a seconda del ruolo prevalentemente estetico o funzionale che devono svolgere. Per quanto riguarda la mano, essa può essere ad apertura volontaria (rimane chiusa fino a che, tirando un cavo, si apre e il rilassamento chiude la mano intorno all'oggetto con una forza di presa predeterminata) o a chiusura volontaria (rimane aperta finché, tirando un cavo, si aziona la chiusura, che avrà una forza di presa proporzionale alla forza che il soggetto ha esercitato

per tirare il cavo) (13). Le tipologie di terminal device più diffuse sono: l'uncino, il body-powered e l'electric-powered.

- L'uncino è considerato più funzionale di una mano ad energia corporea per attività giornaliere che richiedono una certa precisione. Inoltre, i pazienti lo preferiscono per il suo design semplice e la sua utilità per mansioni pesanti. La preferenza dell'uncino è più evidente in caso di protesi body-powered, ma esistono anche protesi externally-powered con un uncino come terminal device. Esso può essere di alluminio, acciaio o titanio, che lo rendono molto durevole, e può presentare una fodera in gomma per migliorare la presa. La forza prensile di uncini ad apertura volontaria è determinata dal numero di nastri di gomma che lo tengono chiuso. La terminazione ad uncino permette una miglior visibilità durante la presa e la manipolazione degli oggetti (4).
- I body-powered terminal device forniscono una forza di presa minore e richiedono elevata escursione e forza per funzionare. Inoltre, i pazienti con questo livello di assenza spesso trovano la mano ad energia corporea difficile da utilizzare a causa delle corte dimensioni della leva dell'avambraccio residuo a questi livelli.
- Gli electric-powered terminal device sono quelli maggiormente utilizzati per amputazioni e menomazioni a questo livello, in quanto richiedono il movimento di un minor volume corporeo per funzionare e forniscono una forza di presa maggiore. Nelle versioni più tradizionali è presente un meccanismo interno e un sottile guanto esterno. Anche se l'aspetto esteriore è quello di una mano naturale, il meccanismo interno è costituito da solo 3 dita (il pollice, l'indice e il medio) che generano la forza prensile. La mano si apre e chiude in un unico modo, e tutte le dita si muovono insieme formando un movimento di presa.

3.4 Protesi robotizzate di spalla in via di sviluppo

3.4.1 Protesi del gruppo Sistemi Uomo-Macchina (Politecnico di Milano)

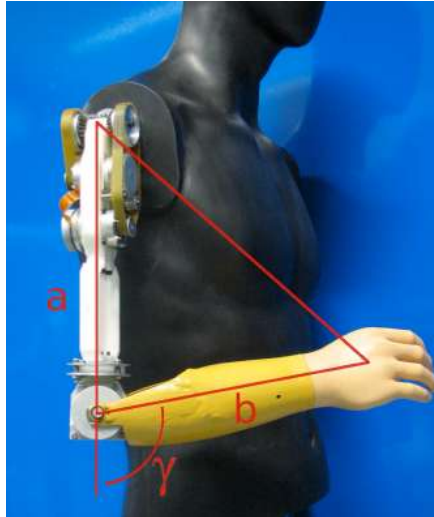


Figura 37: Protesi attiva di arto superiore del gruppo Sistemi Uomo-Macchina del Dipartimento di Ingegneria Meccanica del Politecnico di Milano

La protesi attiva di arto superiore qui descritta (Fig. 37) rappresenta il caso studio di partenza di questo lavoro di tesi ed è stata realizzata dal gruppo Sistemi Uomo-Macchina del Dipartimento di Ingegneria Meccanica del Politecnico di Milano (14). Il prototipo di terza generazione implementa, in sostituzione dell'articolazione della spalla, un sistema differenziale composto da tre ruote coniche realizzate in materiale plastico. Il meccanismo è movimentato da una coppia di motori brushless in corrente continua collegati rispettivamente a due riduttori. I motori, modello Maxon Motor EC 45, sono alimentati a una tensione pari a 12 V e sono in grado di erogare 30 W di potenza. I riduttori sono Harmonic Drive, HDC-010-Metric della Harmonic Drive Technologies, con rapporto di riduzione 1:80. Data l'incapacità dell'harmonic drive di reggere carichi trasversali, è presente una struttura di sostegno, costituita da un tubolare in alluminio, unito al motore tramite un elemento di giunzione, che alloggia al suo interno un cuscinetto a sfere che sostiene il circular spline del riduttore. Per la trasmissione del moto al sistema differenziale, la protesi utilizza un sistema a cinghia e pulegge dentate, che aumenta ulteriormente il rapporto di riduzione.

Il telaio è realizzato in materiale DELRIN, dotato di alta resistenza meccanica e durezza, e comprende i fori per l'alloggiamento dei gruppi motoriduttori.

A livello dell'articolazione della spalla, il sistema differenziale è costituito da due telai e da tre ruote coniche dentate (come mostrato in Fig. 38).




Figura 38: Sistema differenziale relativo all'articolazione della spalla.

Una ruota conica (RUOTA 1) è solidale con la spalla mentre le altre due sono libere di ruotare rispetto all'asse B. Il primo telaio (TELAIO 1) è libero di ruotare intorno all'asse A in modo da seguire l'asse B, mentre il secondo telaio (TELAIO 2) è libero e solidale al telaio del braccio.

Il sistema differenziale, quindi, consente movimenti intorno agli assi A e B attraverso la combinazione delle rotazioni delle ruote dentate 2 (RUOTA 2) e 3 (RUOTA 3). In particolare, velocità angolari uguali in modulo ma di segno opposto determinano una rotazione attorno all'asse A, producendo un movimento di flessione-estensione della spalla; velocità angolari uguali in modulo e in segno determinano una rotazione intorno all'asse B, generando un movimento di abduzione-adduzione della spalla; infine, combinando velocità angolari diverse sia in modulo che in segno, si genera un movimento composto della spalla.

A livello del gomito, la protesi è dotata di un giunto a frizione, rappresentato in figura (Fig. 39), realizzato con due dischi di materiale autolubrificante premuti mediante il serraggio di bulloni, la cui funzione è quella di assicurare il sistema contro eventuali urti. Infatti, in caso di urto violento, tale giunto permette all'omero artificiale di ruotare intorno al proprio asse e di evitare quindi il propagarsi della sollecitazione alla spalla.



Figura 39: Giunto di frizione del gomito.

Il movimento di flessione-estensione del gomito è realizzato sfruttando un gruppo motoriduttore, come quello presente a livello della spalla.

Per la parte terminale della mano, il sistema presenta la mano commerciale Otto-Bock® dotata di due gradi di libertà: uno di prono-supinazione del polso e il secondo di apertura-chiusura della mano.

3.4.2 Protesi INAIL



Figura 40: Protesi attiva di arto superiore del Centro Protesi INAIL di Vigorso di Budrio.

Il Centro Protesi INAIL di Vigorso di Budrio ha sviluppato, nel 2008, in collaborazione con l'Università di Bologna, una protesi di spalla attiva (Fig. 40), externally-powered a comando mioelettrico, con due gradi di libertà adatta per gli amputati interscapolotoracici e transomerali (15).

L'articolazione consta in due giunti motorizzati connessi, che permettono l'elevazione del braccio in qualunque piano verticale passando attraverso il centro di rotazione della spalla. La protesi incorpora anche un controllore in grado di gestire fino a cinque giunti motorizzati con diverse strategie di controllo, in accordo con le preferenze dell'amputato.

Il modello di spalla elaborato (Fig. 41) prevede due giunti motorizzati con assi ortogonale e assiale ed un giunto passivo: i due gradi di libertà permettono il movimento sferico del braccio, mentre il giunto di frizione passivo permette la rotazione omerale.




Figura 41: Schema cinematico della protesi INAIL (sinistra) e prototipo (destra).

I due giunti connessi, J_1 e J_2 , attuano la rotazione θ_1 intorno all'asse verticale (fissato all'invasatura della protesi) e la rotazione θ_2 intorno all'asse orizzontale, la cui orientazione è determinata da θ_1 . Quindi, l'attuazione del primo giunto seleziona il piano verticale lungo il quale il secondo giunto eleva il braccio. J_1 è un semplice giunto di rotazione, mentre J_2 è composto da un meccanismo *slider-crank* invertito. Quest'ultimo permette di ottenere una coppia elevata senza l'utilizzo di un riduttore di velocità con un elevato rapporto di trasmissione.

Il giunto di frizione passivo è semplicemente integrato all'estremità del secondo giunto.

La Tabella 6 riporta le specifiche dei due giunti motorizzati.

Giunto	Motore	Voltaggio nominale [V]	Potenza max uscita [W]	Stall Torque [N*mm]	Rapporto di riduzione totale	Efficienza meccanica
J ₁	DC commerciale	6	4,55	21,2	1:1050	0,25
J ₂	DC commerciale	12	17,00	80	Non costante (max=1:1187)	0,45

Tabella 6: Specifiche dei giunti motorizzati della spalla.

L'unità di controllo impiantata è stata realizzata basandosi sui massimi voltaggi e correnti richiesti dai motori e sulla compatibilità con le componenti protesiche in commercio. Tale unità consiste in un microcontrollore Microchip PIC18F4431 e in cinque *motor driver*. Ricevendo come input al massimo 4 segnali EMG, il controllore è in grado di gestire i 5 motori dell'arto protesico (cioè spalla, gomito, polso e mano). Riferendosi allo schema di controllo comune che prevede l'attivazione sequenziale dei giunti uno alla volta, sono state implementate nel controllore 3 strategie per il *joint switching* : *EMG-co contraction*,^{3rd} *electrode selection* e *double command*.

I test clinici hanno evidenziato margini di miglioramento. In primo luogo, il controllo sequenziale con switch a trazione non sfrutta l'elevata mobilità della protesi, quindi sono necessarie nuove strategie di controllo. Secondariamente, il meccanismo risulta essere molto rumoroso e questo va modificato riconsiderando la fattura ed il design degli elementi. Infine bisogna ridurre il carico sul moncone e sul torace del paziente durante il funzionamento e quindi risulta necessario modificare l'invasatura utilizzata, ad esempio ampliando l'area di contatto.

3.4.3 DEKA "Luke" Arm

La Luke arm® (Fig. 42), sviluppata nel 2007 dal team DEKA (Manchester, New Hampshire), è una protesi modulare progettata in "sezioni" per poterla adattare a diversi livelli di amputazione. Nel caso di disarticolazione della spalla, la struttura prevede 18 gradi di libertà forniti attraverso un abduttore/adduttore e un flessore/estensore della spalla, un rotatore omerale, un flessore/estensore del gomito, un rotatore e un flessore del polso, e una mano sofisticata a 11 gradi di libertà.




Figura 42: Luke arm® del team DEKA (Manchester, New Hampshire)

Il braccio realizzato ha dimensione e il peso (3,6 Kg) dell'arto superiore di una donna appartenente al cinquantesimo percentile, così da risultare confortevole per molti utenti.

Gli elementi funzionali (16) sono descritti di seguito:




Figura 43: Componenti della Luke Arm® (16).

- L'abduzione/adduzione della spalla include l'Harness Mount, elemento di connessione dell'apparato protesico con il suo supporto e lo Shoulder Flexion Assembly Mount, che lo interfaccia con il flessore della spalla. Il movimento viene generato da un motore brushed DC che trasmette la rotazione ad un Harmonic Drive tramite un sistema a cinghie ed una ruota dentata.
- Il flesso/estensore della spalla presenta un motore a magneti, che trasmette la rotazione, tramite un sistema cinghia/puleggia, ad un Harmonic Drive, il quale

funge da riduttore di velocità e permette l'attuazione del movimento di flesso/estensione della spalla. Intorno al Circular Spline dell'Harmonic Drive è posizionato un Compliance Subassembly, costituito da elementi elastici e reattivi che attenuano il trasferimento di eventuali urti violenti al resto del componente di flessione. Inoltre, il Compliance Reactor è in grado di misurare il proprio spostamento rispetto al Compliance Sensor Magnet.

Esso possiede un sistema di bloccaggio in grado di far mantenere la posizione all'arto quando non è in movimento.

Il blocco di flesso/estensione si interpone tra il componente di abduzione/adduzione della spalla e il rotatore omerale.

- Il rotatore omerale include il Control Housing, che lo connette al flesso/estensore della spalla.

Il movimento è generato attraverso un motore a magneti, la cui velocità angolare è ridotta tramite un Harmonic Drive che produce la rotazione assiale finale, misurata tramite un potenziometro angolare.

- Il flesso/estensore del gomito include il giunto del gomito e il Radial Mount. Il primo comprende un motore a magneti il cui movimento è trasmesso ad una Sun Gear e quindi a 4 Planetary Gears che, ruotando nel Ring Gear, generano la rotazione del Planetary Carrier che funge da Wave Generator per un Harmonic Drive, dando luogo ad un doppio stadio di riduzione della velocità. Include inoltre l'interfaccia con il rotatore del gomito. Il Radial Amount fornisce un alloggiamento per l'Arm Control Module e include l'interfaccia di connessione con il rotatore del polso.

Anche qui è presente un Compliance Subassembly che attenua l'ampiezza della torsione in caso di urto violento.

- Il rotatore del polso comprende un motore a magneti e il movimento è controllato da un Harmonic Drive simile a quello del rotatore omerale. Presenta un potenziometro, per la misura della rotazione, ad una estremità dell'albero del polso, che può essere tubulare e presenta dei canali per il passaggio dell'energia elettrica.
- Il flesso/estensore del polso si interfaccia con il rotatore del polso e con la mano. Possiede una connessione elettrica per fornire energia al motore responsabile dell'azionamento di un sistema a ruote che produce la rotazione dell'Output Arm.

In caso di urto violento, l'impatto è attenuato da elementi elastici, presenti nell'Output Arm, che si comprimono.

- La mano, molto sofisticata, permette l'esecuzione di movimenti molto fini di tutte e cinque le dita. Esse sono removibili per permettere una facile sostituzione e per poter essere meglio adattate ai diversi soggetti.
- Il sensore di feedback tattile può essere posizionato all'interno della struttura del pollice. Può essere di pressione, di forza, di spostamento o qualsiasi sensore capace di fornire al soggetto un segnale di feedback. Il sensore è connesso ad un attuatore di feedback attraverso cavi o via wireless. Quando il soggetto afferra un oggetto con la mano, il sensore legge lo spostamento o la forza esercitata sulla struttura del pollice e invia un segnale all'attuatore che dà all'utente un feedback tattile proporzionale alla forza della presa. L'attuatore può essere posizionato sul petto del paziente, localizzato sull'apparato di supporto della protesi o in qualunque altra area in grado di ricevere un feedback tattile. Ad esempio, può essere localizzato in un controllore posto nel piede ed usato per controllare la mano. L'attuatore può essere un motore vibrazionale o un attuatore di pressione. Si possono utilizzare anche sensori che rilevano una variazione di pressione o forza, piuttosto che i loro valori assoluti, e quindi l'attuatore si azionerà solo nel caso di valori mutati di queste grandezze.

La prima versione della Luke arm prevedeva un sistema di controllo basato sull'utilizzo di una *foot platform*: per manovrare il braccio, l'utente doveva spostare la pressione su un array di sensori incorporati nella calzatura.

Una seconda versione usa la tecnica chirurgica della *Targeted Muscle Reinnervation*, inventata dal Dr. Todd Kuiken, che consiste nel trasferimento dei nervi efferenti dell'arto superiore su diverse porzioni del pettorale in modo da poterne registrare i segnali sEMG da utilizzare per il controllo della protesi.

La protesi è attualmente in fase di test clinico e il tentativo della DEKA è quello di rendere la protesi più accessibile al pubblico, riducendo il costo a 100.000 \$ (17).

3.4.4 Johns Hopkins APL's Modular Prosthetic Limb



Figura 44: Johns Hopkins APL's Modular Prosthetic Limb.

Il Johns Hopkins University Applied Physics Laboratory (APL) di Laurel, Maryland, (18) ha sviluppato un primo prototipo di braccio dotato di 7 gradi di libertà attuati indipendentemente (flesso-estensione della spalla, rotazione omerale, flesso-estensione del gomito, rotazione del polso, flesso-estensione del polso e due prese attuate della mano) che usa strategie di integrazione neurale non invasive basate sulla Target Muscle Reinnervation e la rilevazione del segnale sEMG.

Tale prototipo fornisce al paziente un feedback aptico attraverso elementi vibro tattili attivati dal contatto della mano protesica con un oggetto e posti sulle aree reinnervate (dove risiedono le fibre sensoriali afferenti), che generano una vera e propria sensazione tattile.

Su questa base tecnologica, è stato sviluppato un ulteriore prototipo per migliorare il design ed aumentarne la destrezza. Si tratta di un sistema dotato di 17 gradi di libertà attuati, con un totale di 26 gradi di libertà, le cui specifiche sono riportate nella Tabella 7. Queste quantità differiscono in quanto alcuni giunti sono cinematicamente accoppiati nel tentativo di minimizzare la complessità.

La protesi è composta da:

- 4 upper arm drives: flesso/estensione della spalla, abduzione/adduzione della spalla, rotazione omerale e flesso/estensione del gomito;
- 3 wrist drives: rotazione, abduzione/adduzione e flesso/estensione;

- 4 thumb drives: abduzione/adduzione carpo metacarpale, flessione/estensione carpo metacarpale, flessione/estensione metacarpofalangea, flessione/estensione interfalangea;
- 1 finger drive per ogni dito a livello del giunto metacarpofalangeo per azionare i 3 giunti del dito accoppiati cinematicamente;
- 2 drives finali: abduzione/adduzione dita.

Il braccio e la mano contengono più di 100 sensori (Fig. 45). In corrispondenza di ogni singolo giunto, sono presenti sensori che misurano l'angolo, la velocità e la torsione. Sulla punta delle dita sono presenti dei sensori aggiuntivi che misurano forza, vibrazione, contatto puntuale e la temperatura/ flusso di calore.




Figura 45: Sensori incorporati nella Johns Hopkins APL's Modular Prosthetic Limb.

Parameter	Value	Units
Degrees of Freedom	26	DOF
Motors (Degree of Control)	17	DOC
Onboard Motor Controllers	Custom Embedded	
Onboard Sensor Conditioning and Digitization	Custom Embedded	
Mass of Hand and Wrist	2.9	lbs
Mass of Upper Arm with Battery	7.6	lbs
Payload Capacity (Wrist Active)	15	lbs
Payload Capacity (Wrist Static and Upper Arm Active)	35	lbs
Cylindrical Grasp Force	70	lbf
Two-Jaw Pinch Force	15	lbf
Three-Jaw Chuck Pinch Force	25	lbf
Lateral Key-Pinch Force	25	lbf
Upper Arm Joint Speed	120*	degs/s
Wrist Joint Speed	120*	degs/s
Hand Open or Close Time	300	ms
Voltage	24	volts
Communications	CAN	

Tabella 7: Specifiche della Johns Hopkins APL's Modular Prosthetic Limb a 26 gdl.

Capitolo 4.

Controllo basato sull'EMG Pattern Recognition

Il controllo basato sull'EMG Pattern Recognition si basa sull'assunzione che i pattern EMG contengano una ricca informazione sul movimento intenzionale dell'arto amputato. Tramite una tecnica di classificazione del pattern, si può identificare il movimento che il soggetto è intenzionato a svolgere e viene, quindi, mandato un comando al controllore della protesi in modo che faccia eseguire il movimento (Fig. 46).

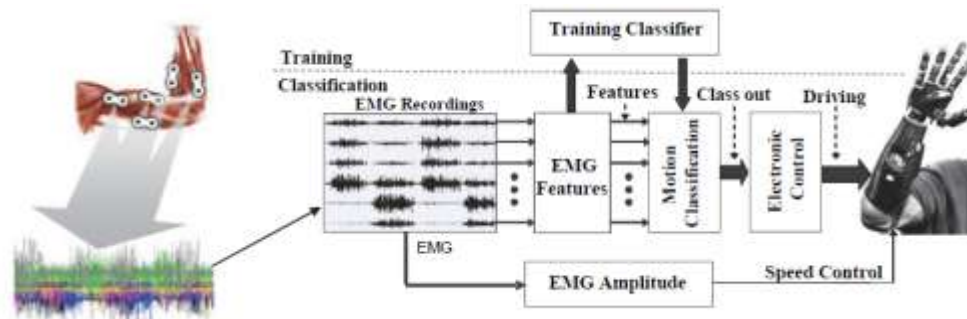


Figura 46: Diagramma schematico del sistema di controllo protesico basato sull'EMG Pattern Recognition (da Li et al. (19))

Con questo nuovo approccio, diversamente da quanto avviene con il controllo mioelettrico convenzionale, il soggetto contrae il muscolo corrispondente al grado di libertà che vuole controllare. Ne risulta così un controllo più intuitivo da parte del soggetto e una selezione rapida di ogni funzione. Ciò permette al soggetto di far muovere più facilmente la protesi con molteplici gradi di libertà, come richiesto nelle amputazioni di arto di alto livello.

In generale, un approccio di controllo basato sull'EMG *pattern recognition* consiste nei seguenti passi:

1. Acquisizione EMG multicanale,
2. Segmentazione dei dati EMG (in modo che venga presa una decisione di classificazione all'interno di ogni finestra temporale),
3. *Feature representation*, costituita da:
 - a. *Feature extraction* (per estrarre l'informazione utile nascosta nei dati EMG e per rimuovere le componenti indesiderate),

- b. *Feature reduction* (per rimuovere le informazioni ridondanti e ridurre il tempo computazionale del classificatore),
- 4. Classificazione delle *feature* (per predire la classe di movimento tra un sottoinsieme di movimenti intenzionali),
- 5. Controllo protesi multifunzionale (per implementare l'operazione protesica della classe predetta di movimento).

4.1 Acquisizione EMG multicanale

Nel controllo basato sull'EMG Pattern Recognition di protesi multifunzionale, sono necessarie registrazioni mioelettriche multicanale per catturare informazioni sufficienti per un'accurata classificazione di molteplici classi di movimento.

Ciò introduce due principali elementi a cui porre particolare attenzione: il numero di canali mioelettrici e il posizionamento degli elettrodi. Questi dipendono principalmente dal numero di classi di movimento che sono richieste dalla protesi multifunzionale e dal numero di muscoli residui che possono essere sfruttati per il controllo mioelettrico.

È ovvio che, maggiore è il numero di classi di movimento, maggiore è il numero di elettrodi richiesti per ottenere un adeguato numero di segnali. Utilizzando un maggior numero di elettrodi, aumenta il numero di segnali mioelettrici catturati, ma allo stesso tempo aumentano la complessità, il peso e il costo della protesi.

Da studi precedenti (20), si è osservato come l'errore di classificazione diminuisca all'aumentare del numero di canali (Fig. 47).




Figura 47: Errore di classificazione (%) per 2 e 4 canali sEMG (Englehart et al., 2001 (20))

I segnali EMG catturati con gli elettrodi di superficie sono comunemente filtrati con un passa-banda per migliorare la qualità del segnale:

- Alle alte frequenze dello spettro del segnale, viene usato un filtro passa-basso per attenuare le componenti ad alta frequenza indesiderate e per evitare la distorsione del segnale causata dal fenomeno di aliasing. Generalmente la frequenza di taglio del filtro passa-basso è determinata dal teorema di campionamento di Nyquist, secondo cui la frequenza di taglio deve essere minore o uguale a metà della frequenza di campionamento del segnale ($f_{\text{cut-off}} \leq 0.5 f_{\text{sampling}}$).
- Alle basse frequenze dello spettro del segnale, la frequenza di taglio del filtro passa-alto è determinata dalla necessità di rimuovere le lente variazioni del segnale causate da artefatti di movimento come, ad esempio, il movimento dell'elettrodo e il movimento dei cavi.

Quasi tutti gli studi precedenti sul controllo di protesi basato sull'EMG Pattern Recognition hanno adottato una frequenza di taglio del filtro passa-alto compresa tra 5 Hz e 20 Hz. È noto, però, come gli artefatti di movimento dei cavi abbiano tipicamente un range di 1-50 Hz e che la densità di potenza degli artefatti di movimento dell'elettrodo assuma valori fino a 20 Hz. Quindi, un filtro passa-alto di 5-20 Hz potrebbe effettivamente attenuare gli artefatti di movimento, i quali possono danneggiare l'accuratezza di controllo e la stabilità di una protesi mioelettrica. I risultati di un recente studio (19) ha mostrato che l'accuratezza della classificazione di un numero di classi di movimento di arto superiore potrebbe non beneficiare molto dall'acquisizione di componenti frequenziali più basse del segnale EMG. Includendo componenti frequenziali di 20-100 Hz, l'accuratezza della classificazione è lievemente aumentata sia nei soggetti normodotati (di circa 0,25%) sia negli amputati (di circa 1,6%). Ciò suggerisce che una maggior frequenza di taglio del filtro passa-alto, pari a 50-60 Hz, può essere usata per rimuovere o ridurre maggiormente gli artefatti di movimento dai segnali EMG al fine di migliorare la stabilità del controllo della protesi mioelettrica multifunzionale.

Ad eccezione di alcuni casi, la maggior parte della potenza (circa il 95%) dei segnali EMG superficiali è entro i 400-500 Hz (21) e la maggior parte delle componenti frequenziali superiori a 500 Hz sono dovute al rumore degli elettrodi e dell'apparecchiatura o all'interferenza ambientale. Così, la frequenza di campionamento ampiamente adottata negli studi di sEMG è intorno ai 1000 Hz. Tale frequenza di campionamento è stata usata in molti studi di controllo di protesi basato sull'EMG Pattern Recognition (22) (23) (24)

(25). È ovvio che la scelta di utilizzare una frequenza di campionamento alta permette di rilevare le componenti ad alta frequenza del segnale sEMG, ma contemporaneamente aumenta la complessità di processing e computazionale del controllore della protesi. Con la capacità limitata del controllore, basato su microprocessore montato nel socket, sarebbe preferibile adottare una frequenza di campionamento bassa senza però compromettere molto le performance di controllo della protesi. Recenti studi (19) hanno mostrato che, scegliendo una frequenza di campionamento pari a 500 Hz, l'accuratezza media di classificazione per i soggetti con amputazione di arto superiore si riduce del 2% in confronto ad una frequenza di campionamento di 1000 Hz. Dimezzando quindi la frequenza di campionamento, viene risparmiata la memoria del 50% e si riduce del 50% il tempo di processing dei dati con un leggero sacrificio nell'accuratezza: ciò semplificherebbe enormemente il design e l'implementazione del controllore. Inoltre, la maggior velocità di processing dei dati permetterebbe di utilizzare algoritmi di Pattern Recognition più sofisticati.

4.2 Segmentazione dei dati EMG

Prima della feature extraction, i segnali EMG devono essere finestrati: il segnale relativo ad ogni canale viene segmentato in una serie di finestre di analisi che possono essere temporalmente sovrapposte o meno.

Il processo di segmentazione dei dati richiede di affrontare tre punti importanti:

a. Tecnica di finestrazione dei dati EMG

Esistono 2 principali tecniche di finestrazione dei dati: finestrazione adiacente e sovrapposta.

Nella finestrazione adiacente sono usati, per la feature extraction, segmenti disgiunti adiacenti di lunghezza fissa, come mostrato in Fig. 48. Il movimento intenzionale classificato emerge dopo un certo ritardo di processing. Dal momento in cui il tempo di processing è una piccola porzione della lunghezza del segmento, il processore è inattivo nella restante porzione. In caso di finestrazione adiacente, l'intervallo temporale dato dalla lunghezza della finestra e dal tempo di processing dei comandi di controllo dovrebbe essere uguale o inferiore a 300 ms, in modo da rispettare il requisito di real-time.




Figura 48: Finestre adiacenti di lunghezza W e ritardo τ (da Englehart et al., 2001 (20)).

La finestrazione sovrapposta usa il tempo in cui il processore era inattivo in modo da massimizzare l'utilizzo del flusso continuo di dati e di produrre un flusso di decisioni che sia il più denso possibile, tenendo conto della capacità computazionale disponibile.

In questo caso, il nuovo segmento è sovrapposto al precedente, con un incremento temporale inferiore alla lunghezza della finestra (Fig. 49). L'incremento dovrebbe essere maggiore rispetto al tempo di processing, in quanto il processore deve calcolare il feature set e generare una decisione, prima che arrivi un nuovo segmento. Per l'analisi con finestre sovrapposte, il ritardo operativo nel controllo real-time è pari alla durata della sovrapposizione invece che alla lunghezza della finestra.




Figura 49: Finestre sovrapposte (da Englehart et al., 2003 (26))

Englehart et al. (26) hanno investigato l'effetto del segmento incrementale sulla performance di classificazione. Un segmento incrementale più piccolo produce un flusso di *class decision* più denso ma semi-ridondante che può migliorare il tempo di risposta e l'accuratezza.

Farina e Merletti (27) hanno mostrato che le finestre sovrapposte provocano solamente un aumento del tempo di processing, senza fornire un significativo miglioramento nell'accuratezza delle feature spettrali come i coefficienti AR.

b. Lunghezza della finestra

La lunghezza della finestra deve essere scelta in modo da rispettare il requisito di real-time, secondo cui il tempo di risposta della protesi non deve superare 300 ms. Oltre i 300 ms, infatti, il soggetto percepirebbe il ritardo (20).

Il principale trade-off nella selezione della lunghezza della finestra consta nel tempo di risposta e nell'accuratezza della classificazione: finestre più lunghe migliorano la stabilità delle feature (riducendo la varianza e aumentando la performance di classificazione (26)) ma, allo stesso tempo, generano un maggior ritardo nella decisione della classe.

Diversi lavori hanno cercato di individuare la lunghezza ideale della finestra, tra cui:

- Englehart e Hudgins (26) hanno rilevato che, adottando una segmentazione continua su un segnale steady state, la lunghezza del segmento può essere ridotta da 256 ms a 128 ms senza una considerevole diminuzione dell'accuratezza (Fig. 50).

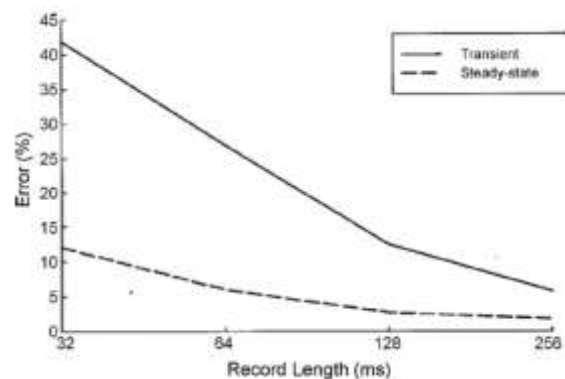


Figura 50: Errore di classificazione (%) in funzione della lunghezza della finestra (Englehart e Hudgins (26)).

- Smith et al. (28) hanno studiato la relazione tra ritardo di controllo e l'errore di classificazione e i risultati suggeriscono che la lunghezza ottimale della finestra sia compresa tra 150 ms e 250 ms. Questo risultato è stato ottenuto confrontando 6 diverse lunghezze (50 ms, 150 ms, 250 ms, 350 ms, 450 ms e 550 ms).

Per utilizzare finestre più ampie di 250 ms, deve essere applicata la tecnica delle finestre sovrapposte. In questo caso, l'incremento, ossia l'intervallo di tempo tra due segmenti consecutivi, dovrebbe essere inferiore a 300 ms in modo da evitare fallimenti nell'applicazione real-time (29). Un recente studio (29) ha confrontato 8 diverse combinazioni di lunghezza (125, 250 e 500 ms) e incremento (62.5, 125 e 250 ms) con il

tentativo di individuare la combinazione più robusta nel tempo. I risultati mostrano che la finestra ottimale ha una lunghezza pari a 500 ms e un incremento di 125 ms.

I risultati degli studi appena esposti sono riportati nella Tabella 8.

Autori studio, Anno	Finestra ottimale
Englehart K, Hudgins B, 2003 (26)	$T_a=128-256$ ms (per segnale steady state) $T_a=256$ ms (per segnale transiente)
Smith LH, Lock BA, Hargrove L., 2011 (28)	$T_a=150-250$ ms
Phinyomark et al., 2013 (29)	$T_a=500$ ms $T_{incr}=125$ ms

Tabella 8: Finestra ottimale individuata in diversi studi.

c. Stato dei dati EMG

Un segnale mioelettrico comprende due stati:

- uno stato transiente che deriva dal *burst* della fibra, quando il muscolo passa dalla fase di *rest* al livello di contrazione volontaria, e
- uno stato di *steady*, quando si ha il mantenimento costante di una contrazione del muscolo.

Hudgins et al. (30) furono i primi a considerare il contenuto informativo del segnale transiente. Sebbene le feature estratte dallo stato transiente, circa 100 ms dopo l'onset, mostrino un elevato potenziale per la classificazione, non è chiaro se questo sia dovuto al determinismo elettrofisiologico o ad altre ragioni, come ad esempio il movimento degli elettrodi o lo stiramento della pelle. La principale debolezza nell'utilizzo dello stato transiente nel controllo mioelettrico è che la contrazione dovrebbe iniziare dalla condizione di rest. Questo impedisce il passaggio da una classe all'altra in maniera efficace e la coordinazione di azioni complesse che coinvolgono gradi di libertà multipli. Perciò, nel controllo real-time, viene preso in considerazione lo stato steady del segnale.

Englehart et al. (20) hanno dimostrato che i dati steady-state vengono classificati in maniera più accurata e che la classificazione soffre meno della riduzione della lunghezza della finestra rispetto ai dati transienti (Fig. 50). La classificazione degrada più lentamente al diminuire della lunghezza per il dato steady rispetto al dato transiente.

Il segnale mioelettrico presenta uno stato indeterminato durante la transizione tra diversi livelli di contrazione; di conseguenza, la maggior parte degli errori di classificazione avvengono quando si cambia classe. Quindi l'individuazione e l'eliminazione di segmenti di dati provenienti da periodi di transizione, possono aumentare l'accuratezza del controllore. Questo può essere maggiormente applicabile quando si deve generare un *training dataset*.

4.3 Feature Representation

La *feature representation* gioca un ruolo importante nell'accuratezza della classificazione, più di quanto possa essere svolto da un classificatore. Infatti, con un opportuno feature set ed un numero sufficiente di canali, la maggior parte dei classificatori avrà performance simile. Questa osservazione è stata illustrata da Hargrove et al. (24). L'effetto del feature set è mostrato in Fig. 51(a), dove sono indicati il valor medio e la deviazione standard dell'accuratezza della classificazione di sei soggetti. L'influenza del classificatore è mostrata in Fig. 51(b). Si può osservare come la feature representation abbia più influenza rispetto alla complessità del classificatore. Ne deriva che, con un adeguata feature representation, il compito di classificazione è essenzialmente un problema lineare.




Figura 51: Confronto tra (a) 6 feature set usando il classificatore LDA e (b) 5 classificatori usando il feature set AR (Hargrove et al., (24)).

4.3.1 Feature extraction

La *feature extraction* è una tecnica che serve ad estrarre l'informazione utile nascosta all'interno del segnale sEMG e a rimuovere le componenti indesiderate del segnale (31) (32).

Alcune features sono robuste a diverse tipologie di rumore; di conseguenza, scegliendo le feature appropriate, si può evitare di implementare intensi metodi di preprocessing (33). Inoltre, una scelta adeguata di feature, porta ad un'elevata accuratezza di classificazione (34). Sono state suggerite tre proprietà per confrontare quantitativamente le loro capacità: la massima separabilità tra classi, la robustezza e la complessità (31) (32).

In generale, le feature possono essere definite in 3 domini: dominio del tempo, della frequenza, del tempo-frequenza/tempo-scala.

4.3.1.1 Feature nel dominio del tempo

Le feature nel dominio del tempo sono generalmente veloci e facili da implementare poiché non necessitano di alcuna trasformazione, vengono infatti calcolate dal segnale EMG nel tempo.

Il maggiore svantaggio deriva dalla proprietà di non stazionarietà del segnale EMG, ossia dal cambiamento nel tempo delle sue proprietà statistiche; infatti, le feature nel dominio del tempo assumono che il segnale sia stazionario (35). Quindi, la variazione delle feature di questo gruppo può essere osservata ampiamente quando si registra un segnale sEMG durante movimenti dinamici. Inoltre, a causa del modo in cui vengono calcolate, basato sull'ampiezza del segnale EMG, molta dell'interferenza che viene acquisita in fase di registrazione diviene un principale svantaggio, in particolare per le feature che vengono estratte da proprietà di energia (36).

Comunque, le feature di questo gruppo sono state ampiamente adoperate a causa delle loro performance nella classificazione in ambienti con basso rumore e per la loro bassa complessità computazionale in confronto alle feature degli altri due gruppi.

Nella Tabella 9, vengono descritte le feature nel dominio del tempo (37).

Feature	Valore	Descrizione
IEMG (Integrated EMG)	$IEMG = \sum_{i=1}^N x_i $	Usato solitamente come indice di detezione dell'onset della contrazione.. x_i è il campione i del segnale EMG discreto all'interno della finestra di lunghezza N .
MAV (Mean Absolute Value) ARV (Average Rectified Value) AAV (Averaged Absolute Value) IAV (Integral of Absolute Value) V1 (first order of v-Order features)	$MAV = \frac{1}{N} \sum_{i=1}^N x_i $	È il più popolare nell'analisi del segnale EMG. È usato come indice di detezione dell'onset, in particolare per segnali sEMG per controllo di arto protesico.
MAV modificato tipo 1	$MAV1 = \frac{1}{N} \sum_{i=1}^N w_i x_i $ $w_i = \begin{cases} 1, & \text{se } 0.25N \leq i \leq 0.75N \\ 0.5, & \text{altrimenti} \end{cases}$	La funzione peso w_i migliora la robustezza del MAV.
MAV modificato tipo 2	$MAV2 = \frac{1}{N} \sum_{i=1}^N w_i x_i $ $w_i = \begin{cases} 1, & \text{se } 0.25N \leq i \leq 0.75N \\ \frac{4i}{N}, & \text{se } i < 0.25N \\ \frac{4(i-N)}{N}, & \text{altrimenti} \end{cases}$	La funzione peso w_i è una funzione continua.
SSI (Simple Square Integral)	$SSI = \sum_{i=1}^N x_i^2$	È un indice di energia del segnale EMG.

VAR (Variance)	$VAR = \frac{1}{N-1} \sum_{i=1}^N x_i^2$	È un indice di potenza.
TM3 (absolute value of the 3th Temporal Moment)	$TMR3 = \frac{1}{N} \sum_{i=1}^N x_i^3 $	
TM4 (absolute value of the 4th Temporal Moment)	$TMR4 = \frac{1}{N} \sum_{i=1}^N x_i^4$	
TM5 (absolute value of the 5th Temporal Moment)	$TMR5 = \frac{1}{N} \sum_{i=1}^N x_i^5 $	
RMS (Root Mean Square)	$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	È una feature molto utilizzata nell'analisi del segnale EMG.
V (v-order)	$V = \left(\frac{1}{N} \sum_{i=1}^N x_i^v \right)^{1/v}$	V è un detettore non lineare che stima implicitamente la forza di contrazione muscolare. È definito da un modello matematico funzionale di generazione del segnale EMG: $x_i = (\gamma m_i^\alpha) n_i$, dove γ e α sono costanti, e n_i è classe di un processo Gaussiano ergodico. Sperimentalmente, è stato mostrato che α assume valori compresi tra 1 e 1.75. Un valore ottimale di v è pari a 2, che porta alla definizione della RMS.
LOG (Log Vector)	$LOG = e^{\frac{1}{N} \sum_{i=1}^N \log(x_i)}$	Come V, fornisce una stima della forza di contrazione del muscolo.
WL (Waveform Length) WAVE	$WL = \sum_{i=1}^{N-1} x_{i+1} - x_i $	È una misura di complessità del segnale EMG.
AAC (Average Amplitude Change) DAMV (Difference	$AAC = \frac{1}{N} \sum_{i=1}^{N-1} x_{i+1} - x_i $	È quasi equivalente a WL: si differenzia per l'operazione di media svolta da $1/N$.

Absolute Mean Value)		
DASDV (Difference Absolute Standard Deviation Value)	$DASDV = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (x_{i+1} - x_i)^2}$	È il valore di deviazione standard della wavelength.
AFB (Amplitude of the First Burst)		È definito come il primo punto massimo estratto dalla funzione temporale risultante. Innanzitutto, il segnale EMG viene elevato al quadrato e filtrato con filtro FIR a media mobile con funzione di finestrata di Hamming. Poi, dopo il filtraggio, si ottengono le componenti a bassa frequenza del segnale EMG ed il valore massimo del primo burst.
ZC (Zero Crossing)	$ZC = \sum_{i=1}^{N-1} [sgn(x_i \times x_{i+1}) \cap x_i - x_{i+1} \geq TH]$ $sgn(x) = \begin{cases} 1, & \text{se } x \geq TH \\ 0, & \text{altrimenti} \end{cases}$	Dà un'informazione nel campo delle frequenze del segnale EMG. È il numero di volte che i valori di ampiezza del segnale EMG attraversano il livello di ampiezza zero. Per evitare fluttuazioni a basso voltaggio o rumori di fondo, viene implementata una condizione di soglia.
MYOP (Myopulse Percentage rate)	$MYOP = \frac{1}{N} \sum_{i=1}^N [f(x_i)]$ $f(x) = \begin{cases} 1, & \text{se } x \geq TH \\ 0, & \text{altrimenti} \end{cases}$	È un valore medio di myopulse output (f(x)), il quale è definito pari ad 1 quando il segnale EMG supera un valore di soglia predefinito.
WAMP (Willison Amplitude)	$WAMP = \sum_{i=1}^{N-1} [f(x_i - x_{i+1})]$ $f(x) = \begin{cases} 1, & \text{se } x \geq TH \\ 0, & \text{altrimenti} \end{cases}$	Dà un'informazione nel campo delle frequenze del segnale EMG, così come ZC. È il numero di volte in cui la differenza tra l'ampiezza del segnale EMG tra due segmenti adiacenti supera

		una soglia predefinita. La WAMP è legata alla frequenza di sparo delle unità motorie e dalla forza di contrazione.
SSC (Slope Sign Change)	$SSC = \sum_{i=2}^{N-1} [f[(x_i - x_{i-1}) \times (x_i - x_{i+1})]]$ $f(x) = \begin{cases} 1, & \text{se } x \geq TH \\ 0, & \text{altrimenti} \end{cases}$	É legato a ZC, MYOP e WAMP. È un altro metodo per rappresentare l'informazione in frequenza del segnale EMG. È il numero di volte che la pendenza del segnale EMG cambia di segno. Il numero di cambiamenti tra pendenza positiva e negativa tra tre segmenti successivi è calcolato con la funzione soglia per evitare l'influenza del rumore di fondo presente nel segnale. Il valore di soglia TH normalmente scelto per ZC, MYOP, WAMP e SSC è di $50 \mu V \div 100 \text{ mV}$, a seconda del guadagno dell'elettromiografo e del livello di rumore di fondo.
MAVSLP (Mean Absolute Value Slope)	$MAVSLP_k = MAV_{k+1} - MAV_k$ $k = 1, \dots, K - 1$	MAVSLP è una versione modificata di MAV al fine di stabilire multiple features. Vengono determinate le differenze di MAV di segmenti adiacenti. K è il numero di segmenti che coprono il segnale EMG. Quando K cresce, può migliorare la rappresentazione del segnale EMG originale rispetto alla tradizionale MAV.
MHW (Multiple Hamming Windows)	$MHW_k = \sum_{i=0}^{N-1} (x_i w_{i-i_k})^2$ $k = 1, \dots, K$	Sono una versione originale del multiple time windows method, la cui idea è quella di catturare il cambiamento dell'energia del segnale EMG nel tempo tramite varie multiple windows functions. Viene segmentato

		<p>il segnale EMG tramite le finestre di Hamming e calcolate le MHW utilizzando l'energia di ogni finestra.</p> <p>w è la funzione di finestrazione di Hamming.</p>
MTW (Multiple Trapezoidal Windows)	$MTW_k = \sum_{i=0}^{N-1} (x_i^2 w_{i-i_k})$ $k = 1, \dots, K$	<p>Sono un tipo di multiple time windows method. Come MHW, questo metodo di feature usa l'energia contenuta in una finestra del segnale come valore della feature. Però, la funzione di finestrazione w non è più di Hamming ma di tipo trapezoidale.</p>
HEMG (Histogram of EMG)		<p>È una versione estesa di ZC e di WAMP. Fornisce un'informazione nel campo delle frequenze. HEMG divide gli elementi nel segnale EMG in B segmenti equispaziati e restituisce il numero di elementi del segnale per ogni segmento. Zardoshi et al. (2002) raccomanda un numero di livelli B pari a 9.</p>
AR (Auto-Regressive coefficients)	<p><i>Modello AR:</i></p> $x_i = \sum_{p=1}^P a_p x_{i-p} + w_i$	<p>Il modello autoregressivo è un modello di predizione che descrive ogni campione del segnale EMG come una combinazione lineare dei precedenti campioni x_{i-p} più un termine di errore w_i (rumore bianco). Nella classificazione del segnale EMG si possono utilizzare i coefficienti a_p di tale modello. P è l'ordine del modello AR. Studi precedenti (es. Paiss&Inbar, 1987) hanno suggerito di utilizzare un modello del quarto ordine.</p>
CC (Cepstral Coefficients)	$c_1 = -a_1$	<p>La Cepstrum analysis è definita della trasformata inversa di Fourier del</p>

	$c_p = -a_p - \sum_{l=1}^{p-1} \left(1 - \frac{l}{p}\right) a_p c_{p-l}$	<p>logaritmo della magnitudo dello spettro di potenza del segnale. I coefficienti della Cepstrum analysis sono stati utilizzati come feature e possono essere ricavati dal modello AR.</p> <p>c_p è il coefficiente di ordine p della Cepstral analysis ; $1 \leq l \leq P$.</p> <p>Dalla formula fornita, questa feature si può considerare una feature nel dominio del tempo perché non richiede l'utilizzo della trasformata di Fourier.</p>
--	--	---

Tabella 9: Feature nel dominio del tempo.

Le feature nel dominio del tempo possono essere divise a loro volta in 4 principali tipologie, come riassunto nella Tabella 10:

1. metodi di informazione sull'energia e sulla complessità,
2. metodi di informazione nelle frequenze,
3. metodi di modello di predizione e
4. metodi tempo-dipendenti.

Le feature del primo gruppo vengono calcolate a partire dai valori di ampiezza del segnale EMG. Questo gruppo può dividersi a sua volta in 2 sottoclassi che sono basate sull'informazione di energia e sull'informazione di complessità. Alla prima sottoclasse appartengono 9 feature: IEMG, MAV, MAV1, MAV2, SSI, VAR, RMS, V e LOG; mentre, alla seconda sottoclasse appartengono 6 feature: WL, AAC, DASDV, TM3, TM4 e TM5.

Il secondo gruppo di feature dà informazioni nel campo delle frequenze tramite calcoli che avvengono nel dominio del tempo. A questa classe appartengono: ZC, MYOP, WAMP e SSC.

Il terzo gruppo di feature è costituito dai coefficienti di un modello di predizione. Quando l'ordine del modello aumenta, cresce anche il numero di feature. Le feature di questo gruppo sono: AR e CC. Molti lavori hanno mostrato che le feature di questo gruppo risultano essere migliori rispetto a quelle del primo e del secondo, ma hanno svolto un

confronto scorretto: infatti, il vettore di feature relativo al modello di predizione conteneva più di un elemento, a differenza del vettore di feature del primo e del secondo gruppo, i quali erano costituiti da un solo elemento. Nello studio svolto da Phinyomark et al. (37), per ogni coefficiente, è stato osservato separatamente il suo scatter plot. Dalle definizioni matematiche dei metodi AR e CC, che possono essere convertite usando una semplice equazione, il potere discriminatorio delle feature AR e CC sembrano essere simili tra loro.

Il quarto e ultimo gruppo di feature nel dominio del tempo si ricava dalle feature appartenenti al primo ed al secondo gruppo tramite segmentazione dei segnali EMG. Le versioni estese delle feature del primo gruppo basate sull'informazione di energia sono: MAVS, MHW e MTW. Phinyomark et al. (37) hanno rilevato un'alta differenza nel potere discriminatorio del MAVS, a seconda del coefficiente considerato, ma una bassa separabilità tra classi. In altre parole, le dispersioni dei valori delle feature ottenuti dai metodi MHW e MTW sono simili alle dispersioni di feature del primo gruppo del dominio del tempo; mentre, la loro performance di classificazione risulta essere inferiore. Un'altra feature, la HEMG, è versione estesa delle feature del secondo gruppo del dominio del tempo.

Lo studio di Phinyomark et al. (37) ha valutato le feature ottimali per ogni gruppo appartenente al dominio del tempo, in termini di accuratezza della classificazione, in modo tale da evitare di usare feature ridondanti.

Per il primo gruppo, le feature ottimali ricavate sono:

1. MAV per la prima sottoclasse,
2. WL per la seconda sottoclasse. La performance di WL è simile alle feature AAC e DASDV ma il suo costo computazionale è inferiore.

La combinazione tra feature della prima e della seconda sottoclasse fa crescere leggermente la performance di separabilità tra classi a causa di una piccola differenza dello spazio delle feature.

Il secondo gruppo di feature, come già detto, è basato sull'informazione nel campo delle frequenze. Dai risultati di accuratezza della classificazione, la performance nella classificazione risulta essere circa uguale; ciò nonostante, da precedenti studi (36), la

robustezza della WAMP rende quest'ultimo un candidato raccomandabile per questo gruppo.

Per il terzo gruppo di feature, costituito dai coefficienti del modello di predizione, le feature AR risultano essere leggermente migliori rispetto alle feature CC. Dalle osservazioni degli scatter graph, si nota una bassa capacità nel classificare. La dispersione delle feature AR e CC nello spazio è peggiore rispetto alla dispersione delle feature rappresentative del primo (MAV e WL) e secondo (WAMP) gruppo. Comunque, l'uso di tutti i coefficienti AR e CC è ancora significativo a causa delle loro basi matematiche.

Per un confronto ragionevole, è stato considerato un feature vector di dimensione pari a 3 (MAV, WL e WAMP) al fine di valutarlo rispetto ai 2 feature vector di 4 elementi costituiti, rispettivamente, dai coefficienti AR e CC del modello di predizione del quarto ordine. Si è osservato dagli esperimenti come, combinando le feature MAV, WL e WAMP, l'accuratezza della classificazione risulti essere superiore rispetto ai feature vector AR e CC. Comunque, i coefficienti AR restano utili per accrescere la performance di classificazione. Ad esempio, in questo studio, sono state combinate le 3 feature MAV, WL e WAMP con i coefficienti AR del quarto ordine, ottenendo un'accuratezza nella classificazione pari al 97%.

Il quarto ed ultimo gruppo di feature del dominio del tempo comprende i metodi tempo-dipendenti. Dai risultati dell'accuratezza della classificazione, si nota come le versioni estese delle feature basate sull'informazione dell'energia non siano migliori rispetto alle versioni originali. Per quanto riguarda la versione estesa delle feature basate sull'informazione nel campo delle frequenze, nominata HEMG, la sua performance è stata considerata, in alcuni studi precedenti, migliore rispetto ad altre feature del dominio del tempo; ma, i confronti svolti da questi studi erano scorretti. Nello studio di Phinyomark et al. (37), la discriminazione nello spazio della feature HEMG è molto bassa, come confermato dal basso valore dell'accuratezza. L'uso di tutti i segmenti del HEMG resta ancora importante, come detto anche per i coefficienti AR e CC; comunque, l'accuratezza della classificazione di tutti i 9 segmenti è ancora molto bassa (34.82%). I dati ottenuti suggeriscono che le performance del HEMG non lo rendono adatto per la classificazione del segnale EMG.

Feature nel dominio del tempo					
Gruppo 1		Gruppo 2	Gruppo 3	Gruppo 4	
a. Informazione sull'energia	b. Informazione sulla complessità	Informazione nelle frequenze	Modello di predizione	Tempo- dipendenti	
				Estensione Gruppo 1a	Estensione Gruppo 1b
IEMG (86.74±9.9)	WL (88.72±7.2)	ZC (86.93±8.1)	AR (92.11±6.3)	MAVS (69.56±11.2)	HEMG (34.82±4.9)
MAV (86.49±9.6)	AAC (88.42±7.9)	MYOP (85.53±10.0)	CC (91.55±6.8)	MHW (78.33±9.7)	
MAV1 (86.31±9.8)	DASDV (88.79±7.3)	WAMP (85.03±9.7)		MTW (34.82±4.9)	
MAV2 (85.31±9.9)	TM3 (50.96±7.6)	SSC (88.31±7.7)			
SSI (78.63±9.1)	TM4 (59.53±7.3)	AFB (71.64±7.9)			
VAR (78.42±9.2)	TM5 (41.65±5.2)				
RMS (86.21±9.4)					
V (86.21±9.4)					
LOG (83.32±9.8)					

Tabella 10: Principali tipologie delle feature nel dominio del tempo. In grassetto sono indicate le feature ritenute migliori per ciascun gruppo.

I feature set nel dominio del tempo maggiormente conosciuti in letteratura sono:

1. Il feature set di Hudgins (30) : MAV, WL, ZC e SSC;

In questo vettore, ZC e SSC appartengono allo stesso gruppo di feature e sono quindi ridondanti. Si è infatti osservato (37) che usando solo 3 delle 4 feature, ossia MAV, WL e SSC, si ottiene una performance simile a quella ottenuta calcolando tutte e 4 le feature.

2. Il feature set di Du (38): IEMG, VAR, WL, ZC, SSC e WAMP.

In questo caso, IEMG e VAR appartengono allo stesso gruppo di feature, così come ZC, SSC e WAMP. Così, scegliendo quindi solo 3 delle 6 feature (IEMG, WL e

WAMP) si ottiene una performance simile rispetto ad quella raggiunta con tutte e 6 le *feature*.

Un recente studio (29) ha valutato 50 feature nel dominio del tempo e nel dominio delle frequenze, al fine di esaminare la singola feature e il feature set più robusti. I risultati mostrano che:

- la feature più robusta è la Sample Entropy (SampEn) (definita nel dominio del tempo);
- il feature set più robusto, considerando che sia composto da 4 feature, è SampEn+CC+RMS+WL (definiti nel dominio del tempo).

L'utilizzo anche della sola SampEn risulta essere migliore in termini di performance della classificazione, rispetto al feature set di Hudgins. L'accuratezza della classificazione, aumenta infatti da 78.73% (per il feature set di Hudgins) a 93.37% (per SampEn).

4.3.1.2 Feature nel dominio delle frequenze

Le feature nel dominio delle frequenze sono maggiormente usate per studiare la fatica del muscolo e per l'analisi del reclutamento delle unità motorie. La densità spettrale di potenza (PSD) è la principale analisi che viene effettuata nel dominio delle frequenze. Diverse tipologie di proprietà statistiche sono state applicate alla PSD, che è definita come la trasformata di Fourier della funzione di autocorrelazione del segnale EMG. La PSD può essere stimata usando altri metodi quali il Periodogramma e metodi statistici, come il modello AR (27). Due variabili della PSD ampiamente utilizzate sono la frequenza media (MNF) e la frequenza mediana (MDF). Esistono altre variabili caratteristiche, quali, la frequenza di picco (PKF), la potenza media (MNP) e la potenza totale (TTP).

Nella Tabella 11, sono definite le feature nel dominio della frequenza (39):

Feature	Valore	Descrizione
MNF (Mean Frequency) f _c (Central Frequency) Spectral Center of Gravity	$MNF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j}$	f _j è la frequenza j-esima dello spettro, P _j è lo spettro di potenza del segnale EMG alla frequenza j-esima, e M è la lunghezza dell'asse discreto delle frequenze.

MDF (Median Frequency)	$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j$ $= \frac{1}{2} \sum_{j=1}^M P_j$	È la frequenza che divide lo spettro in due regioni con uguale ampiezza. In altre parole, MDF è metà della feature TTP.
PKF (Peak Frequency)	$PKS = \max (P_j)$ $j = 1, \dots, M$	È la frequenza a cui corrisponde la massima potenza.
MNP (Mean Power)	$MNP = \sum_{j=1}^M P_j / M$	È la potenza media dello spettro di potenza del segnale EMG
TTP (Total Power) o SM0 (Zero Spectral Moment) o Energy	$TTP = \sum_{j=1}^M P_j$	È definito come un aggregato dello spettro di potenza del segnale EMG
SM1 (1st Spectral Moment)	$SM1 = \sum_{j=1}^M P_j f_j$	Il momento spettrale è una modalità di analisi statistica alternativa per estrarre le features dallo spettro di potenza del segnale EMG. I primi 3 momenti sono i più importanti.
SM2 (2st Spectral Moment)	$SM2 = \sum_{j=1}^M P_j f_j^2$	
SM3 (3st Spectral Moment)	$SM3 = \sum_{j=1}^M P_j f_j^3$	
FR (Frequency Ratio)	$FR = \sum_{j=LLC}^{ULC} P_j / \sum_{j=LHC}^{UHC} P_j$	È stato proposto per distinguere la contrazione dal rilassamento del muscolo utilizzando il rapporto tra le componenti a bassa frequenza e quelle ad alta frequenza del segnale EMG. ULC e LLC sono le frequenze di upper- e lower- cut-off della banda a bassa frequenza, UHC e LHC sono le frequenze di upper- e lower- cut-off della banda ad alta frequenza, rispettivamente. La soglia per dividere tra basse frequenze e alte frequenze può essere definita per via sperimentale (ad es. Han et al. (2000) considerarono i range di 30-250 Hz e 250-1000 Hz rispettivamente per le componenti a bassa e alta frequenza.) o per via teorica usando il valore di MNF. Dalla definizione matematica, FR è l'inverso

		della feature high-to-low ratio (H/L ratio), ampiamente usata in studi di fatica del diaframma.
PSR (Power Spectrum Ratio)	$PSR = \frac{P_0}{P}$ $= \frac{\sum_{j=f_0}^{f_0+n} P_j}{\sum_{j=-\infty}^{\infty} P_j}$	PSR può essere visto come un'estensione di PKF e FR. PSR è definito come il rapporto tra l'energia P_0 , che è vicino al massimo valore dello spettro di potenza del segnale EMG, e l'energia P , che è l'intera energia dello spettro di potenza del segnale EMG. f_0 è il valore di PKF, n è il limite integrale
VCF (Variance of Central Frequency)	VCF $= \frac{1}{SM0} \sum_{j=1}^M P_j (f_j - f_c)^2$ $= \frac{SM2}{SM0} - \left(\frac{SM1}{SM0}\right)^2$	È un importante caratteristica della PSD. Può essere definito usando alcuni momenti spettrali.

Tabella 11: Feature nel dominio della frequenza.

Per quanto riguarda le feature nel dominio della frequenza, è stato mostrato come le loro performance dal punto di vista della separabilità tra classi non le rendano adatte per il sistema di riconoscimento dell'EMG. Alcune feature nel dominio delle frequenze (MNP, TTP, SM1, SM2 e SM3) hanno lo stesso potere discriminatorio, nello spazio delle feature, delle feature nel dominio del tempo. Però, queste ultime sono superiori rispetto alle feature nel dominio delle frequenze in quanto hanno una complessità computazionale inferiore e non richiedono alcuna trasformazione.

4.4.1.3 Feature nel dominio del tempo-frequenza (tempo-scala)

Come già detto, il problema delle feature nel dominio del tempo è che assumono stazionario un segnale che in realtà è non stazionario. Per quanto riguarda il dominio delle frequenze, la trasformata di Fourier perde le informazioni del segnale nel dominio del tempo, e si ha quindi il problema di non avere accesso all'istante temporale in cui un fenomeno ha luogo (40). Questo è accettabile per segnali stazionari, poiché le loro proprietà non cambiano nel tempo; tuttavia, il segnale mioelettrico contiene molte caratteristiche non stazionarie e transitorie. L'analisi wavelet risulta essere, invece, una tecnica più compatibile con la natura del segnale EMG.

Tra i differenti tipi di rappresentazioni tempo-frequenza, sono preferibili per le applicazioni real-time le rappresentazioni lineari e discrete, come la STFT (Short-Time Fourier Transform) o Gabor Transform, la WT (Wavelet Transform) e la WPT (Wavelet Packet Transform).

La differenza fondamentale tra queste 3 tipologie di rappresentazioni sta nella modalità in cui partizionano il piano tempo-frequenza (Fig. 52):




Figura 52: Partizionamento del piano tempo-frequenza per (a) STFT, (b) WT e (c) WPT (Englehart et al. (41)).

STFT: partiziona il piano in modo uniforme. Le celle hanno la stessa dimensione (*aspect ratio*).

WT: le celle sono di dimensione variabile all'interno del piano (l'*aspect ratio* delle celle varia così che la risoluzione in frequenza sia proporzionale alla frequenza centrale). È stato visto come questo tipo di partizione del piano tempo-frequenza sia più appropriato per molti segnali fisici, ma ciò nonostante la partizione rimane fissa.

WPT: la partizione è adattativa. Si ha un set esteso di possibili partizioni e viene quindi selezionata la migliore per una data applicazione. L'approccio più comune per specificare la partizione WPT è di selezionare quella che minimizza l'errore di ricostruzione, adottando come funzione di costo l'entropia (42). Questa può essere considerata ottimale per la compressione del segnale ma inappropriata per la classificazione del segnale. È stata quindi proposta una forma modificata di questo algoritmo che tende a massimizzare l'abilità discriminante della WPT adottando una funzione di costo di separabilità tra le classi (43).

a. Wavelet Transform (WT)

La tecnica WT può essere di 2 tipologie: discreta (DWT) e continua (CWT).

Per le applicazioni real-time, è preferita la DWT in quanto ha un onere computazionale inferiore rispetto alla CWT.

La DWT trasforma iterativamente il segnale di interesse in più subset multi-risoluzione di coefficienti. Tale procedimento è denominato Wavelet Decomposition. Ciò avviene filtrando il segnale sEMG con un filtro passa-alto e un filtro passa-basso, i cui coefficienti dipendono dal tipo di *wavelet function* (WF) utilizzata. Vengono così generati, rispettivamente, a partire dal segnale sEMG, un subset di coefficienti di dettaglio (cD1) e un subset di coefficienti di approssimazione (cA1) al primo livello. Per ottenere un'analisi multi-risoluzione, viene eseguito questo procedimento per più livelli, fino a raggiungere il livello finale desiderato. Nell'analisi EMG, si è osservato che la performance migliore si ottiene con 4 livelli di scomposizione, (44) (45) (46) (39), mostrati in Fig. 53.

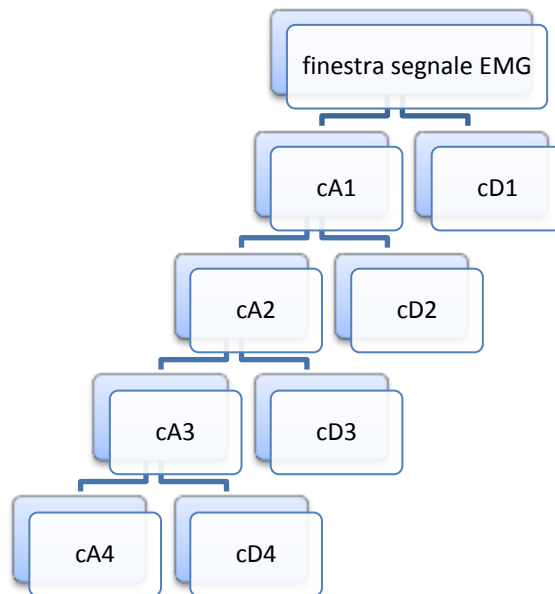


Figura 53: Wavelet decomposition fino a livello 4.

Ciascun subset di coefficienti wavelet può essere poi ricostruito, utilizzando la DWT inversa (IDWT), per stimare una componente efficace del segnale sEMG. La IDWT è calcolata usando i coefficienti di tutte le componenti wavelet. Quindi, a partire dai subset di coefficienti cA4, cD1, cD2, cD3 e cD4, si possono ottenere i rispettivi segnali EMG ricostruiti, ossia, A4, D1, D2, D3 e D4 (Fig. 54).




Figura 54: Wavelet Reconstruction.

In un recente studio (47), si è osservato il vantaggio di considerare solo i coefficienti di alcune componenti frequenziali rispetto alla totalità dei subset. Selezionando le componenti frequenziali, infatti, viene ridotto il rumore e la parte indesiderata del segnale (48). Questo approccio, non solo migliora l'accuratezza della classificazione, ma riduce il costo computazionale, in quanto viene ridotto il numero di subset da calcolare. In particolare, si è osservato (39) che la miglior performance di classificazione può essere ottenuta usando: il segnale ricostruito dai coefficienti di dettaglio al livello 2 (D2), scegliendo come WF la Daubechies wavelet di ordine 7 (db7) e calcolando in seguito la feature ZC; e il segnale ricostruito dai coefficienti di dettaglio al livello 1 (D1), scegliendo come WF la Daubechies wavelet di ordine 5 (db5) e calcolando in seguito la feature MYOP.

Nello stesso studio si è mostrato come l'adeguatezza di un subset di coefficienti e di una WF, dipenda dal tipo di feature che si vuole estrarre (come mostrato in Fig.10).

Feature extraction	Optimal wavelet component	Optimal WF	RES index
ZC	D2	Db7	12.52
WAMP			12.22
MAV, IEMG			11.11
VAR, SSL, TTP, MNP			10.83
MMAV			10.69
SM1			10.45
LOG			9.53
RMS, V2	cD1	Db10	11.06
V3			10.27
SM2			10.23
SM3			9.83
MYOP			12.95
MFL	D1	Db5	9.86
WL, AAC		Db8	11.69
DASDV	Raw	-	11.15
MNF			5.48
MDF			5.38
PSR			4.99
FR			3.46

Tabella 12: Subset di coefficienti e WF ottimali per ciascuna feature, e relativo indice RES (indice di separabilità tra le classi).

Phinyomark (39) suggerisce quindi di estrarre un feature vector costituito dalle caratteristiche ZC, WAMP e MAV del segnale ricostruito dai coefficienti del secondo livello con la wavelet madre Daubechies di ordine 7; e dalla feature MYOP del segnale ricostruito dai coefficienti del primo livello con la wavelet madre Daubechies di ordine 5.

b. Wavelet Packet Transform (WPT)

Il metodo wavelet packet è una versione generalizzata della classica wavelet decomposition, presentando più possibilità per il processing del segnale. La principale differenza tra WT e WPT è che vengono scomposte, oltre alle approssimazioni del segnale, anche i dettagli, come mostrato in Fig. 55.

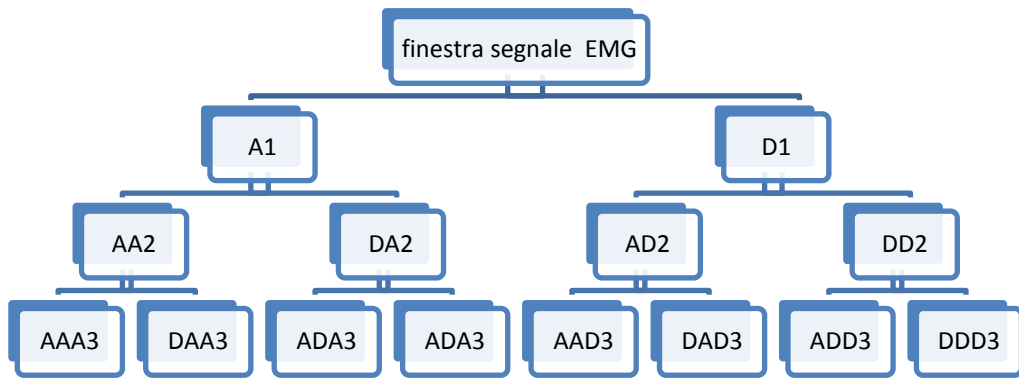


Figura 55: Decomposition tree WPT con 3 livelli di scomposizione.

Quindi, con l'uso della WPT, si può ottenere una miglior risoluzione in frequenza per il segnale scomposto. Inoltre, si estrae un maggior numero di feature relative al segnale.

La WPT permette di rappresentare il segnale originale con varie combinazioni di componenti a bassa e alta frequenza. In particolare, con livello di scomposizione pari a n , esistono $2^{2^{n-1}}$ possibili modi di descrivere il segnale. Ad esempio, con $n=3$ ho 16 possibili modi per descrivere il segnale S:

$$\text{segnale originale} = A1 + D1 = \dots = A1 + AAD3 + DAD3 + DD2.$$

La WPT può essere pensata come un albero di sottospazi. Il nodo radice dell'albero (lo spazio del segnale originale) è $\Omega_{0,0}$. Un sottospazio $\Omega_{j,k}$ è decomposto in due sottospazi ortogonali $\Omega_{j,k} \rightarrow \Omega_{j+1,2k}$ e $\Omega_{j,k} \rightarrow \Omega_{j+1,2k+1}$. Qui j denota la scala, e k indica l'indice di

sottobanda attraverso le scale. Ogni sottospazio $\Omega_{j,k}$ è visto da 2^{n_0-j} vettori di base $\{w_{j,k,n}\}_{n=0}^{2^{n_0-j}-1}$, dove $n_0 = \log_2 N$. Questi *basis vector* sono le funzioni base della WPT. In Fig. 56 è mostrata la decomposizione alla scala J=3.




Figura 56: Wavelet Packet Tree fino alla scala J=3.

Il set di sottospazi nell'albero binario WPT è ridondante, cioè, la trasformata fornisce un albero binario di coefficienti comprendendo 2^N possibili basi ortonormali, dove N è la lunghezza di registrazione. La potenza della WPT è che la base migliore può essere scelta per un'applicazione specifica, identificandola da un'insieme di possibili candidate. Per determinare la base migliore, è necessario valutare e confrontare l'efficacia di diverse basi. Alla fine deve essere scelta una funzione costo per rappresentare la riuscita dell'applicazione. L'algoritmo di selezione della base migliore ha origine nella compressione del segnale, e tutte le funzioni costo associate con la compressione implicano una certa misura di entropia. Questo può essere considerato ottimale per la compressione del segnale, ma potrebbe essere inappropriato per la classificazione.

Una forma modificata di questo algoritmo è stata proposta da N. Saito (49), che ha chiamato l'algoritmo Local Discriminant Basis (LDB), suggerendo che venga selezionata dall'albero binario WPT la base ortonormale che più discrimina il dato set di classi. La misura della separabilità delle classi è descritta dalla misura di discriminazione D. Una misura discriminante di n feature può essere definita come $D(p, q)$, dove $p = \{p_i\}_{i=1}^n$ e $q = \{q_i\}_{i=1}^n$ sono misure utilizzate per rappresentare le n feature per due diverse classi p e q. Tra diverse misure di discriminazione studiate da (50), quella che ha mostrato fornire la

migliore performance per la classificazione del segnale mioelettrico è stata l'entropia simmetrica relativa:

$$D(p, q) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i} + \sum_{i=1}^n q_i \log \frac{q_i}{p_i}.$$

Per ottimizzare la rappresentazione, nel rispetto della localizzazione della caratteristiche tempo-frequenza delle basi wavelet packet, i parametri in ingresso a D sono le mappe di energia tempo-frequenza di ogni classe.

La *time-frequency energy map* della classe c è definita come:

$$\Gamma_c(j, k, n) = \frac{\sum_{i=1}^{N_c} (\mathbf{w}_{j,k,n}^T \mathbf{x}_i^{(c)})^2}{\sum_{i=1}^{N_c} \|\mathbf{x}_i^{(c)}\|^2}.$$

Dove $\{\mathbf{x}_i^{(c)}\}_{i=1}^{N_c}$ è un set di segnali di training proveniente dalla classe c, e N_c è il numero di pattern nella classe c.

Tale energia è calcolata sommando i quadrati dei coefficienti della trasformata per ogni entry nel binary packet tree (j,k,n), e normalizzando per l'energia totale del segnale proveniente dalla classe c.

Per K classi, la misura complessiva di discriminazione per il sottospazio $\Omega_{j,k}$ è:

$$D(\{\Gamma_c(j, k, \cdot)\}_{c=1}^K) = \sum_{n=0}^{2^{n_0-j}-1} D(\Gamma_1(j, k, n), \dots, \Gamma_K(j, k, n)).$$

Sia $B_{j,k}$ il set di vettori base provenienti dal subspace $\Omega_{j,k}$ disposto in forma matriciale

$$B_{j,k} = [\mathbf{w}_{j,k,0}, \mathbf{w}_{j,k,1}, \dots, \mathbf{w}_{j,k,2^{n_0-j}-j}]^T,$$

sia $A_{j,k}$ l'LDB per il training set ristretto alla larghezza di $B_{j,k}$, e sia $\Delta_{j,k}$ un array di lavoro contenente le misure di discriminazione del nodo (j,k), l'algoritmo LDB è definito come segue.

Dato un data set di training contenente K classi di segnali $\left\{ \left\{ \mathbf{x}_i^{(c)} \right\}_{i=1}^{N_c} \right\}_{c=1}^K$,

0. Scegliere un metodo di decomposizione tempo-frequenza. Cioè, specificare una WF, il grado di decomposizione J, e la misura di discriminazione D.
1. Costruire la mappa di energia tempo-frequenza Γ_c per $c = 1, \dots, K$.

2. Iniziare dal livello J: il set $A_{j,k} = B_{j,k}$ e $\Delta_{j,k} = D(\{\Gamma_c(j,k,\cdot)\}_{c=1}^K)$ per $K = 0, \dots, 2^j - 1$.
3. Determinare il miglior sottospazio $A_{j,k}$ per $j = J - 1, \dots, 0, k = 0, \dots, 2^j - 1$ dalla regola seguente:

$$\text{Settare } \Delta_{j,k} = D(\{\Gamma_c(j,k,\cdot)\}_{c=1}^K)$$

$$\text{se } \Delta_{j,k} \geq \Delta_{j+1,2k} + \Delta_{j+1,2k+1} \text{ allora } A_{j,k} = B_{j,k}$$

$$\text{altrimenti } A_{j,k} = A_{j+1,2k} \oplus A_{j+1,2k+1} \text{ e } \Delta_{j,k} = \Delta_{j+1,2k} + \Delta_{j+1,2k+1}.$$

Quando lo step 3 è completato, stiamo partendo da $A_{0,0}$, che è l'LDB ristretto alla dimensione di $B_{0,0} = \mathfrak{R}^N$: una base completamente ortogonale. L'LDB scelto consiste in un set di sottospazi disgiunti, che formano una copertura del piano tempo-frequenza. L'algorithmo di *pruning* è veloce dato che si è scelta la misura D come additiva.

4.3.1.4 Confronto tra feature nel dominio del tempo (TD) e del tempo-frequenza (TFD)

Diversi studi hanno cercato di valutare quale tipo di dominio sia più adatto per la classificazione del segnale sEMG.

Nello studio svolto da Englehart et al. (41), si sono confrontate le performance di classificazione di feature set appartenenti al TD e TFD:

1. Feature set di Hudgins nel TD,
2. Feature set basato sulla STFT,
3. Feature set basato sulla WT,
4. Feature set basato sulla WPT.

Per ciascuna trasformata in analisi, sono stati scelti empiricamente i parametri ottimali (Tabella 13) in modo da avere una miglior generalizzazione, in media, tra tutti i soggetti.

STFT	WT	WPT
Lunghezza finestra: 64 ms	Wavelet madre**: Coiflet-4	Wavelet madre**: Symmlet-5
Overlap tra finestre: 50%		Funzione di costo***: Separabilità tra classi (distanza Euclidea)
Tipo di finestra*: Hamming		
*: Scelta tra le finestra Rettangolare, di Hamming, di Hanning, di Blackman, di Bartlett e di Kaiser (Marple et al., 1987, (51)).		

** : Scelta tra tutti i possibili ordini delle seguenti famiglie: Daubechies, Coiflet, Symmlet, Vaidyanathan, Beylkin e biorthogonal spline (Daubechies et al., 1992, (52)).

*** : Scelta tra più criteri, tra cui la compressione e la separabilità tra classi basate su funzioni obiettivo.

Tabella 13: Parametri ottimali delle Trasformate tempo-frequenza (Englehart et al., 1999, (41)).

Dai risultati, si è ricavato che la miglior performance si ottiene scegliendo la combinazione WPT/PCA/LDA, come mostrano la Fig.57 e la Tabella 14.

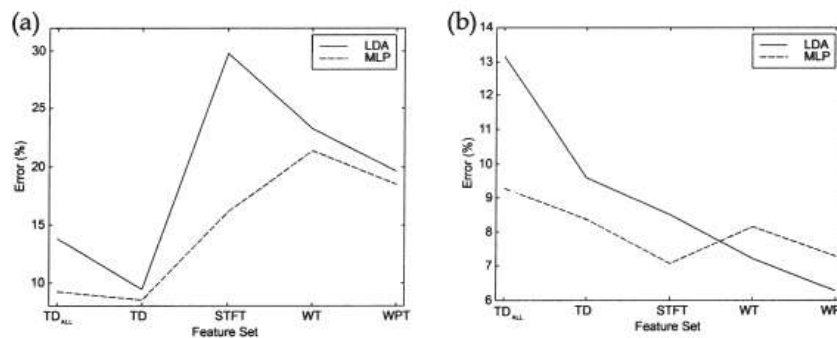


Figura 57: Errore di classificazione al variare del feature set, per il classificatore LDA e MLP. (a) Utilizza il metodo di riduzione della feature Selection (CS); (b) utilizza la PCA.

	Elementi confrontati	Combinazione per miglior performance (minor errore assoluto)
Feature set	-TD -STFT -WT -WPT	WPT
Metodo di riduzione	-CS -PCA	PCA
Classificatore	-LDA -MLP	LDA

Tabella 14: Combinazione Feature set, metodo di riduzione e classificatore che forniscono le migliori performance.

Un seguente studio (20), svolto dagli stessi autori, ha confermato la miglior performance della WPT, rispetto agli altri feature set (TD, STFT e WT), sia per segnali transienti sia per segnali steady state. I risultati sono stati ottenuti applicando il metodo di riduzione PCA e il classificatore LDA.

Un recente studio di Li et al. (25), ha confrontato 4 feature set, i primi 3 appartenenti al TD e l'ultimo al TFD:

1. feature set di Hudgins (MAV, WL, ZC e SSC),
2. coefficienti del modello AR di ordine 6,
3. MAV, WL e coefficienti del modello AR di ordine 6,
4. 8 valori medi dei coefficienti ricostruiti dagli 8 set di wavelet packet coefficients, ottenuti scegliendo la wavelet madre db4 e il livello di scomposizione 3.

I risultati hanno mostrato che, usando il classificatore LDA, la miglior performance si ottiene con il feature set di Hudgins, mentre la peggiore si ha con il feature set costituito dai coefficienti AR.

4.3.2 Feature reduction

Nella maggior parte dei problemi reali di *machine learning* si cerca di descrivere degli oggetti complessi, quindi, i dati sono rappresentati in termini di feature vector ad elevata dimensionalità. L'alto numero di feature incide in maniera negativa sull'affidabilità dei risultati ottenuti, in quanto l'apprendimento da parte del sistema in uno spazio di così vaste dimensioni risulta, in generale, impossibile. Le features, in particolare quelle estratte nel dominio tempo-frequenza, dovrebbero essere ridotte dimensionalmente prima di essere mandate al classificatore.

Un modo pratico per ovviare a questo problema è la riduzione di dimensionalità (DR) dello spazio delle feature attraverso delle forme di *feature mapping* in modo da ridurre le variazioni intra-classe e mantenere, o esaltare, quelle inter-classi. Inoltre, al fine di migliorare la qualità del segnale e ridurre il rumore, la DR può tentare di ridurre le ridondanze nel feature *vector*. Tramite questa tecnica si rappresenta, quindi, un dato multidimensionale in una dimensione ridotta ma comunque significativa. Tale rappresentazione avrà, idealmente, dimensionalità corrispondente a quella intrinseca dei dati, che rappresenta il minimo numero di parametri necessari per descrivere le proprietà dei dati osservati e che viene quindi scelta come dimensionalità appropriata dello spazio ridotto delle feature.

Quindi, assumendo che il dataset sia rappresentato da una matrice $X, n \times D$, formata da n vettori $x_i (i \in \{1, 2, \dots, n\})$ con dimensionalità D , e che il dataset abbia dimensionalità d (con $d \ll D$), con dimensionalità intrinseca si indica che i punti del dataset X giacciono

su un dataset di dimensionalità d che è interno allo spazio D -dimensionale. La DR trasforma, perciò, un dataset X con dimensionalità D , in un nuovo dataset Y di dimensionalità d , cercando di conservare il più possibile la geometria dei dati. Perciò, la dimensionalità intrinseca determina essenzialmente se il dato pattern D -dimensionale possa essere descritto adeguatamente in un sottospazio di dimensionalità minore di D .

La tecnica della DR è, quindi, in grado di ridurre la dimensionalità dei dati mantenendo la capacità di discriminazione, riducendo la quantità di memoria richiesta e aumentando la velocità del classificatore grazie alla riduzione del numero di parametri di apprendimento necessari. Inoltre riduce il problema della *curse of dimensionality* che si traduce nel peggioramento delle performance di classificazione che si ha quando il numero di campioni di training, utilizzati nel progetto del classificatore, è piccolo rispetto al numero delle feature. Bisogna, comunque, ricordare che un'eccessiva riduzione del numero di feature può condurre ad una perdita del potere di discriminazione e quindi ad una minore accuratezza del sistema di riconoscimento risultante (53).

Esistono due metodi generali per la DR delle feature: la *feature selection* e la *feature projection* (40). Il primo approccio ricerca tutte le caratteristiche esistenti in un possibile spazio delle caratteristiche, in modo da scegliere un subset ottimale che risulti in un più elevato grado di classificazione. Il secondo approccio crea un subset di nuove caratteristiche tramite una combinazione delle feature del set originale, basandosi su una mappatura lineare e non lineare. La scelta tra feature selection e feature projection dipende dal dominio di applicazione e dai dati di training disponibili.

4.3.2.1 Feature Selection

La feature selection richiede una strategia di ricerca che selezioni dei subset, e una funzione oggettiva che li valuti. Ci sono molte strategie di ricerca per la selezione dei subset di feature, come la *sequential forward selection*, *sequential backward selection*, e la *sequential floating selection*; così come molte strategie di ricerca random, quali la *branch and bound*, la *simulated annealing*, ed i *Genetic algorithms*.

Una funzione oggettiva può essere sia una misura geometrica di separabilità, sia l'*hit rate* di un classificatore. Oskoei e Hu (40) hanno presentato una feature subset selection per trovare il subset migliore di caratteristiche mioelettriche utilizzando algoritmi genetici a cascata come strategia di ricerca, e l'indice Davies-Bouldin come misura di separabilità

delle classi; mentre, Englehart et al. (41) utilizzano un criterio di separabilità tra le classi basato sulla distanza Euclidea.

La feature selection può essere ritenuta un metodo supervisionato, poiché le feature vengono ordinate in base all'informazione di appartenenza alla classe. L'incorporamento di tale informazione all'interno del metodo influenza la rappresentazione dei dati di training e quindi anche il classificatore, ostacolando la performance di generalizzazione. Questo metodo di feature reduction conduce ad una diminuzione del costo computazionale (poiché alcune feature vengono escluse) e le feature selezionate mantengono la loro interpretazione fisica originale e possono quindi essere importanti per capire il processo fisico che ha generato il pattern. Tuttavia, l'approccio feature projection fornisce un'abilità di discriminazione superiore rispetto al migliore subset di feature selezionato da quelle date, anche se queste nuove feature possono non avere un chiaro significato fisico (20) (53); dunque, in questo lavoro, si è scelto di utilizzare tale metodo di feature reduction.

4.3.2.2 Feature Projection

La feature projection è largamente utilizzata per superare il problema della dimensionalità che si ha soprattutto quando si utilizzano caratteristiche tempo-scala. Infatti, la trasformata wavelet genera molti coefficienti per rappresentare le caratteristiche in tale dominio. Questi richiedono di essere mappati in dimensioni minori, preservando le informazioni discriminanti. Le nuove feature, ottenute come combinazioni lineari o non lineari del set originale, possono, quindi, non avere un chiaro significato fisico. La *Principal Component Analysis* (PCA) e la *Linear Discriminant Analysis* (LDA) sono le due principali funzioni lineari di mapping utilizzate per la feature projection nel machine learning. La prima si basa su un criterio di rappresentazione del segnale che riproduce i campioni in maniera accurata in uno spazio lineare a più bassa dimensione utilizzando il criterio dell'errore quadratico medio; la seconda, si basa invece su un criterio di classificazione che esalta l'informazione di discriminazione delle classi nello spazio di minore dimensione per estrarre linearmente le feature più discriminanti. Englehart et al. (20) (41) hanno presentato uno studio comparativo relativamente all'applicazione della *linear projection* nelle caratteristiche tempo-scala, evidenziando come la PCA fornisca le migliori performance. Tra le tecniche non lineari si trovano la *Multi-Dimensional Scaling* (MDS) (54) e le *Self-Organizing Features Maps* (SOFM) (55).

a. Tecniche lineari

Le tecniche lineari assumono che i dati giacciono sopra ad un sottospazio lineare dello spazio multidimensionale totale. Questi metodi eseguono la DR fissando i dati in questo sottospazio di dimensionalità ridotta.

La tecnica lineare, non supervisionata, più diffusa è la PCA.

Principal Component Analysis (PCA)

L'analisi delle componenti principali è un metodo di estrazione di feature basata sul criterio dell'errore quadratico medio. È una tecnica non supervisionata e non è quindi espressamente finalizzata ad ottimizzare l'accuratezza in un problema di classificazione ma è invece un approccio classico alla riduzione della dimensionalità. Essa esprime un dato segnale come somma di componenti ortonormali e scorrelate ed è applicabile sia a vettori aleatori (dimensione finita) che a processi aleatori; questo metodo statistico identifica le proiezioni lineari delle feature che corrispondono alle variazioni principali nei dati (56).

Sia $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ un data set di n campioni, modellizzati come realizzazioni indipendenti di un vettore aleatorio \mathbf{x} . Se si assume che le n feature che compongono tale vettore siano combinazioni lineari di m sorgenti s_1, s_2, \dots, s_m ($m \leq n$), supposte indipendenti (e quindi anche scorrelate), si ha un problema di *Blind Source Separation*. La PCA sfrutta l'informazione di scorrelazione tra le sorgenti e genera un insieme di, al massimo, n feature scorrelate y_1, y_2, \dots, y_n , come stime delle sorgenti, a partire dalle n feature generiche x_1, x_2, \dots, x_n .

La matrice di covarianza nello spazio trasformato è diagonale:

$$\begin{aligned} COV\{\mathbf{y}\} &= E\{(\mathbf{y} - E\{\mathbf{y}\})(\mathbf{y} - E\{\mathbf{y}\})^t\} = \\ &= \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} \end{aligned}$$

In particolare, l'elemento diagonale i -esimo λ_i della covarianza nello spazio trasformato è la varianza della feature y_i : $VAR\{y_i\} = \lambda_i$, per $i = \{1, 2, \dots, n\}$.

La decorrelazione delle feature date si ottiene mediante una trasformazione lineare definita da una matrice di dimensioni $n \times n$, T : $\mathbf{y} = T\mathbf{x}$.

La matrice T si ottiene diagonalizzando la matrice di covarianza di \mathbf{x} : $S = COV\{\mathbf{x}\}$.

S è una matrice $n \times n$ simmetrica, semidefinita positiva, ed ammette quindi n autovalori $\lambda_1, \lambda_2, \dots, \lambda_n \geq 0$ ed n autovettori ortonormali $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$. La matrice T adottata dalla PCA è, per definizione, data dalla giustapposizione per righe degli autovettori della matrice di covarianza, ed è quindi una matrice ortogonale :

$$T = \begin{bmatrix} \mathbf{e}_1^t \\ \vdots \\ \mathbf{e}_n^t \end{bmatrix}$$

Le variabili aleatorie y_1, y_2, \dots, y_n (ossia le proiezioni di \mathbf{x} lungo gli assi $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n$) si dicono componenti principali. Generalmente, si ordinano gli n autovalori di S in ordine decrescente ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$). Quindi, l'asse \mathbf{e}_1 è la direzione lungo cui si ha la massima dispersione ed \mathbf{e}_n è la direzione lungo cui la dispersione è più bassa. La PCA fornisce quindi intrinsecamente un ordinamento delle sorgenti estratte. Se si assume che il potere informativo di una feature sia legato alla sua varianza e se gli ultimi autovalori sono molto piccoli, le feature trasformate corrispondenti si possono considerare poco significative.

La matrice di covarianza S del vettore aleatorio \mathbf{x} è solitamente sconosciuta e va stimata a partire dal dataset $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$. Si assume che $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ sia un insieme di n vettori aleatori indipendenti ed identicamente distribuiti con distribuzione uguale a quella di \mathbf{x} . Sotto tali ipotesi, una stima non polarizzata e consistente della matrice di covarianza S è data dalla covarianza-campione: $\hat{S} = \frac{1}{n-1} \sum_{k=1}^n (\mathbf{x}_k - \hat{\mu})(\mathbf{x}_k - \hat{\mu})^t$, dove $\hat{\mu} = \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k$ è la media-campione, stima non polarizzata e consistente della media $\mu = E\{\mathbf{x}\}$ del vettore aleatorio \mathbf{x} .

Operativamente, la PCA consiste nei seguenti step:

1. Stima della media m e della matrice di covarianza S in termini di media-campione e covarianza-campione del data set;
2. Calcolo degli autovalori della covarianza-campione ed i corrispondenti autovettori;
3. Ordinamento degli autovalori in ordine decrescente;
4. Costruzione della matrice di trasformazione T giustapponendo per righe gli autovettori.

La PCA rappresenta la riduzione lineare ottima delle feature rispetto al criterio dell'errore quadratico medio. Considerando infatti, nello spazio n -dimensionale delle feature, un

sistema di riferimento, esso è identificato, da una base ortonormale $\{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n\}$ e da un'origine \mathbf{c} (Fig. 58).




Figura 58: (nero) Sistema di riferimento originale (X_1, X_2), (rosso) dati, (blu) asse lungo cui si ha la massima dispersione dei dati, \mathbf{e}_1 , e sua distanza dal centro del sistema di riferimento, \mathbf{c} .

In tale sistema di riferimento \mathbf{x} ($\mathbf{x} \in \mathbb{R}^n$) si esprime come: $\mathbf{x} = \mathbf{c} + \sum_{i=1}^n y_i \mathbf{e}_i$.

Essendo $\{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_n\}$ una base ortonormale, la componente y_i è data da: $y_i = \mathbf{e}_i^t (\mathbf{x} - \mathbf{c})$.

Riducendo lo spazio delle feature conservando solo m componenti, scelte in modo da minimizzare l'errore quadratico medio, si ottiene: $\bar{\mathbf{x}} = \mathbf{c} + \sum_{i=1}^m y_i \mathbf{e}_i$, che rappresenta la proiezione di \mathbf{x} sul sottospazio m -dimensionale generato dagli m autovettori $\{\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_m\}$, corrispondenti agli autovalori maggiori della matrice di covarianza.

La procedura di apprendimento della PCA è un processo volto a creare un sistema di coordinate ben descritto per la distribuzione delle feature in input. Inoltre, la PCA ha i vantaggi di una soluzione *closed-form* e classifica automaticamente l'importanza della feature nel *projection space* (57). La principale limitazione della PCA è che essa non considera la separabilità delle classi, poiché non dà importanza al *class-label* del feature vector; la PCA esegue semplicemente una rotazione delle coordinate che allinea gli assi trasformati con la direzione di massima varianza ma non è garantito che tale direzione contenga le informazioni migliori per la discriminazione (57) (53) (56). L'utilizzo di più componenti principali può condurre ad una migliore classificazione; tuttavia, l'aumento di dimensionalità dello spazio di input richiede un maggior numero di dati di training per fornire un *decision boundary* denso per superare il curse of dimensionality (24).

Altre tecniche di feature projection lineari sono: la Linear Discriminant Analysis (LDA) e l'Uncorrelated Linear Discriminant Analysis (ULDA).

Linear Discriminant Analysis (LDA)

L'LDA è un metodo supervisionato che calcola la trasformazione ottima che massimizza il rapporto della distanza tra le classi e la distanza entro la classe, ottenendo la massima discriminazione (58). Nella discriminant analysis la separazione tra le classi è enfatizzata sostituendo la matrice di covarianza totale della PCA con una misura di separabilità generale, come il criterio di Fisher, il che si traduce nel trovare gli autovettori di $S_w^{-1}S_b$ (il prodotto dell'inverso della scatter matrix dentro la classe, S_w^{-1} , e la scatter matrix tra le classi, S_b) (56).

Data una matrice di dati $A \in \mathbb{R}^{m \times n}$, la *discriminant analysis* classica calcola una trasformazione lineare $G \in \mathbb{R}^{m \times l}$ che mappa ogni colonna a_i di A nello spazio m -dimensionale, in un vettore y_i nello spazio l -dimensionale: $G: a_i \in \mathbb{R}^m \rightarrow y_i = G^T a_i \in \mathbb{R}^l (l < m)$. L'obiettivo dell'LDA è di trovare la trasformazione G in modo che la struttura dello spazio originale ad alta dimensione sia mantenuta nello spazio a dimensione ridotta.

Sia la matrice di dati A partizionata in k classi $A = [A_1, A_2, \dots, A_k]$, dove $A_i \in \mathbb{R}^{m \times n_i}$, e $\sum_{i=1}^k n_i = n$, nell' LDA (59), vengono definite tre matrici di scatter chiamate *within-class* (S_w), *between-class* (S_b) e *total* (S_t) *scatter matrix*, definite come:

$$\begin{aligned} S_w &= \frac{1}{n} \sum_{i=1}^k \sum_{x \in A_i} (x - c^{(i)})(x - c^{(i)})^T, \\ S_b &= \frac{1}{n} \sum_{i=1}^k \sum_{x \in A_i} (c^{(i)} - c)(c^{(i)} - c)^T = \frac{1}{n} \sum_{i=1}^k n_i (c^{(i)} - c)(c^{(i)} - c)^T, \quad [2] \\ S_t &= \frac{1}{n} \sum_{j=1}^n (a_j - c)(a_j - c)^T, \end{aligned}$$

dove il centroide $c^{(i)}$ dell' i -esima classe è definito come $c^{(i)} = \frac{1}{n_i} A_i e^{(i)}$ con $e^{(i)} = (1, 1, \dots, 1)^T \in \mathbb{R}^{n_i}$, e il centroide globale c è definito come $c = \frac{1}{n} A e$, con $e = (1, 1, \dots, 1)^T \in \mathbb{R}^n$. È facilmente verificabile che $S_t = S_b + S_w$.

Definendo le matrici H_w, H_b, H_t :

$$\begin{aligned} H_w &= \frac{1}{\sqrt{n}} [A_1 - c^{(1)}(e^{(1)})^T, \dots, A_k - c^{(k)}(e^{(k)})^T], \\ H_b &= \frac{1}{\sqrt{n}} [\sqrt{n_1}(c^{(1)} - c), \dots, \sqrt{n_k}(c^{(k)} - c)], \\ H_t &= \frac{1}{\sqrt{n}} (A - c e^T). \end{aligned}$$

Quindi $S_t, S_b,$ e S_w possono essere espresse come: $S_w = H_w H_w^T$, $S_b = H_b H_b^T$, $S_t = H_t H_t^T$. Le tracce delle due matrici di scatter S_w ed S_b possono essere calcolate come segue:

$$\begin{aligned} \text{trace}(S_w) &= \frac{1}{n} \sum_{i=1}^k \sum_{x \in A_i} (x - c^{(i)})^T (x - c^{(i)}) = \frac{1}{n} \sum_{i=1}^k \sum_{x \in A_i} \|(x - c^{(i)})\|^2, \\ \text{trace}(S_b) &= \frac{1}{n} \sum_{i=1}^k n_i (c^{(i)} - c)^T (c^{(i)} - c) = \frac{1}{n} \sum_{i=1}^k n_i \|(c^{(i)} - c)\|^2. \end{aligned}$$

Quindi, $\text{trace}(S_w)$ misura la coesione within-class, mentre $\text{trace}(S_b)$ misura la separazione between-class.

Nello spazio a dimensione ridotta risultante dalla trasformazione lineare G , le matrici di scatter diventano: $S_w^L = G^T S_w G$; $S_b^L = G^T S_b G$; $S_t^L = G^T S_t G$.

Una trasformazione ottima G massimizza $\text{trace}(S_b^L)$ e minimizza $\text{trace}(S_w^L)$ simultaneamente, il che è equivalente a massimizzare $\text{trace}(S_b^L)$ e minimizzare $\text{trace}(S_t^L)$ simultaneamente, poiché $S_t^L = S_w^L + S_b^L$. Un'ottimizzazione comune nella discriminant analysis classica è

$$G = \text{argmax}_G \{ \text{trace}(S_t^L)^{-1} (S_b^L) \}. \quad [8]$$

La soluzione può essere ottenuta applicando una decomposizione in autovettori della matrice $S_t^{-1} S_b$, se S_t è non singolare. Ci sono al massimo $k - 1$ autovettori corrispondenti ad autovalori diversi da zero, poiché il rango della matrice S_b è limitato superiormente da $k - 1$. Quindi, la dimensione ridotta dall'LDA classica è, al massimo, $k - 1$. Un modo stabile per risolvere questo problema di decomposizione è applicare la *Singular Value Decomposition* (SVD) sulle matrici di scatter (60).

Una limitazione di questo approccio è la necessità di avere una matrice di scatter totale, S_t , non singolare, il che può non essere ottenuto in casi di sottocampionamento; questo è noto come problema del sottocampionamento o problema di singolarità (61).

Uncorrelated Linear Discriminant Analysis (ULDA)

L'ULDA è un algoritmo per la riduzione della dimensionalità basato sulla discriminant analysis. Questo metodo possiede numerosi vantaggi. In primo luogo, le feature ottenute sono combinazioni del set originale: quindi l'ULDA tiene in considerazione le relazioni tra le diverse feature. Un altro aspetto importante è che le feature nello spazio trasformato sono incorrelate, e ciò assicura che vi sia la minima ridondanza possibile tra le feature nello

spazio ridotto. Il terzo vantaggio è che risolve il problema del fallimento della classica discriminant analysis quando la matrice di scatter tra le classi, S_b , è singolare: tale problema è risolto utilizzando la Generalized Singular Value Decomposition (56) (61).

L'ULDA è un'estensione della classica discriminant analysis espressa nell'equazione [§], dove l'inverso di una matrice, $(S_t^L)^{-1}$, è sostituito dalla matrice pseudo-inversa, $(S_t^L)^+$. Infatti, mentre l'inverso di una matrice può non esistere, la pseudo-inversa di ogni matrice è ben definita. Ovviamente, quando una matrice è invertibile, l'inversa coincide con la pseudo-inversa.

La nuova ottimizzazione diventa: $G = \operatorname{argmax}_G \{ \operatorname{trace}(S_t^L)^+(S_b^L) \}$.

La risoluzione di questo problema di massimizzazione è basata sulla diagonalizzazione simultanea delle matrici di scatter.

Sia $H_t = U\Sigma V^T$ la SVD di H_t , dove H_t è definito nell'equazione [2], U e V sono ortogonali, $\Sigma = \begin{pmatrix} \Sigma_t & 0 \\ 0 & 0 \end{pmatrix}$, $\Sigma_t \in \mathbb{R}^{t \times t}$ è diagonale, e $t = \operatorname{rank}(S_t)$. Quindi $S_t = H_t H_t^T = U\Sigma V^T V \Sigma^T U^T = U \begin{pmatrix} \Sigma_t^2 & 0 \\ 0 & 0 \end{pmatrix} U^T$.

Sia $U = (U_1, U_2)$ tali che $U_1 \in \mathbb{R}^{m \times t}$ e $U_2 \in \mathbb{R}^{m \times (m-t)}$. Poiché $S_t = S_b + S_w$, si ha:

$$\begin{aligned} \begin{pmatrix} \Sigma_t^2 & 0 \\ 0 & 0 \end{pmatrix} &= U^T (S_b + S_w) U = \begin{pmatrix} U_1^T \\ U_2^T \end{pmatrix} S_b (U_1, U_2) + \begin{pmatrix} U_1^T \\ U_2^T \end{pmatrix} S_w (U_1, U_2) = \\ &= \begin{pmatrix} U_1^T S_b U_1 & U_1^T S_b U_2 \\ U_2^T S_b U_1 & U_2^T S_b U_2 \end{pmatrix} + \begin{pmatrix} U_1^T S_w U_1 & U_1^T S_w U_2 \\ U_2^T S_w U_1 & U_2^T S_w U_2 \end{pmatrix}. \end{aligned} \quad [a]$$

Segue che $U_2^T S_b U_2 + U_2^T S_w U_2 = 0$. Quindi $U_2^T S_b U_2 = 0$ e $U_2^T S_w U_2 = 0$, poiché entrambe sono positive semidefinite. Perciò si ha $U_1^T S_b U_2 = 0$ e $U_1^T S_w U_2 = 0$, poiché entrambe le matrici nella parte destra dell'equazione sono semidefinite positive:

$$U^T S_b U = \begin{pmatrix} U_1^T S_b U_1 & 0 \\ 0 & 0 \end{pmatrix}, \quad U^T S_w U = \begin{pmatrix} U_1^T S_w U_1 & 0 \\ 0 & 0 \end{pmatrix}. \quad [b]$$

Dalle equazioni [a] e [b], si ha $\Sigma_t^2 = U_1^T S_b U_1 + U_1^T S_w U_1$. Segue che:

$$I_t = \Sigma_t^{-1} U_1^T S_b U_1 \Sigma_t^{-1} + \Sigma_t^{-1} U_1^T S_w U_1 \Sigma_t^{-1}. \quad [c]$$

Indicando $B = \Sigma_t^{-1} U_1^T H_b$, e sia $B = P\Delta Q^T$ la SVD di B , dove P e Q sono ortogonali e Δ è diagonale, allora: $\Sigma_t^{-1} U_1^T S_b U_1 \Sigma_t^{-1} = P\Delta^2 P^T = P\Sigma_b P^T$, dove:

$$\Sigma_b \equiv \Delta^2 = \text{diag}(\lambda_1, \dots, \lambda_t),$$

$$\lambda_1 \geq \dots \geq \lambda_q > 0 = \lambda_{q+1} = \dots = \lambda_t, \text{ e } q = \text{rank}(S_b).$$

Segue da [c] che: $I_t = \Sigma_b + P^T \Sigma_t^{-1} U_1^T S_w U_1 \Sigma_t^{-1} P$, perciò $P^T \Sigma_t^{-1} U_1^T S_w U_1 \Sigma_t^{-1} P = I_t - \Sigma_b \equiv \Sigma_w$ è anch'essa diagonale.

Combinando tutto insieme, si ha:

$$X^T S_b X = \begin{pmatrix} \Sigma_b & 0 \\ 0 & 0 \end{pmatrix} \equiv D_b, \quad X^T S_w X = \begin{pmatrix} \Sigma_w & 0 \\ 0 & 0 \end{pmatrix} \equiv D_w, \quad X^T S_t X = \begin{pmatrix} \Sigma_t & 0 \\ 0 & 0 \end{pmatrix} \equiv D_t,$$

$$\text{dove } X = U \begin{pmatrix} \Sigma_t^{-1} P & 0 \\ 0 & I \end{pmatrix}.$$

Quindi, la matrice X diagonalizza simultaneamente S_t, S_b , e S_w .

La soluzione del criterio proposto può essere definita come $G = X_q M$, dove X_q è la matrice che consiste delle prime q colonne di X , $q = \text{rank}(S_b)$, e $M \in \mathbb{R}^{q \times q}$ è una matrice non singolare arbitraria.

b. Tecniche non lineari

Le tecniche non lineari di riduzione della dimensionalità possono essere suddivise in tre tipologie principali:

- Tecniche globali – cercano di preservare le proprietà globali dei dati originali nella rappresentazione a dimensione ridotta;
- Tecniche locali – cercano di preservare le proprietà locali dei dati originali nella rappresentazione a dimensione ridotta;
- Tecniche di allineamento globale – allineano globalmente una collezione di modelli localmente lineari.

In questa tipologia di tecniche per la feature projection troviamo il Multidimensional Scaling (MDS) che presenta, però, il problema di non fornire una funzione di mapping esplicita, e quindi non permette di posizionare un nuovo pattern in una mappa che è stata calcolata per un dato training set senza dover ripetere il mapping. Un altro metodo utilizzato per la feature projection non lineare è la Self-Organizing Feature Map (SOFM) di Kohonen (55) che fornisce una mappa m -dimensionale con una connettività spaziale. Quest'ultimo metodo sarà ora spiegato in maniera più approfondita e successivamente implementato.

Self-Organizing Feature Maps (SOFM)

La SOFM implementa un mapping ordinato di una distribuzione ad elevata dimensionalità in una griglia regolare (simmetrica) a bassa dimensionalità. Così è in grado di convertire le relazioni complesse e non lineari tra dati ad elevata dimensionalità in semplici relazioni geometriche in una visualizzazione a bassa dimensionalità. La struttura di una SOFM (Fig. 60) di Kohonen (55) è relativamente semplice: è costituita da uno strato di unità, interconnesse tra loro, alle quali viene dato in ingresso un vettore di n componenti. I pesi delle connessioni tra il livello di input e quello di output vengono aggiornati grazie al processo di apprendimento che permette alla rete di auto-organizzarsi, mentre le connessioni tra i neuroni del livello di output presentano pesi che producono eccitazione tra i neuroni limitrofi e inibizioni tra i neuroni lontani.

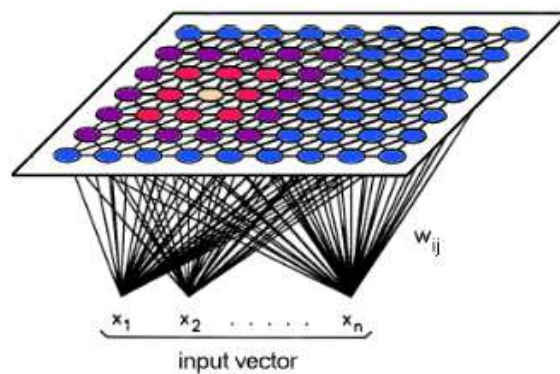


Figura 59: Struttura SOFM.

Il contributo più innovativo al classico paradigma di apprendimento competitivo è proprio quello di aver introdotto il concetto di vicinanza (*neighborhood*), e di aver esteso l'eccitazione ad un gruppo di neuroni nelle vicinanze del neurone vincente. L'utilizzo di una *neighborhood function* permette di preservare le proprietà topologiche dello spazio di input. Generalmente una SOFM consiste in una griglia regolare 2D di nodi. Un modello di una certa osservazione è associato ad ogni nodo. L'algoritmo calcola i modelli in modo che essi descrivano in maniera ottima il dominio delle osservazioni. I modelli sono automaticamente organizzati in ordine 2D significativo in cui i simili sono più vicini tra loro nella griglia, rispetto ai più dissimili. In questo senso, la SOFM è un *similarity graph*, e anche un *clustering diagram*. Il suo calcolo è un processo parametrico di regressione ricorsiva.

Supponendo che un pattern di ingresso abbia N feature e sia rappresentato da un vettore x in uno spazio di N dimensioni, l'algoritmo di apprendimento delle reti di Kohonen si sviluppa come segue (55):

1. Si inizializzano i vettori peso $w_j(0)$ sinaptici con valori casuali a partire da un set di feature disponibile, dove $j = 1, \dots, l$ ed l è il numero di neuroni nel reticolo;
2. Si prende un campione x dalla distribuzione in ingresso;
3. Si individua il neurone vincente $i(x)$ utilizzando il criterio della minima distanza Euclidea $i(x) = \arg \min_j (\|x(n) - w_j\|)$;
4. Si esegue l'aggiornamento dei pesi per tutti i neuroni utilizzando la seguente formula $w_j(n+1) = w_j(n) + \eta(n)h_{j,i(x)}(n)(x(n) - w_j(n))$ dove $\eta(n) = \eta_0 \exp\left(\frac{-n}{\tau_2}\right)$ è il *learning rate* che decresce esponenzialmente all'aumentare del tempo n , e $h_{j,i(x)}(n)$ è la funzione di vicinanza centrata nel neurone vincente $i(x)$;
5. Si continua con lo step 2 fino a quando non vengono più osservati cambiamenti rilevanti nella feature map.

Nella procedura di Pattern Recognition, la SOFM trova il neurone vincente con la migliore similarità tra il suo vettore dei pesi e il vettore di feature in input. Quindi, le coordinate 2D del neurone vincente sono le nuove componenti del feature vector.

c. Combinazione Tecniche Lineari e Non Lineari

La DR tramite PCA può approssimare la distribuzione delle feature originali, ma i cluster delle diverse classi non sono esattamente separati nello spazio ridotto delle feature. La ragione è che la PCA produce un sistema di coordinate ben descritto per la distribuzione delle feature, senza considerare la separazione delle classi. È noto, però, che caratteristiche con un'elevata separabilità delle classi migliorano l'accuratezza del riconoscimento.

Chu et al. (57) hanno proposto un metodo di feature projection composto da PCA e SOFM, che include due funzioni: la riduzione della dimensionalità e il mapping non lineare. La DR svolta dalla PCA semplifica la struttura del classificatore e riduce il tempo di processing per la Pattern Recognition. Il mapping non lineare eseguito dal SOFM, trasforma le feature ridotte dalla PCA in un nuovo spazio delle feature con una più elevata separabilità delle classi. Come risultato, il classificatore può trovare un iperpiano con un margine di separazione esaltato. Questo schema migliora le performance di classificazione

rispetto al solo utilizzo della PCA. Inoltre, è applicabile alla Pattern Recognition in real-time poiché presenta un tempo di processing minore di quello necessario se si applicasse alle feature TFD direttamente la SOFM. Gli autori hanno estratto il vettore delle feature tramite WPT, che è stato poi ridotto tramite PCA. Successivamente, gli output della PCA sono stati trasformati tramite SOFM in un nodo del reticolo per costruire i cluster dei feature set. Infine, hanno utilizzato un *Multi Layer Perceptron* (MLP) come classificatore. La migliore base WPT è stata scelta utilizzando l'algoritmo LDB proposto da Saito e Coifman (43). Per aumentare la separabilità delle classi Chu et al. (57) hanno costruito l'LDB indipendentemente per ogni canale, ottenendo i coefficienti WPT basandosi su quattro set di LDB, e hanno estratto i valori assoluti di questi coefficienti come feature nella procedura di Pattern Recognition. Una volta estratti i valori assoluti dei coefficienti WPT come feature, la PCA attua la riduzione di dimensionalità per ogni canale. La performance di riconoscimento è sensibile alla riduzione di dimensionalità del vettore delle feature, ma non è influenzata dalla DR se la dimensione ridotta dalla PCA è maggiore del ventesimo ordine. La procedura di apprendimento della PCA è un processo volto a stabilire un sistema di coordinate ben descritto per la distribuzione delle feature in input. La SOFM trasforma, in maniera non lineare, le feature ridotte dalla PCA in un nuovo spazio delle features con un'alta separabilità delle classi. Chu et al. (57) hanno allenato le SOFM indipendentemente per ogni canale.

4.4 Classificazione delle feature

Le informazioni ottenute durante la feature reduction vengono poi date in ingresso al classificatore. Questo dovrebbe essere in grado di mappare i diversi pattern e di matcharli in maniera appropriata. Un classificatore efficiente deve riuscire a classificare i pattern in poco tempo per rispondere ai vincoli specifici dell'applicazione real-time del device protesico.

I quattro migliori approcci utilizzati in letteratura nella Pattern Recognition sono: il template matching, la statistical classification, il syntactic o structural matching, e le neural networks.

Una breve descrizione riassuntiva di questi metodi è riportata nella Tabella 15 (53).

Approccio	Rappresentazione	Funzione di riconoscimento	Criterio
Template matching	Campioni, Pixel, Curve	Correlazione, misura di distanza	Errore di classificazione
Statistical	Features	Funzioni di discriminazione	Errore di classificazione
Syntactic /Structural	Primitives	Regole, grammatica	Errore di accettazione
Neural Networks	Campioni, Pixel, Features	Funzione di rete	Errore quadratico medio

Tabella 15: Metodi di classificazione usati nella Pattern Recognition.

Risulta evidente che per l'applicazione di nostro interesse debbano essere presi in considerazione l'approccio statistico e l'approccio basato sulle reti neurali e possano essere esclusi gli altri.

4.4.1 Approccio Statistico

Nell'approccio statistico, ogni pattern è rappresentato in termini di d feature ed è visto come un punto nello spazio d -dimensionale. Lo scopo è quello di fare in modo che i pattern vector appartenenti a diverse categorie vadano ad occupare delle regioni compatte e disgiunte nello spazio delle feature d -dimensionale. Dato un set di training data da ogni classe, l'obiettivo è quello di definire dei decision boundary nello spazio delle feature che separino i pattern appartenenti ad ogni classe.

Nello *Statistical Decision Theoretic Approach*, i decision boundary sono determinati dalle distribuzioni di probabilità dei pattern che appartengono ad ogni classe, la quale deve essere specificata o appresa a seconda che l'apprendimento sia o meno supervisionato.

L'approccio di classificazione *Discriminant Analysis-Based*, invece, specifica inizialmente una forma parametrica (ad esempio, lineare o quadratica) dei decision boundary e successivamente identifica il decision boundary migliore, della forma specificata, basandosi sulla classificazione dei training pattern. Tali decision boundary possono essere costruiti, ad esempio, usando il criterio dell'errore quadratico medio.

Linear Discriminant Analysis (LDA)

L'idea dell'analisi discriminante (62) è quella di associare un feature vector osservato ad una classe di movimento per cui è massimizzata la probabilità a posteriori $P(C_g|\vec{f})$, dove:

C_g ($g = [1, G]$) denota la classe di movimento e \bar{f} è il feature vector relativo ad una finestra di analisi.

La probabilità a posteriori è la probabilità della classe C_g dato il feature vector osservato \bar{f} e può essere espressa come: $P(C_g|\bar{f}) = \frac{P(\bar{f}|C_g)P(C_g)}{P(\bar{f})}$, dove: $P(C_g)$ è la probabilità a priori, $P(\bar{f}|C_g)$ è la likelihood, e $P(\bar{f})$ è la probabilità del feature vector \bar{f} osservato.

I classificatori basati sull'analisi discriminante possono essere matematicamente descritti come: $\tilde{C}_g = \operatorname{argmax}_{C_g} \{P(C_g|\bar{f})\} = \operatorname{argmax}_{C_g} \{\ln P(C_g|\bar{f})\} = \operatorname{argmax}_{C_g} \{\ln P(\bar{f}|C_g)\} + \ln P(C_g) - \ln P(\bar{f})$.

Data la classe di movimento C_g , i feature vector osservati hanno una distribuzione normale multivariata (MVN), $P(\bar{f}|C_g) \sim MVN(\mu_g, \Sigma_g)$, dove: μ_g è il vettore media, Σ_g è la matrice di covarianza della classe C_g .

Inoltre, si assume che la probabilità a priori $P(C_g)$ sia equivalente per ciascuna classe di movimento e che ogni classe abbia un valore di covarianza comune, ossia $\Sigma_g = \Sigma$.

Quindi, la massimizzazione della probabilità a posteriori diventa: $\tilde{C}_g = \operatorname{argmax}_{C_g} \{\ln P(\bar{f}|C_g)\} = \operatorname{argmax}_{C_g} \left\{ \bar{f}^T \Sigma^{-1} \mu_g - \frac{1}{2} \mu_g^T \Sigma^{-1} \mu_g \right\} = \operatorname{argmax}_{C_g} \{d_{C_g}\}$ dove d_{C_g} è definita come la funzione lineare discriminante.

Nel training offline, μ_g e Σ vengono stimati a partire dai feature vector calcolati da una gran quantità di dati di training: $\tilde{\mu}_g = \frac{1}{K_g} \sum_{k=1}^{K_g} \bar{f}_{C_g,k}$ e $\tilde{\Sigma} = \frac{1}{G} \sum_{g=1}^G \frac{1}{K_g-1} (F_g - M_g) (F_g - M_g)^T$,

dove: K_g è il numero di osservazioni nella classe C_g , $\bar{f}_{C_g,k}$ è il feature vector k -esimo osservato nella classe C_g , F_g è la feature matrix $F_g = [\bar{f}_{C_g,1}, \bar{f}_{C_g,2}, \dots, \bar{f}_{C_g,K_g}]$, e M_g è la mean matrix $M_g = [\tilde{\mu}_g, \tilde{\mu}_g, \dots, \tilde{\mu}_g]$, che ha lo stesso numero di colonne di F_g .

Perciò, i parametri della funzione lineare discriminante sono noti, cioè: $\tilde{d}_{C_g} = \bar{f}^T \tilde{\Sigma}^{-1} \tilde{\mu}_g - \frac{1}{2} \tilde{\mu}_g^T \tilde{\Sigma}^{-1} \tilde{\mu}_g$.

Nella fase di testing, la feature osservata \bar{f} relativa a ciascuna finestra di analisi viene data in ingresso al classificatore per calcolare \tilde{d}_{C_g} per ogni classe di movimento e viene

classificata in una specifica classe \tilde{C}_g che soddisfa:

$$\tilde{C}_g = \operatorname{argmax}_{C_g} \{ \tilde{d}_{C_g} \}, C_g \in \{ C_1, C_2, \dots, C_G \}.$$

4.4.2 Approccio basato sulle reti neurali

La principale caratteristica delle reti neurali è la loro l'abilità di apprendere relazioni complesse e non lineari di input-output, e di adattarsi ai dati. Le famiglie di neural network più comunemente utilizzate per la Pattern classification sono le *feed-forward network*, che includono il Multilayer Perceptron (MLP). Queste reti sono organizzate in strati ed hanno connessioni unidirezionali tra essi.

L'accuratezza di classificazione del MLP dipende molto dalla separabilità delle classi delle feature in input.

L'MLP ha origine dal modello del percettrone, che è un modello semplificato del neurone biologico (Fig. 60).




Figura 60: Modellizzazione del neurone biologico con un percettrone.

In natura, il neurone accumula carica (informazione) a livello delle sinapsi. L'entità di tale carica dipende dall'intensità del segnale a livello dei neuroni presinaptici (x_i) e dalla forza delle sinapsi dei neuroni presinaptici (w_i).

La carica accumulata nel neurone si può vedere come una somma pesata dei segnali provenienti dai neuroni presinaptici ($\sum_{i=1}^n w_i x_i$). Quindi, ogni volta che viene superata una

certa soglia di carica, detta soglia di attivazione, il neurone rilascia carica lungo il suo assone.

Il perceptrone è un classificatore di tipo binario, che adotta come funzione di attivazione σ una funzione segno.

In fase di training della rete, vengono presentati al perceptrone le coppie input/target (\vec{x}, t) e vengono aggiornati i pesi w_i e il bias b fino all'epoca tale per cui gli errori sui dati di training si annullano.

Il limite del perceptrone è che riesce a generare solo funzioni di separazione di tipo lineare. Ad esempio, considerando di avere in ingresso il vettore $\vec{x} = [x_1 \ x_2]$, il perceptrone è in grado di generare, come funzione di separazione tra le classi, una retta. Più in generale, per un vettore n-dimensionale \vec{x} , viene generato un iperpiano nello spazio n-D.

Per superare tale limitazione, sono stati introdotti i perceptroni multistrato, reti neurali di tipo feedforward organizzate in più strati (Fig. 61):

1. strato di ingresso: costituito dal vettore di input,
2. strato di uscita: che genera gli output,
3. uno o più strati nascosti: posti tra lo strato di ingresso e quello di uscita.




Figura 61: Architettura MLP.

Ogni nodo appartenente agli strati nascosti e allo strato di uscita si comporta come un perceptrone: è quindi caratterizzato dai suoi pesi, dal suo bias e dalla funzione di attivazione σ , la quale è costante per tutti i nodi di uno strato.

Questa tipologia di rete viene allenata tramite il metodo della *backpropagation*, il quale altro non è che un metodo del gradiente, che propaga dai nodi di uscita fino a quelli di ingresso, l'errore della rete (Fig. 62).

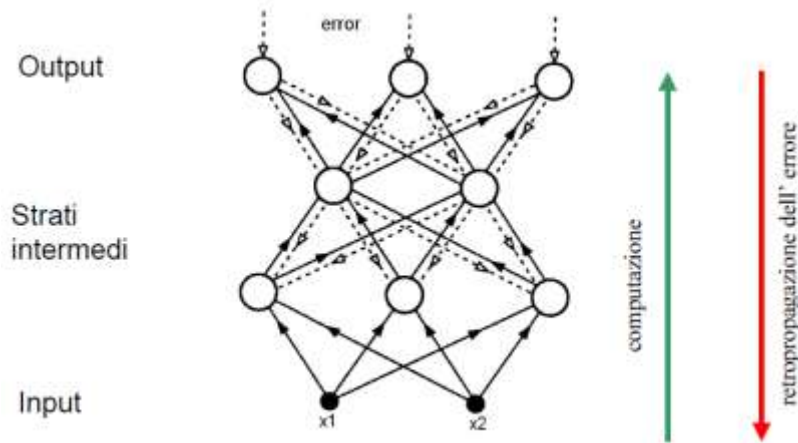


Figura 62: Metodo della backpropagation.

Definita una cifra di merito (quale può essere la cross entropia), l'aggiornamento dei pesi sinaptici avviene in modo da minimizzare tale funzione. Questa operazione richiede di calcolare la derivata parziale della cifra di merito rispetto ai singoli pesi della rete. Questa rappresenta un fattore di sensitività che determina la direzione di ricerca nello spazio dei pesi. Per i neuroni degli strati nascosti, per i quali non è definita un'uscita desiderata, l'errore viene determinato in modo ricorsivo dagli errori di tutti i neuroni direttamente connessi a quello in esame. La backpropagation richiede che la funzione di attivazione di tutti i neuroni della rete, pur rimanendo non lineare, sia differenziale (come le funzioni sigmoidali).

Capitolo 5.

Materiali

Per la realizzazione del presente lavoro di tesi si è reso necessario l'utilizzo di un set up sperimentale per l'acquisizione dei segnali elettromiografici utilizzati per svolgere l'analisi off-line necessaria per l'individuazione dei pattern da dare in ingresso al classificatore. Le componenti principali del set up sperimentale sono:

- Elettromiografo BTS FREEEMG 300®,
- Caricatore per le sonde,
- Elettrodi per la rilevazione del segnale sEMG,
- Personal computer (workstation),
- Access Point per la connessione wireless tra l'elettromiografo e la workstation,
- Sistema optoelettronico SMART di analisi del movimento con 8 telecamere.

5.1 BTS FREEEMG 300



Figura 63: BTS FREEEMG 300®.

Il segnale elettromiografico è stato rilevato tramite il BTS FREEEMG 300® (Fig. 63). Il modello utilizzato è basato su tecnologie wireless, ed impiega, per il prelievo e la trasmissione del segnale EMG, sonde miniaturizzate che amplificano il segnale, lo

convertono in formato digitale e lo trasmettono ad un'unità ricevente (UR) che può essere indossata dal paziente, posata sul tavolo o tenuta dal medico. L'unità ricevente può inviare i dati ad una Workstation (WS), su cui è installato il software sviluppato per l'acquisizione, la visualizzazione e una prima elaborazione dei segnali elettromiografici.

5.1.1 Sonde EMG Wireless

BTS FREEEMG 300® utilizza per il prelevamento del segnale EMG sonde wireless miniaturizzate ad elettrodi attivi dal peso inferiore ai 9 grammi. Le sonde (Fig. 64) possono essere agganciate, attraverso delle clip, direttamente agli elettrodi pregellati senza ulteriore fissaggi con cerotti o biadesivi.




Figura 64: Sonde delettromiografiche.

Ciascuna sonda (bipolare) si compone di un elettrodo madre e di un elettrodo satellite, ciascuno dotato di clip. Le due parti, collegate attraverso un cavetto flessibile, possono essere posizionate secondo le esigenze dell'utente a distanza variabile tra i 16 mm e i 66 mm. Nell'elettrodo madre si trovano il convertitore A/D, l'antenna e la batteria, mentre nell'elettrodo satellite si trova il Signal Conditioning (preamplificatore e filtro) ed è riportato l'ID della sonda.

Tutte le sonde sono inoltre equipaggiate di una memoria tampone, a stato solido, per evitare la perdita dei dati per problemi alla rete WI-Fi o a causa del superamento della distanza rispetto al range operativo utile.

Ciascuna sonda è inoltre dotata di un LED di stato.

Le caratteristiche delle sonde sono riportate nella Tabella 16:

Elettrodi di superficie	Elettrodi di superficie a geometria variabile con connessione clip Interdistanza=16 mm-66 mm
Batteria	ricaricabile a ioni di litio
Autonomia	5h in acquisizione continua. Fino a 5 giorni in modalità stand-by

Dimensioni	17x36x8mm elettrodo madre; diametro 17 x 8mm elettrodo satellite
Peso	<9g, batteria inclusa
Trasmissione dati a UR	Banda ISM 2.4GHz (standard IEEE802.15.4)
Portata sonde-UR	Fino a 50 m in spazio libero (si può ridurre a 30 metri in presenza di ostacoli interposti)
Memoria	Memoria tampone a stato solido on board
Impedenza d'ingresso	>10 GOhm
CMRR	>110 dB @ 50-60Hz
Risoluzione	16bit
Frequenza di acquisizione	Fino a 4KHz
Sensibilità	1 μ V
Accuratezza di misura	\pm 2%

Tabella 16: Specifiche delle sonde wireless BTS FREEMG300®.

5.1.2 Unità Ricevente (UR)

L'UR è composta da un'unità di acquisizione e da una piattaforma PocketPC (Fig. 65).



Figura 65: Componenti Unità ricevente BTS FREEMG300®.

L'unità d'acquisizione è costituita da: una scheda digitale, una scheda ricevitore, una guida per l'inserzione del PocketPC.

La scheda digitale si connette al palmare, attraverso la porta Compact Flash, quando questo viene fatto scivolare nell'apposita guida. Connettendo l'unità d'acquisizione al palmare, la scheda digitale comunica "descrivendo" se stessa al driver in esecuzione e permettendo così l'autoconfigurazione e l'autodiagnosi del sistema. Oltre a fungere da interfaccia Compact Flash, la scheda digitale permette il controllo della scheda ricevitore e gestisce l'acquisizione dei dati provenienti dalle sonde.

La scheda ricevitore è composta da 4 elementi che fungono da coordinatori delle reti wireless di comunicazione con le sonde, sia per l'attivazione che per l'acquisizione dei dati.

L'unità di acquisizione è in grado di gestire fino a 16 sonde destinate all'acquisizione dell'attività di altrettanti segnali elettromiografici.

L'HP iPAQ hx4700 PocketPC è un Personal Digital Assistant basato su Microsoft Windows®.

Le caratteristiche dell'UR sono riportate nella Tabella 17:

Autonomia	fino a 24h con batterie ricaricabili; fino a 9h con batteria singola
Batteria	ricaricabile a ioni di litio
Dimensioni	155x106x35mm
Peso	360 grammi
Frequenza impegnata	banda ISM 2.4GHz (standard IEEE802.15.4 e IEEE802.11b)
Portata UR-PC	fino a 30 m indoor – fino a 350 m outdoor
Display	4" VGA colori touch-screen

Tabella 17: Caratteristiche dell'UR BTS FREEEMG330®.

5.2 Caricatore per le sonde

La carica delle sonde avviene tramite un caricatore dedicato, il Charger, a cui le sonde si agganciano attraverso le stesse clip utilizzate per il prelevamento del segnale elettromiografico.



Figura 66: Caricatore per le sonde BTS FREEEMG330®.

Una volta collegato l'adattatore AC/DC alla rete e azionato l'interruttore posto sul pannello posteriore, il Charger permette di caricare simultaneamente 8 sonde EMG.

5.3 Personal Computer e Software

La strumentazione utilizzata viene gestita in remoto da un PC tramite i software della famiglia SMART dedicati all'analisi del movimento, con i quali è stato possibile acquisire e processare i segnali elettromiografici in maniera integrata e sincrona ai segnali del sistema optoelettronico connesso.

I software impiegati sono:

- SMART Diagnostic permette di rilevare lo stato di connessione delle periferiche di acquisizione del sistema;
- SMART Capture che permette di calibrare il sistema optoelettronico, settare i parametri di acquisizione, avviare/interrompere la registrazione, visualizzare in tempo reale il segnale elettromiografico di uno o più canali selezionati e la cinematica registrata da ogni singola telecamera;
- SMART Tracker è un ambiente grafico interattivo che permette la ricostruzione 3D dei marker a partire dalla sequenza di dati 2D catturata dalle telecamere. Permette la creazione di un modello cinematico, nel quale viene assegnata un'etichetta ad ogni marker e vengono definiti i segmenti di connessione tra essi. Consente, inoltre, una volta acquisito, di associare ad ogni marker il corrispondente *label* del modello. Sono presenti numerose altre funzioni secondarie, tra cui la visualizzazione della traiettoria di ciascun marker, della posizione delle telecamere e della terna di riferimento.
- SMART Analyzer che permette di effettuare elaborazioni avanzate dei segnali EMG, estrarre parametri cinematici e di integrarli con i dati elettromiografici.

5.4 Access Point

La trasmissione real-time dei dati tra l'UR e la Workstation (PC laptop o desktop) avviene tramite rete Wi-fi. Questo tipo di connessione viene garantita utilizzando un Access Point (AP), ossia un dispositivo Ethernet che funziona da ponte tra i dispositivi wireless e i sistemi collegati fisicamente alla rete tramite connettore RJ45. L'AP diffonde i segnali all'area circostante attraverso onde radio (Fig. 67). Tutti i dispositivi wireless interni a tale area possono ricevere segnali e comunicare con l'AP e, attraverso esso, con tutti gli altri dispositivi, creando quindi una rete senza fili.

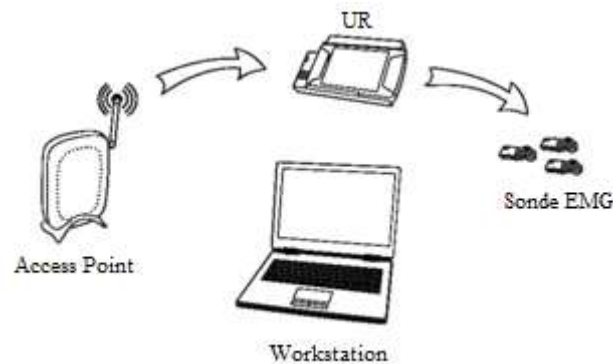


Figura 67: Schema di funzionamento dell'Access Point.

5.5 Elettrodi per sEMG

Gli elettrodi utilizzati nella fase sperimentale sono degli elettrodi standard per elettrostimolazione neonatale, ECG per neonatologia, EMG e biofeedback, circolari con diametro di 26mm, in FOAM, a clip in Ag/AgCl, pregellati, monouso, prodotti da BIELSAN® (Fig. 68).



Figura 68.

Gli elettrodi sono stati scelti di dimensioni abbastanza contenute, tali che ciascuno giacesse in corrispondenza del muscolo indagato, cercando di ridurre così il fenomeno del cross talk, ma sufficienti a garantire un'ampiezza del segnale adeguata.

5.6 Sistema Optoelettronico SMART

La soluzione tecnologica più diffusa per l'analisi del movimento umano è rappresentata dai sistemi stereo-fotogrammetrici optoelettronici, che permettono di realizzare un'indagine cinematica tridimensionale non invasiva. Si tratta di sistemi basati sull'utilizzo di marcatori ottici, posizionati sul corpo del soggetto in particolari punti di repere anatomici, e di un numero variabile di telecamere operanti nell'infrarosso (720-820 nm).

Il nostro studio è stato svolto presso il Laboratorio di Biomeccanica del Movimento e Controllo Motorio (MBMC Lab), che è dotato di un sistema SMART-e (BTS, Milano) per l'analisi del movimento.

I marcatori ottici utilizzati sono di forma sferica e realizzati in materiale catarifrangente in modo che la luce infrarossa emessa dai quattro anelli di LED disposti su corone circolari

coassiali con la telecamera venga riflessa e possa quindi essere rilevata dal sistema di lenti e sensori matriciali indirizzabili CCD (Fig. 69).



Figura 69: Telecamera del sistema SMART-e (BTS).

Il sistema consta di 8 telecamere disposte in modo da coprire l'intero volume di lavoro (Fig. 70) e in modo che ogni marker possa essere rilevato contemporaneamente da almeno 2 telecamere al fine di poter calcolare le coordinate tridimensionali di ciascun marker.




Figura 70: Disposizione telecamere all'interno del laboratorio.

Per poter procedere alla ricostruzione 3D, risulta fondamentale effettuare una procedura di calibrazione prima di ogni serie omogenea di acquisizioni cinematiche. Questa procedura richiede di definire il volume di calibrazione e il sistema di riferimento cartesiano assoluto

(origine e orientamento degli assi nel laboratorio) e permette di determinare i parametri interni (lunghezza focale, coordinate del punto principale e coefficienti di distorsione) ed esterni (posizione del sistema di riferimento della telecamera rispetto al sistema di riferimento assoluto) delle telecamere. La determinazione dei parametri geometrici delle telecamere implica l'utilizzo di un insieme di punti di controllo, distribuiti internamente al volume di calibrazione. Nella maggior parte delle procedure di calibrazione, è necessario conoscere a priori le coordinate dei punti di controllo. A questo scopo, vengono utilizzati oggetti a forma fissa in cui i punti di controllo sono posizionati su una struttura rigida e la distanza tra questi è misurata con accuratezza a priori.

Capitolo 6.

Metodi

6.1 Definizione del protocollo di acquisizione

6.1.1 Reclutamento Soggetti

Allo studio hanno partecipato 8 soggetti (4 maschi e 4 femmine) di età compresa tra i 22 e i 29 anni (media 25, SD 1,8). Nessun compenso economico è stato assegnato ai partecipanti al test. A ciascuno è stato fatto firmare un modulo di consenso informato prima dell'avvio del test. I partecipanti hanno dichiarato di non aver alcun deficit neuromuscolare né di aver subito traumi alla spalla.

Ad ognuno di essi sono state effettuate misure antropometriche per valutare l'Indice di Massa Corporea (BMI), (altezza, peso) e per ottenere un posizionamento degli elettrodi standard (distanza tra punti anatomici di interesse). Questi valori sono riportati in Tabella 18.

	Media	Deviazione Standard
Peso (Kg)	62,8	9,4
Altezza (m)	1,7	0,1
BMI (Kg/m)	21,5	1,8
Angolo Acromiale/Processo Xifoideo (cm)	32,1	1,9
Clavicola Distale/C6 (cm)	18,1	2,4
C7/Angolo Acromiale (cm)	21,3	2,3
Spina Scapolare/T12 (cm)	33,1	2,3
Punto centrale del bordo mediale della scapola / Tubercolo maggiore (cm)	20,2	2,8
Tubercolo maggiore/ L5 (cm)	45,9	3,1

Tabella 18: Misure antropometriche e loro valori di media e deviazione standart per 8 soggetti.

Prima dell'inizio del test ad ogni soggetto è stato spiegato dettagliatamente la tipologia di movimento da eseguire e le modalità.

Al fine di evitare che, tra una ripetizione e l'altra, il soggetto mantenesse i muscoli contratti, si è scelto di non utilizzare un tutorial che lo guidasse durante l'intera esecuzione del movimento anche se questa opzione avrebbe garantito una velocità intra e inter-soggetto uniforme. Per minimizzare le variazioni di velocità tra le prove, il test è stato svolto con l'ausilio di un metronomo.

6.1.2 Scelta del Movimento

In questo studio si è deciso di considerare i movimenti svolti lungo i piani principali al fine di valutare se fosse possibile discriminarli a partire dal segnale sEMG ad essi associato. Sono stati quindi selezionati per l'articolazione della spalla destra: la flessione/estensione nel piano sagittale, l'ab/adduzione nel piano frontale e una loro combinazione nel piano inclinato di 45° rispetto al piano frontale.

Per ogni piano sono state definite le ampiezze del movimento tenendo conto dei vincoli a cui è soggetta la protesi del caso in studio (14):

- Flessione/estensione nel piano sagittale: sono stati eseguiti, a partire dalla posizione ortostatica, 4 movimenti di ampiezza, rispettivamente, pari a 45°, 90°, 110°, -30°;
- Ab/Adduzione nel piano frontale: sono stati eseguiti, a partire dalla posizione ortostatica, 2 movimenti di ampiezza, rispettivamente, pari a 45°, 90°;
- Movimento nel piano inclinato: sono stati eseguiti, a partire dalla posizione ortostatica, 2 movimenti di ampiezza, rispettivamente, pari a 45°, 90°.

Tutti i movimenti sono stati svolti a braccio completamente esteso. Ogni movimento è stato ripetuto 10 volte lasciando al soggetto la decisione di quanti secondi far trascorrere tra una ripetizione e la successiva in modo che i muscoli non rimanessero contratti in fase di rest (soggetto in ortostatismo, con piedi paralleli distanziati di 12 cm, braccia distese lungo i fianchi e con i palmi delle mani rivolti verso il corpo).

Ogni ripetizione consta di tre fasi successive:

1. Fase di Elevazione: a partire dalla posizione di riposo, si allontana l'arto dal corpo fino al raggiungimento dell'angolo target. Questa fase viene compiuta in 2 secondi;

2. Fase di Mantenimento: si mantiene l'arto nella posizione target per 3 secondi;
3. Fase di Ritorno: si ritorna alla posizione di riposo. Questa fase viene eseguita in 2 secondi.

Per indicare il punto di fine movimento nello spazio, è stata usata un'asta verticale (Fig. 71) con base di appoggio al terreno, provvista di un perno scorrevole posto perpendicolarmente all'asta.



Figura 71: Asta utilizzata in fase di acquisizione.

Prima di ogni sequenza di 10 ripetizioni è stata determinata, per ogni soggetto, la posizione della base di appoggio e l'altezza esatta a cui fissare il perno in modo tale che l'ampiezza massima del movimento si avesse in corrispondenza del contatto tra il perno e la mano del soggetto.

6.1.3 Scelta dei Muscoli

I muscoli che sono stati considerati nello studio sono stati selezionati in modo che soddisfacessero tre requisiti:

1. Coinvolgimento del muscolo nell'esecuzione dei movimenti scelti;
2. Presenza del muscolo anche a seguito di amputazione a livello dell'articolazione della spalla;
3. Muscolo superficiale (in quanto si vuole rilevare sEMG).

La scelta, tenendo conto anche del fatto che si avevano a disposizione solo 8 canali per la rilevazione del segnale sEMG, è ricaduta sui muscoli riportati in Tabella 19:

Muscolo	Atto motorio in cui è coinvolto
Grande Pettorale Clavicolare	Flessione anteriore gleno-omeroale
Grande Pettorale Sternale	Estensione all'indietro gleno-omeroale Adduzione gleno-omeroale
Serrato Anteriore	Depressione scapolare Rotazione interna della scapola
Trapezio Discendente	Elevazione scapolare Depressione scapolare Rotazione interna della scapola
Trapezio Trasverso	Depressione scapolare
Trapezio Ascendente	Depressione scapolare Rotazione interna della scapola
Infraspinato	Rotazione esterna gleno-omeroale
Gran Dorsale	Estensione all'indietro gleno-omeroale Adduzione gleno-omeroale

Tabella 19: Muscoli scelti per la fase sperimentale di acquisizione.

6.1.4 Scelta posizionamento elettrodi

Non esiste in letteratura uno standard universalmente riconosciuto per il posizionamento degli elettrodi necessari all'acquisizione del segnale elettromiografico di superficie. Pur avendo consultato le indicazioni del progetto SENIAM a riguardo, si è comunque preferito far riferimento ad un più recente atlante pubblicato da Barbero M., Merletti R. e Rainoldi A. nel 2012 (63). In questo volume sono contenute le istruzioni per posizionare gli elettrodi in modo da ottenere una corretta registrazione del segnale sEMG.

Secondo gli autori, l'area migliore per il posizionamento degli elettrodi risulta essere tra la zona di innervazione (IZ) e il tendine distale/proximale. Studiando, in 40 soggetti, le posizioni delle IZ, la cui distribuzione è stata descritta per mezzo di "box and whiskers plots" in cui si sono individuati la mediana, il quartile inferiore, il quartile superiore, il minimo e il massimo, si sono individuate le aree di ciascun muscolo in cui la probabilità che sia presente una zona di innervazioni (IZ) è molto elevata.

Per ogni muscolo investigato, l'atlante fornisce l'anatomical landmark frame (ALF), che individua la linea di congiunzione tra due punti di repere anatomici, l'area che contiene la distribuzione delle IZ descritta dal "box and whiskers plot" e il range in cui è consentito il posizionamento degli elettrodi, espresso in percentuale rispetto alla lunghezza della ALF. Tali valori sono riportati in Tabella 20, insieme ai siti prescelti per posizionare gli elettrodi.

Muscolo	Starting Point ALF	Ending Point ALF	Range (%) consentito	Posizione scelta
Grande Pettorale	Angolo Acromiale	Processo Xifoideo	0 – 45 76 - 100	25% Clavicolare 40% Sternale
Serrato Anteriore	Non è possibile individuare una ALF		Tra V e VII Costa	VII Costa
Trapezio Discendente	Clavicola Distale	VI Vertebra Cervicale	0 – 44 72 – 100	80%
Trapezio Trasverso	VII Vertebra Cervicale	Angolo Acromiale	0 – 35 70 - 100	70%
Trapezio Ascendente	Spina Scapolare	XII Vertebra Toracica	0 – 22 52 - 100	60%
Infraspinato	Punto centrale del bordo mediale della scapola	Tubercolo Maggiore	40 - 100	50%
Gran Dorsale	Punto centrale tra Tubercolo Maggiore e V Vertebra Lombare	Spina Iliaca Superiore Posteriore	0 – 16 55 - 100	0%

Tabella 20: Scelta del posizionamento degli elettrodi in corrispondenza dei muscoli scelti.

Ogni coppia di elettrodi è stata disposta parallelamente alle fibre muscolari, come spiegato nel Capitolo 2, e ad una distanza interelettrodica pari al diametro dell'elettrodo (26mm).

6.1.5 Scelta posizionamento markers

Nel presente lavoro di tesi si è utilizzato un sistema optoelettronico di analisi del movimento al fine di individuare l'istante di inizio di ciascuna delle tre fasi che costituiscono il gesto, precedentemente descritte, valutando la variazione dell'angolo alla spalla.

Sono stati apposti, su ciascun soggetto, 9 markers in corrispondenza dei seguenti punti di repere anatomici (come mostrato in Fig. 72):

- Processo Acromiale Sinistro,
- Processo Acromiale Destro,
- Spina Iliaca Posteriore Superiore Sinistra,
- Spina Iliaca Posteriore Superiore Destra,
- Spina Iliaca Anteriore Superiore Sinistra,
- Spina Iliaca Anteriore Superiore Destra,
- Gomito Destro,
- Testa Ulnare Destra,
- Testa radiale Destra.




Figura 72: Posizionamento marker.

6.2 Fase sperimentale

La fase sperimentale, effettuata presso l'MTBM LAB del Politecnico di Milano, è costituita da più sottofasi:

6.2.1 Calibrazione del Sistema Optoelettronico

Il processo di calibrazione del sistema optoelettronico si è svolta in due fasi successive tramite il software SMART Capture:

- la prima, chiamata Axis Sequence prevede l'acquisizione di tre barre, assemblate in modo da formare una terna cartesiana su cui sono posizionati a distanza nota 9 marker, che definisce il sistema di riferimento del laboratorio;
- la seconda, denominata Wand Sequence, permette di definire il volume di lavoro, acquisendo il movimento, per un determinato intervallo temporale, di una barra su cui sono posizionati 3 marker a distanza nota.

Questa procedura permette di definire il volume di calibrazione e il sistema di riferimento cartesiano assoluto (origine e orientamento degli assi nel laboratorio) e determina i parametri interni (lunghezza focale, coordinate del punto principale e coefficienti di distorsione) ed esterni (posizione del sistema di riferimento della telecamera rispetto al sistema di riferimento assoluto) delle telecamere.

L'algoritmo di calibrazione fornisce all'utente l'errore medio compiuto dal sistema nella ricostruzione 3D e la relativa deviazione standard (Fig. 73).

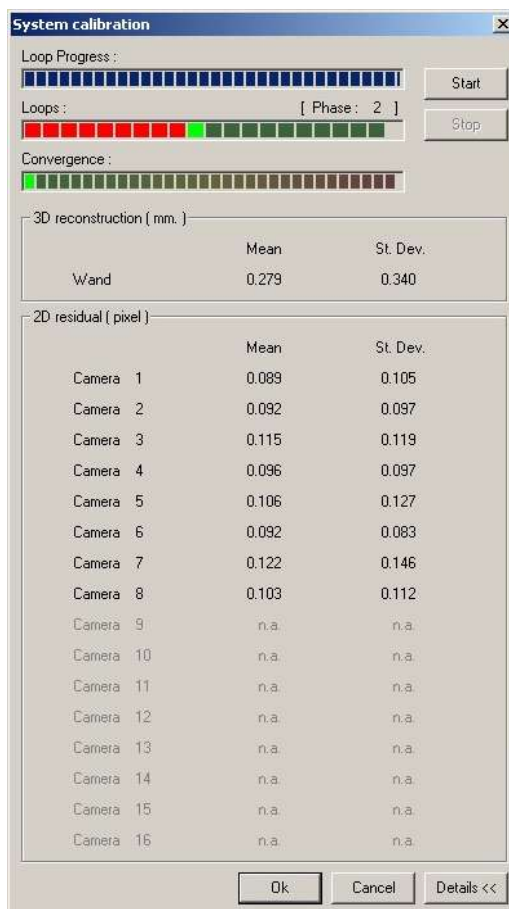


Figura 73: Risultato della calibrazione del sistema SMART-e®.

6.2.2 Preparazione del soggetto

Per ogni soggetto sono state rilevate le misure antropometriche di interesse e individuati i siti in cui allocare ciascuna coppia di elettrodi tenendo conto delle indicazioni raccomandate in (63).

È stata svolta un'accurata pulizia della pelle, tramite l'utilizzo di un dischetto di cotone imbevuto di alcool e, dove necessario, di un rasoio per eliminare i peli al fine di migliorare l'adesione degli elettrodi e ridurre l'impedenza cutanea.

Sono stati quindi applicati gli elettrodi a clip a cui sono state alloggiare le sonde wireless precedentemente attivate.

Infine, sono stati apposti i 9 marker secondo il protocollo precedentemente descritto.

La figura seguente (Fig. 74) mostra la disposizione degli elettrodi e dei marker.



Figura 74: Disposizione degli elettrodi e dei marker sul soggetto.

6.2.3 Acquisizione del segnale sEMG e dei dati cinematici

Una volta posto il soggetto all'interno del volume di calibrazione, è stata posizionata opportunamente (a seconda del piano di movimento e dell'ampiezza dell'angolo da raggiungere) l'asta con perno scorrevole facendo attenzione a non nascondere alcun marker alle telecamere.

È stato quindi spiegato al soggetto il tipo di movimento da svolgere e la modalità di esecuzione.

Si è quindi proceduto alla fase di acquisizione dei segnali elettromiografici (alla frequenza di campionamento di 1000 Hz) e cinematici (alla frequenza di campionamento di 120 Hz) tramite il software SMART Capture.

6.2.4 Creazione del modello cinematico

Il software SMART Tracker ha permesso la creazione di un modello cinematico ad hoc, come mostrato in Fig. 75.




Figura 75: Modello cinematico.

È seguita quindi la fase di *labelling* nella quale è stata associata l'etichetta corrispondente a ciascuno dei 9 marker.

6.2.5 Elaborazione dei dati

La fase di elaborazione dei dati è stata svolta tramite il software MATLAB 2013a.

L'analisi consta di due fasi successive: analisi dei dati cinematici e analisi dei segnali elettromiografici.

6.2.5.1 Analisi dei dati cinematici

In questo studio, il dato cinematico di interesse è l'angolo di elevazione del braccio, calcolato come l'angolo compreso tra i due vettori nello spazio individuati, rispettivamente, dalle coppie di marker Gomito-Spalla Destra e Spina Anteriore Destra-Spalla Destra.

Una volta calcolato l'angolo di elevazione nel tempo, si è sviluppato un algoritmo semiautomatico di individuazione degli istanti temporali relativi all'inizio e alla fine della fase Steady-State (Fig. 76), ossia le fasi di mantenimento della posizione target da parte dell'arto superiore. In letteratura, come già esposto nel capitolo relativo alla Pattern Recognition, si è evidenziato, infatti, come l'utilizzo del solo stato Steady del segnale permetta una più accurata classificazione.




Figura 76: Angolo di elevazione per un soggetto, durante il movimento di flessione a 90°. In rosso, gli istanti corrispondenti all'inizio della fase di Steady; in verde, gli istanti corrispondenti alla fine della fase di Steady.

6.2.5.2 Analisi dei dati elettromiografici

Per ciascuna prova, il segnale sEMG è stato segmentato, all'interno della fase Steady-State, tramite finestre di lunghezza L e con un incremento tra finestre vicine pari ad I .

Al fine di valutare quale tipologia di finestrazione dia un risultato migliore, in termini di accuratezza della classificazione, si è deciso di adoperare sei diverse combinazioni di lunghezza L e incremento I , come mostrato nella seguente Tabella 21.

Lunghezza finestra [msec]	Incremento [msec]
L=500 msec	I=250 msec
L=500 msec	I=125 msec
L=500 msec	I=62 msec
L=250 msec	I=250 msec
L=250 msec	I=125 msec
L=250 msec	I=62 msec

Tabella 21: Tipi di finestre usate per la segmentazione del segnale sEMG.

Per ciascuna delle sei tipologie di segmentazione, sono stati eseguiti quattro diversi percorsi di trattamento dei dati.

Ogni percorso è costituito dai seguenti blocchi principali (Fig. 77):



Figura 77: Blocchi principali della Pattern Recognition.

Come metodo di feature reduction, è stata adottata, per i primi tre procedimenti, la tecnica della PCA, in quanto è adatta ad applicazioni real-time ed è considerata la migliore tra tutte le altre forme di riduzione per la maggior parte dei feature set estratti (20). Essa è stata affiancata, nel quarto percorso, all'utilizzo delle SOFM, come consigliato da Chu et al. (57).

In fase di classificazione, si è utilizzato il classificatore basato sulla LDA, che ha il vantaggio di essere un metodo di classificazione semplice da implementare, veloce da allenare, computazionalmente efficiente per le operazioni real time e non richiede alcun parametro da settare (37) (29). Uno studio svolto da Hargrove et al. (24) ha confrontato l'LDA con altre tipologie di classificatori più complessi (MLP, LP, GMM, HMM), dimostrando che non esistono significative differenze, in termini di accuratezza di classificazione, e concludendo che, una volta scelti in maniera adeguata feature set e metodo di riduzione della dimensionalità, il processo di classificazione diviene poco rilevante, ed un semplice classificatore lineare risulta più che adatto. Un recente studio (64) ha inoltre dimostrato la maggior robustezza nel tempo dell'LDA, rispetto ai classificatori MLP, SVM, KNN e DT. Questi vantaggi lo rendono ampiamente adottato in letteratura (62) (65) (66) per lo sviluppo di sistemi a controllo mioelettrico basati sulla Pattern Recognition.

La classificazione è avvenuta considerando rispettivamente 9, 5 e 4 classi di movimento così composte:

- 9 classi : riposo, flessione a 45°, flessione a 90°, flessione a 110°, iperestensione a -30°, abduzione a 45°, abduzione a 90°, elevazione a 45° nel piano diagonale, elevazione a 90° nel piano diagonale;
- 5 classi: riposo, flessione a 90°, iperestensione a -30°, abduzione a 90°, elevazione a 90° nel piano diagonale;
- 4 classi: riposo, flessione a 90°, iperestensione a -30°, abduzione a 90°.

Tale scelta è stata fatta in modo da poter valutare meglio le performance del metodo sviluppato per un diverso numero di classi.

Il primo percorso di elaborazione, prevede:

- a. Estrazione, per ogni finestra del dataset, del time domain feature set di Hudgins, ampiamente utilizzato in letteratura (20) (64) (34) (37) (25) (19). Tale set è costituito dalle seguenti caratteristiche: *Mean Absolute Value* (MAV), *Waveform Length* (WL), *Zero Crossing* (ZC), *Slope Sign Change* (SSC).

Per ogni finestra, si ottengono così 4 feature, per ciascuno degli 8 canali.

Ogni osservazione è quindi definita da 32 feature.

- b. Suddivisione del dataset, in seguito a mescolamento random delle osservazioni: training dataset (60% del dataset originale) e test dataset (40% del dataset originale).
- c. Applicazione del metodo di riduzione della PCA sul training dataset.

Si ottiene una proiezione delle 32 feature originali, che genera 32 nuove feature.

Vengono, poi, selezionate le prime n componenti principali. La scelta di n è tale da avere il maggior numero di feature che soddisfi il requisito di singolarità della matrice di covarianza dei dati necessario per l'utilizzo del classificatore LDA.

Sperimentalmente, si è osservato che n è pari a 18.

Ogni osservazione è quindi ora definita da 18 feature.

- d. Riduzione del test dataset, coerentemente con la modalità con cui sono stati ridotti i dati di training.
- e. Classificazione dei dati di training tramite LDA.
- f. Classificazione dei dati di test tramite LDA.
- g. Valutazione dell'errore di classificazione sui dati di training.
- h. Valutazione dell'errore di classificazione sui dati di test.

Il secondo percorso di elaborazione prevede:

- a. Estrazione, per ogni finestra del dataset, del time domain feature set suggerito da Phinyomark et al. (29) per la sua robustezza nel tempo. Tale set è costituito dalle seguenti feature: *Sample Entropy* (SampEn), *Cepstral Coefficients* di ordine 4 (CC), *Root Mean Square* (RMS) e *Waveform Length* (WL).

Per ogni finestra, si ottengono così 7 feature, per ciascuno degli 8 canali.

Ogni osservazione è quindi definita da 56 *features*.

- b. Suddivisione del dataset, in seguito a mescolamento random delle osservazioni: training dataset (60% del dataset originale) e test dataset (40% del dataset originale).
- c. Applicazione del metodo di proiezione della PCA sul training dataset.
Si ottiene una proiezione delle 56 feature originali, che genera 56 nuove feature.
Vengono, poi, selezionate le prime n componenti principali. La scelta di n è tale da avere il maggior numero di feature che soddisfi il requisito di singolarità della matrice di covarianza dei dati necessario per l'utilizzo del classificatore LDA.
Sperimentalmente, si è osservato che n è pari a 56.
- d. Proiezione del test dataset, coerentemente con la modalità con cui sono stati proiettati i dati di training.
- e. Classificazione dei dati di training tramite LDA.
- f. Classificazione dei dati di test tramite LDA.
- g. Valutazione dell'errore di classificazione sui dati di training.
- h. Valutazione dell'errore di classificazione sui dati di test.

Il terzo percorso di elaborazione prevede:

- a. Estrazione, per ogni finestra del dataset, del feature set suggerito nello studio di Phinyomark et al. (39). Tale feature vector è costituito dalle seguenti caratteristiche: *Zero Crossing (ZC)*, *Willison Amplitude (WAMP)* e *Mean Absolute Value (MAV)* relativi al segnale ricostruito dai coefficienti del secondo livello con la wavelet madre Daubechies di ordine 7; e *Myopulse Percentage Rate (MYOP)* relativo al segnale ricostruito dai coefficienti del primo livello con la wavelet madre Daubechies di ordine 5 (Fig. 78).




Figura 78: Daubechies wavelet function di ordine 7 (a sinistra) e di ordine 5 (a destra).

Per ogni finestra, si ottengono così 4 feature, per ciascuno degli 8 canali.

Ogni osservazione è quindi definita da 32 feature.

- b. Suddivisione del dataset, in seguito a mescolamento random delle osservazioni: training dataset (60% del dataset originale) e test dataset (40% del dataset originale).
- c. Applicazione del metodo di proiezione della PCA sul training dataset.
Si ottiene una proiezione delle 32 feature originali, che genera 32 nuove feature. Vengono, poi, selezionate le prime n componenti principali. La scelta di n è tale da avere il maggior numero di feature che soddisfi il requisito di singolarità della matrice di covarianza dei dati necessario per l'utilizzo del classificatore LDA.
Sperimentalmente, si è osservato che n è pari a 32.
- d. Proiezione del test dataset, coerentemente con la modalità con cui sono stati proiettati i dati di training.
- e. Classificazione dei dati di training tramite LDA.
- f. Classificazione dei dati di test tramite LDA.
- g. Valutazione dell'errore di classificazione sui dati di training.
- h. Valutazione dell'errore di classificazione sui dati di test.

Il quarto e ultimo percorso di elaborazione prevede:

- a. Estrazione, per ogni finestra del dataset, del feature set costituito dai coefficienti della *Wavelet Packet Transform* (WPT), ottenuti utilizzando come wavelet function una Symmlet del quinto ordine (sym5) e con un livello di decomposizione pari a 4, come suggerito nello studio di Chu et al. (67). La wavelet function adoperata è riportata in Fig. 79.




Figura 79: Symmlet wavelet function di ordine 5

- b. Suddivisione del dataset di coefficienti, in seguito a mescolamento random delle osservazioni, ottenendo il training dataset (60% del dataset originale) e il test dataset (40% del dataset originale).
- c. Poiché il numero di coefficienti estratti da ciascuna finestra è notevole, lo studio di Chu et al. (67) propone una riduzione della dimensionalità del feature vector tramite l'impiego dell'algoritmo LDB (49), applicato separatamente per ciascun canale, che sceglie i sottospazi migliori utilizzando come funzione costo l'entropia simmetrica relativa.
- d. A partire dagli 8 set LDB, si estraggono come feature i loro valori assoluti.
- e. Applicazione del metodo di proiezione della PCA sul training dataset, separatamente per ciascun canale.
- f. Applicazione del metodo di mapping non lineare della SOFM sul training dataset, separatamente per ciascun canale. Le feature di ciascun canale vengono così trasformate in coordinate 2D, relative al neurone vincente.
- g. Riduzione della dimensionalità e mapping del test dataset, coerentemente con le modalità applicate ai dati di training.
- h. Classificazione dei dati di training tramite LDA.
- i. Classificazione dei dati di test tramite LDA.
- j. Valutazione dell'errore di classificazione sui dati di training.
- k. Valutazione dell'errore di classificazione sui dati di test.

Ciascun dei 4 percorsi di elaborazione viene riassunto nella Tabella 22:

Percorso	Feature Extraction	Feature Reduction	Classificazione
1	MAV, WL, ZC, SSC	PCA (n=18)	LDA
2	SampEn, CC, RMS, WL	PCA (n=56)	LDA
3	ZC, WAMP, MAV di D2 (WF=db7) MYOP di D1 (WF=db5)	PCA (n=32)	LDA
4	WPT (WF=sym5)	LDB, PCA, SOFM	LDA

Tabella 22: Metodi di feature extraction, feature reduction e classificazione per i diversi percorsi di elaborazione.

Poiché il quarto percorso, già in fase di feature reduction tramite LDB, non ha dato i risultati voluti, non è stato completato e perciò non verranno in seguito riportati i relativi risultati. Per curiosità del lettore, viene comunque allegato in Appendice quanto è stato implementato.

Dopo aver individuato il metodo di elaborazione migliore, in termini di accuratezza, e la segmentazione migliore ad esso associata, si è voluto indagare se, riducendo il numero di canali di acquisizione sEMG, ci fossero delle variazioni nelle performance di classificazione. A tale scopo, si sono calcolate media e deviazione standard (SD) dei valori di *Root Mean Square* (RMS) per ogni canale, prendendo in considerazione le osservazioni di tutti gli otto soggetti per un dato movimento. Si sono quindi individuati i canali per cui il valore medio di RMS non varia al variare della classe di movimento. Si è quindi provato a svolgere l'elaborazione dei segnali sEMG, con il percorso risultato migliore, andando ad escludere tali canali.

Capitolo 7.

Risultati

In questo capitolo verranno presentati i risultati relativi ai primi tre percorsi di elaborazione, al fine di individuare quale metodo di elaborazione risulta essere migliore, in termini di accuratezza della classificazione.

Ogni percorso presenta a sua volta i risultati relativi a ciascuna delle sei diverse segmentazioni, in modo da individuare quale siano i valori ottimali di lunghezza delle finestre e di incremento temporale tra finestre successive. Verranno riportati i risultati relativi alle segmentazioni che si sono rivelate essere, rispettivamente, la migliore e la peggiore.

7.1 Percorso di elaborazione 1

La Tabella 23 mostra l'errore percentuale di classificazione sui dati di Test al variare del tipo di segmentazione, per ciascuno dei 3 gruppi di classi considerati.




Tabella 23: Errore (%) di classificazione sui dati di Test, al variare della segmentazione, per 4 (blu), 5 (rosso) e 9 (verde) classi.

Per tutte le segmentazioni, si osserva un peggioramento dell'accuratezza di classificazione all'aumentare del numero di classi considerate.

Si può notare un'elevata influenza della tipologia di segmentazione sul risultato.

In particolare, i valori mostrano una miglior performance di classificazione utilizzando finestre di lunghezza pari a 500 ms con un incremento tra finestre pari a 62 ms. Per tale segmentazione, si ha infatti un errore pari a 1.75% su 4 classi, 8.87% su 5 classi e 19.57% su 9 classi. La performance peggiore, nel caso di 5 e 9 classi, si riscontra adoperando finestre adiacenti di lunghezza pari a 250 ms, con errore rispettivamente pari a 12.47% e 24.74%. Per quanto riguarda un numero di classi pari a 4, si osserva il massimo errore, pari a 3.48%, in corrispondenza di finestre di lunghezza pari a 250 ms e incremento di 125 ms.

Verranno di seguito riportate le matrici di confusione (definite anche matrici di classificazione) relative alle segmentazioni migliore e peggiore. Le righe della matrice rappresentano le classi stimate, mentre le colonne rappresentano le classi esatte. Ogni matrice riporta, lungo la diagonale, la frequenza di esecuzione di una stima accurata da parte del sistema di classificazione; mentre, per le restanti celle, restituisce la percentuale con cui 2 classi vengono confuse.

a. *Segmentazione migliore*: lunghezza finestra pari a 500 ms, incremento pari a 62 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 24):

		Classe esatta			
		R	Fl 90°	I -30°	Ab 90°
Classe Predetta	R	99,33 %	0,24 %	4,82 %	0,00%
	Fl 90°	0,59 %	99,14 %	0,00%	0,00%
	I -30°	0,00 %	0,00 %	94,88%	0,00%
	Ab 90°	0,08 %	0,62 %	0,30%	100,00%

Tabella 24: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 4 classi

(R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione).

Si può osservare come la classe maggiormente confusa sia relativa all'iperestensione a -30° , che presenta infatti un'accuratezza della stima pari al 94.88%, a causa della sua confusione con la classe di rest per il 4.82% delle volte. Per le restanti classi, si ha un'accuratezza della stima superiore al 99%, raggiungendo il 100% per la classe di abduzione a 90° .

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 25):

		Classe esatta				
		R	Fl 90°	I -30°	Ab 90°	El 90° diag
Classe predetta	R	99,24%	0,08%	7,42%	0,00%	0,08%
	Fl 90°	0,67%	84,26%	0,00%	0,00%	5,60%
	I -30°	0,00%	0,00%	92,20%	0,00%	0,00%
	Ab 90°	0,08%	0,00%	0,30%	91,44%	5,51%
	El 90° diag	0,00%	15,66%	0,07%	8,56%	88,80%

Tabella 25: Matrice di confusione relativa alla segmentazione $L=500$ ms, $I=62$ ms nel caso di 5 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono la flessione a 90° e l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima che raggiunge, rispettivamente, 84.26% e 88.80%. Si osserva, infatti, che la classe di flessione a 90° viene confusa per il 15.66% delle volte con la classe di elevazione a 90° nel piano diagonale; mentre, la classe di elevazione a 90° nel piano diagonale viene classificata erroneamente come flessione a 90° (5.60% delle volte) e come abduzione a 90° (5.51% delle volte).

La classe con migliore accuratezza di stima risulta essere il rest, con un valore pari a 99.24%.

Le restanti classi hanno un'accuratezza del 92.20% per l'iperestensione a -30° , a causa della sua confusione con il rest nel 7.42% dei casi, e del 91.44% per l'abduzione a 90° , a causa della sua confusione con l'elevazione a 90° nel piano diagonale nel 8.56% dei casi.

Si può, quindi, evidenziare come il *mismatch* sia dovuto all'aggiunta della classe relativa all'elevazione a 90° nel piano diagonale. Ciò si può attribuire al fatto che tale movimento è una combinazione dei movimenti di abduzione e flessione.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 26):

		Classe esatta								
		R	Fl 45°	Fl 90°	Fl 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	95,87%	1,89%	0,08%	0,00%	3,71%	0,25%	0,00%	0,47%	0,00%
	Fl 45°	2,87%	75,40%	4,17%	0,08%	0,00%	0,00%	0,00%	5,61%	1,44%
	Fl 90°	0,00%	5,73%	66,09%	27,26%	0,00%	0,00%	0,00%	1,03%	2,71%
	Fl 110°	0,00%	0,00%	18,17%	63,02%	0,00%	0,00%	0,24%	0,32%	4,92%
	I -30°	0,00%	0,00%	0,00%	0,00%	85,82%	0,00%	0,00%	0,00%	0,00%
	Ab 45°	0,00%	0,00%	0,16%	0,08%	6,68%	84,97%	0,24%	11,37%	1,02%
	Ab 90°	0,00%	0,00%	0,00%	0,08%	0,30%	2,65%	89,90%	0,00%	4,50%
	El 45° diag	1,18%	16,69%	0,94%	0,99%	3,49%	11,24%	0,00%	80,17%	1,70%
	El 90° diag	0,08%	0,29%	10,39%	8,50%	0,00%	0,88%	9,61%	1,03%	83,72%

Tabella 26: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 9 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono la flessione a 90° e la flessione a 110°, con un'accuratezza della stima che raggiunge, rispettivamente, 66.09% e 63.02%. Si osserva, infatti, che la classe di flessione a 90° viene confusa per il 18.17% delle volte con la classe di flessione a 110°, per il 10.39% delle volte con l'elevazione a 90° nel piano diagonale e per il 4.17% delle volte con la flessione a 45°; mentre, la classe di flessione a 110° viene classificata erroneamente come flessione a 90° (27.26% delle volte) e come elevazione a 90° nel piano diagonale (8.50% delle volte).

La classe con migliore accuratezza di stima risulta essere il rest, con un valore pari a 95.87%.

Si osserva inoltre che:

- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (16.69% delle volte), come flessione a 90° (5.73% delle volte).
- La classe di ipertensione a -30° viene confusa con l'abduzione a 45° (6.68% delle volte), con il rest (3.71% delle volte) e con l'elevazione a 45° nel piano diagonale (3.49% delle volte).
- La classe di abduzione a 45° viene confusa con l'elevazione a 45° nel piano diagonale (11.24% delle volte) e con l'abduzione a 90° (2.65% delle volte).
- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (9.61% delle volte).
- La classe di elevazione a 45° nel piano diagonale viene confusa con l'abduzione a 45° (11.37% delle volte) e con la flessione a 45° (5.60% dei casi).
- La classe di elevazione a 90° nel piano diagonale viene confusa con la flessione a 110° (4.91% delle volte), con l'abduzione a 90° (4.50% delle volte) e con la flessione a 90° (2.71% dei casi).

b. *Segmentazione peggiore*: lunghezza finestra pari a 250 ms, incremento pari a 250 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 27):

		Classe esatta			
		R	FI 90°	I -30°	Ab 90°
Classe predetta	R	97,47%	0,00%	4,11%	0,26%
	FI 90°	2,53%	96,72%	0,27%	0,00%
	I -30°	0,00%	0,00%	95,34%	0,00%
	Ab 90°	0,00%	3,28%	0,27%	99,74%

Tabella 27: Matrice di confusione relativa alla segmentazione L=250 ms, I=250 ms nel caso di 4 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione)

Si può osservare come la classe maggiormente confusa sia ancora relativa all'iperestensione a -30° , che presenta infatti un'accuratezza della stima pari al 95.34%, a causa della sua confusione con la classe di rest per il 4.11% delle volte. Per le restanti classi, si nota che solo una classe delle restanti è superiore al 99% (abduzione a 90°) e non viene mai raggiunto il 100% di accuratezza.

Nello specifico, la flessione a 90° raggiunge il 96.72% di accuratezza, a causa della confusione con la classe di abduzione a 90° il 3.28% delle volte; mentre il rest raggiunge un'accuratezza del 97.47% a causa della sua confusione con la flessione a 90° il 2.53% delle volte.

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 28):

		Classe esatta				
		R	FI 90°	I -30°	Ab 90°	El 90° diag
Classe predetta	R	97,19%	0,00%	6,58%	0,26%	0,57%
	FI 90°	1,97%	78,96%	0,00%	0,00%	10,51%
	I -30°	0,00%	0,00%	92,33%	0,00%	0,00%
	Ab 90°	0,28%	0,00%	0,55%	87,96%	7,67%
	El 90° diag	0,56%	21,04%	0,55%	11,78%	81,25%

Tabella 28: Matrice di confusione relativa alla segmentazione L=250 ms, I=250 ms nel caso di 5 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale)

Si evidenzia che le classi maggiormente confuse sono ancora la flessione a 90° e l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima che raggiunge, rispettivamente, 78.96% e 81.25%. Si osserva, infatti, che la classe di flessione a 90° viene confusa per il 21.04% delle volte con la classe di elevazione a 90° nel piano diagonale; mentre, la classe di elevazione a 90° viene classificata erroneamente come flessione a 90° (10.51% delle volte) e come abduzione a 90° (7.67% delle volte).

La classe con migliore accuratezza di stima risulta essere nuovamente il rest, con un valore pari a 97.19%.

Le restanti classi hanno un'accuratezza del 92.32% per l'iperstensione a -30° , a causa della sua confusione con il rest nel 6.57% dei casi, e del 87.96% per l'abduzione a 90° , a causa della sua confusione con l'elevazione a 90° nel piano diagonale nel 11.78% dei casi.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 29):

		Classe esatta								
		R	FI 45°	FI 90°	FI 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	94,38%	3,47%	0,00%	0,00%	5,75%	0,69%	0,00%	1,17%	0,00%
	FI 45°	4,49%	69,98%	8,20%	0,00%	0,00%	0,00%	0,00%	5,83%	4,83%
	FI 90°	0,00%	8,44%	54,92%	29,43%	0,00%	0,00%	0,00%	0,87%	3,98%
	FI 110°	0,56%	0,00%	22,13%	58,58%	0,00%	0,00%	0,26%	0,29%	6,25%
	I -30°	0,00%	0,00%	0,00%	0,00%	84,11%	0,00%	0,00%	0,00%	0,00%
	Ab 45°	0,00%	0,00%	0,00%	0,00%	6,03%	79,21%	2,09%	13,41%	0,85%
	Ab 90°	0,00%	0,00%	0,00%	0,00%	0,27%	4,39%	86,13%	0,00%	6,82%
	El 45° diag	0,56%	17,87%	1,37%	0,82%	3,56%	14,55%	0,00%	76,97%	4,26%
	El 90° diag	0,00%	0,25%	13,39%	11,17%	0,27%	1,15%	11,52%	1,46%	73,01%

Tabella 29: Matrice di confusione relativa alla segmentazione $L=250$ ms, $I=250$ ms nel caso di 9 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono ancora la flessione a 90° e la flessione a 110° , con un'accuratezza della stima che raggiunge, rispettivamente, 54.92% e 58.58%. Si osserva, infatti, che la classe di flessione a 90° viene confusa per il 22.13% delle volte con la classe di flessione a 110° , per il 13.38% delle volte con l'elevazione a 90° nel piano diagonale e per il 8.20% delle volte con la flessione a 45° ; mentre, la classe di flessione a 110° viene classificata erroneamente come flessione a 90° (29.43% delle volte) e come elevazione a 90° nel piano diagonale (11.17% delle volte).

La classe con migliore accuratezza di stima risulta essere nuovamente il rest, con un valore pari a 94.38%.

Si osserva inoltre che:

- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (17.87% delle volte), come flessione a 90° (8.44% delle volte) e anche con il rest (3.47% delle volte).
- La classe di ipertensione a -30° viene confusa con l'abduzione a 45° (6.03% delle volte), con il rest (5.75% delle volte) e con l'elevazione a 45° nel piano diagonale (3.56% delle volte).
- La classe di abduzione a 45° viene confusa con l'elevazione a 45° nel piano diagonale (14.55% delle volte) e con l'abduzione a 90° (4.39% delle volte).
- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (11.52% delle volte) e abduzione a 45° (2.09% delle volte).
- La classe di elevazione a 45° nel piano diagonale viene confusa con l'abduzione a 45° (13.41% delle volte) e con la flessione a 45° (5.83% dei casi).
- La classe di elevazione a 90° nel piano diagonale viene confusa con l'abduzione a 90° (6.82% delle volte), con la flessione a 110° (6.25% delle volte), con la flessione a 45° (4.83% dei casi), con l'elevazione a 45° nel piano diagonale (4.26% dei casi), con la flessione a 90° (3.98% dei casi).

Si può evidenziare come, il passaggio dalla segmentazione migliore a quella peggiore non degrada meramente i valori generali di accuratezza, ma influenza anche la classe con cui si stima in modo erroneo la classe in analisi.

	Segmentazione migliore	Segmentazione peggiore
	Ab 90°	
R	0,00%	0,00%
Fl 45°	0,00%	0,00%
Fl 90°	0,00%	0,00%
Fl 110°	0,24%	0,26%
I -30°	0,00%	0,00%
Ab 45°	0,24%	2,09%
Ab 90°	89,90%	86,13%
El 45° diag	0,00%	0,00%
El 90° diag	9,61%	11,52%

Tabella 30: Matrice di confusione dell'abduzione a 90° per la segmentazione migliore e peggiore.

A titolo d'esempio, nel caso di 9 classi (Tabella 30), l'abduzione a 90° viene confusa, nella segmentazione migliore, per lo 0.24% dei casi sia con la flessione a 110°, che con l'abduzione a 45°. Nella segmentazione peggiore, si nota come, la percentuale relativa alla confusione con la flessione a 110° aumenta del solo 0.02%, mentre la confusione con l'abduzione a 45° aumenta del 1.85%.

7.2 Percorso di elaborazione 2

La Tabella 31 mostra l'errore percentuale di classificazione sui dati di Test al variare del tipo di segmentazione, per ciascuno dei 3 gruppi di classi considerati.




Tabella 31: Errore (%) di classificazione sui dati di Test, al variare della segmentazione, per 4 (blu), 5 (rosso) e 9 (verde) classi.

Per tutte le segmentazioni, si osserva un peggioramento dell'accuratezza di classificazione all'aumentare del numero di classi considerate.

Si può notare un'elevata influenza della tipologia di segmentazione sul risultato.

In particolare, i valori mostrano una miglior performance di classificazione media utilizzando finestre di lunghezza pari a 500 ms con un incremento tra finestre pari a 62 ms. Per tale segmentazione, si ha infatti un errore pari a 0.00% su 4 classi, 2.61% su 5 classi e 7.44% su 9 classi. Valutando i valori di errore per ciascun sottogruppo di classi, si evince che la segmentazione migliore varia. Per 4 classi, risulta indifferente l'incremento tra finestre, a patto di utilizzarle di lunghezza pari a 500 ms. Per 5 classi, la segmentazione

migliore è data dalla combinazione di lunghezza della finestra pari a 500 ms e incremento di 250 ms. Nel caso di 9 classi, invece, risultano essere migliori le finestre di 500 ms, con incremento di 62 ms.

La performance peggiore si riscontra adoperando finestre adiacenti di lunghezza pari a 250 ms, con errori per 4, 5 e 9 classi, rispettivamente pari a 0.20% e 4.51% e 13.19%.

Verranno di seguito riportate le matrici di confusione relative alle segmentazioni migliore media e peggiore.

a. *Segmentazione migliore*: lunghezza finestra pari a 500 ms, incremento pari a 62 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 32), da cui si può osservare come tutte le classi vengano correttamente classificate.

		Classe esatta			
		R	Fl 90°	I -30°	Ab 90°
Classe predetta	R	100%	0%	0%	0%
	Fl 90°	0%	100%	0%	0%
	I -30°	0%	0%	100%	0%
	Ab 90°	0%	0%	0%	100%

Tabella 32: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 4 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione)

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 33):

		Classe esatta				
		R	Fl 90°	I -30°	Ab 90°	El 90° diag
Classe predetta	R	100%	0%	0%	0%	0%
	Fl 90°	0%	96,05%	0%	0%	2,30%
	I -30°	0%	0%	100%	0%	0%
	Ab 90°	0%	0%	0%	97,19%	4,27%
	El 90° diag	0%	3,94%	0%	2,80%	93,42%

Tabella 33: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 5 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che la classe maggiormente confusa è l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima che raggiunge il 93.42%. Si osserva infatti che tale classe viene classificata erroneamente come abduzione a 90° (4.28% delle volte) e come flessione a 90° (2.30% delle volte).

Le classi con migliore accuratezza di stima risultano essere il rest e l'iperestensione a -30°, per i quali il valore di accuratezza è pari al 100%.

Le restanti classi hanno un'accuratezza del 96.05% per la flessione a 90°, a causa della sua confusione con l'elevazione a 90° nel piano diagonale nel 3.95% dei casi, e del 97.20% per l'abduzione a 90°, a causa della sua confusione con l'elevazione a 90° nel piano diagonale il 2.80% delle volte.

Si può, quindi, evidenziare come il *mismatch* sia dovuto all'aggiunta della classe relativa all'elevazione a 90° nel piano diagonale. Ciò si può attribuire al fatto che tale movimento è una combinazione dei movimenti di abduzione e flessione.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 34):

		Classe esatta								
		R	Fl 45°	Fl 90°	Fl 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	100%	0%	0%	0%	0%	0%	0%	0%	0%
	Fl 45°	0%	90,64%	0,23%	0%	0%	0%	0%	3,81%	0,24%
	Fl 90°	0%	0,14%	89,25%	14,44%	0%	0%	0%	0,15%	2,54%
	Fl 110°	0%	0%	7,74%	78,17%	0%	0%	0%	0%	1,89%
	I -30°	0%	0,56%	0%	0%	100%	0%	0%	0,15%	0%
	Ab 45°	0%	0%	0%	0%	0%	97,18%	0,08%	6,04%	0%
	Ab 90°	0%	0%	0%	0%	0%	0,78%	96,47%	0%	4,35%
	El 45° diag	0%	8,65%	0,15%	0,08%	0%	2,02%	0%	89,57%	0,49%
	El 90° diag	0%	0%	2,60%	7,30%	0%	0%	3,44%	0,23%	90,46%

Tabella 34: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 9 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che la classe maggiormente confusa è la flessione a 110° (con accuratezza pari a 78.17%, che viene stimata come flessione a 90° (per il 14.44% dei casi) ed elevazione a 90° nel piano diagonale (per il 7.30% delle volte).

Le classi con migliore accuratezza di stima risultano essere il rest e l'iperstensione a -30° con un valore pari a 100%.

Per le restanti classi, si possono fare le seguenti osservazioni:

- La classe di flessione a 90° viene confusa con la flessione a 110° (7.74% dei casi) e con l'elevazione a 90° nel piano diagonale (2.60% dei casi).
- La classe di elevazione a 45° nel piano diagonale viene confusa con l'abduzione a 45° (6.04% dei casi) e con la flessione a 45° (3.81% dei casi).
- La classe di elevazione a 90° nel piano diagonale viene confusa con l'abduzione a 90° (4.35% dei casi), con la flessione a 90° (2.54% dei casi) e con la flessione a 110° (1.89% dei casi).
- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (8.65% delle volte).
- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (3.44% delle volte).
- La classe di abduzione a 45° viene confusa con l'elevazione a 45° nel piano diagonale (2.02% delle volte).

b. **Segmentazione peggiore:** lunghezza finestra pari a 250 ms, incremento pari a 250 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 35):

		Classe esatta			
		R	Fl 90°	I -30°	Ab 90°
Classe predetta	R	100%	0%	0%	0%
	Fl 90°	0%	99,24%	0%	0%
	I -30°	0%	0%	100%	0%
	Ab 90°	0%	0,76%	0%	100%

Tabella 35: Matrice di confusione relativa alla segmentazione L=250 ms, I=250 ms nel caso di 4 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione).

Si può osservare come la classe maggiormente confusa sia la flessione a 90° con un'accuratezza di classificazione che raggiunge il 99.24%. Le restanti classi vengono, invece, correttamente stimate nella totalità dei casi.

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 36):

		Classe esatta				
		R	Fl 90°	I -30°	Ab 90°	El 90° diag
Classe predetta	R	99,73%	0%	0%	0%	0%
	Fl 90°	0%	90,58%	0%	0%	2,44%
	I -30°	0,26%	0%	100%	0%	0,30%
	Ab 90°	0%	0%	0%	94,97%	5,50%
	El 90° diag	0%	9,41%	0%	5,02%	91,74%

Tabella 36: Matrice di confusione relativa alla segmentazione L=250 ms, I=250 ms nel caso di 5 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale)

Si evidenzia che le classi maggiormente confuse sono ancora la flessione a 90° e l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima che raggiunge, rispettivamente, 90.58% e 91.74%. Si osserva, infatti, che la classe di flessione a 90° viene confusa per il 9.41% delle volte con la classe di elevazione a 90° nel piano diagonale; mentre, la classe di elevazione a 90° viene classificata erroneamente come abduzione a 90° (5.50% delle volte) e come flessione a 90° (2.44% delle volte).

Le classi con migliore accuratezza di stima risultano essere l'iperestensione a -30°, con un valore pari al 100% e il rest, con un valore pari al 99.73%.

La restante classe, ovvero l'abduzione a 90°, ha un'accuratezza del 94.97%, a causa della sua confusione con l'elevazione a 90° nel piano diagonale nel 5.02% dei casi.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 37):

		Classe esatta								
		R	FI 45°	FI 90°	FI 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	98,39%	0%	0%	0%	0%	0%	0%	0%	0%
	FI 45°	0%	85,53%	0,51%	0,28%	0%	0%	0%	6,43%	1,53%
	FI 90°	0%	0,76%	78,12%	18,31%	0%	0%	0%	0,80%	1,53%
	FI 110°	0%	0%	15,01%	70,99%	0%	0%	0,56%	0%	2,75%
	I -30°	0%	1,52%	0%	0%	100%	0%	0%	0,27%	0%
	Ab 45°	0%	0%	0%	0%	0%	90,89%	1,12%	13,67%	0%
	Ab 90°	0%	0%	0%	0%	0%	1,48%	91,62%	0%	6,73%
	El 45° diag	0%	11,93%	0%	0,28%	0%	7,14%	0%	78,02%	0,61%
	El 90° diag	0%	0,25%	6,36%	10,14%	0%	0,49%	6,70%	0,80%	86,85%

Tabella 37: Matrice di confusione relativa alla segmentazione L=250 ms, I=250 ms nel caso di 9 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono la flessione a 110°, l'elevazione a 45° nel piano diagonale e la flessione a 90° con un'accuratezza della stima che raggiunge, rispettivamente, 70.99% e 78.02% e 78.12%. Si osserva, infatti, che la classe di flessione a 110° viene confusa per il 18.31% delle volte con la classe di flessione a 90°, per il 10.14% delle volte con l'elevazione a 90° nel piano diagonale; mentre, la classe di elevazione a 45° nel piano diagonale viene classificata erroneamente come abduzione a 45° (13.67% delle volte) e come flessione a 45° (6.43% delle volte). Per quanto riguarda la flessione a 90°, essa viene confusa con la flessione a 110° (15.01% delle volte) e con l'elevazione a 90° nel piano diagonale (6.36% delle volte).

Le classi con migliore accuratezza di stima risultano essere nuovamente l'iperestensione a -30° con un'accuratezza del 100% e il rest con un valore pari a 98.39%.

Si osserva inoltre che:

- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (11.93% delle volte) e come iperestensione a -30° (1.52% delle volte).

- La classe di elevazione a 90° nel piano diagonale viene confusa con l'abduzione a 90° (6.73% delle volte), con la flessione a 110° (2.75% delle volte) e con la flessione a 90° e la flessione a 45° (entrambe 1.53% delle volte).
- La classe di abduzione a 45° viene confusa con l'elevazione a 45° nel piano diagonale (7.14% delle volte) e con l'abduzione a 90° (1.48% delle volte).
- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (6.70% delle volte) e abduzione a 45° (1.12% delle volte).

Si può evidenziare come, con questo metodo di elaborazione, si riescono a raggiungere dei valori di accuratezza di classificazione anche del 100%; nel caso specifico di 4 classi, questo percorso di analisi fornisce, con qualunque tipo di segmentazione (tra quelle considerate) un valore minimo di accuratezza pari al 99.24%.

In generale, l'errore di classificazione è notevolmente minore rispetto a quello ottenuto con il primo metodo di elaborazione.

Inoltre, sia la segmentazione migliore che la peggiore coincidono con quelle del primo metodo.

Considerando la segmentazione migliore (lunghezza finestra di 500 ms e incremento di 62 ms) per entrambi i percorsi, vengono di seguito riportati (Tabella 38) i valori di accuratezza del movimento meglio classificato e peggio classificato all'interno di quel sottogruppo di classi.

		Percorso			
		1		2	
		min	max	min	max
Numero classi	4	94.88%	100%	100%	100%
	5	84.26%	99.24%	93.42%	100%
	9	63.02%	95.87%	78.17%	100%

Tabella 38: Valori di accuratezza del movimento peggio classificato (min) e meglio classificato (max), per i primi 2 percorsi di elaborazione al variare del numero delle classi.

7.3 Percorso di elaborazione 3

La Tabella 39 mostra l'errore percentuale di classificazione sui dati di Test al variare del tipo di segmentazione, per ciascuno dei 3 gruppi di classi considerati.




Tabella 39: Errore (%) di classificazione sui dati di Test, al variare della segmentazione, per 4 (blu), 5 (rosso) e 9 (verde) classi.

Per tutte le segmentazioni, si osserva un peggioramento dell'accuratezza di classificazione all'aumentare del numero di classi considerate.

Si può notare come la tipologia di segmentazione vada ad influenzare il risultato.

In particolare, i valori mostrano una miglior performance di classificazione utilizzando finestre di lunghezza pari a 500 ms con un incremento tra finestre pari a 62 ms. Per tale segmentazione, si ha infatti un errore pari a 0.59% su 4 classi, 7.72% su 5 classi e 25.28% su 9 classi.

La performance peggiore media si riscontra adoperando finestre di lunghezza pari a 250 ms e con incremento di 62 ms. Un risultato di poco migliore si ottiene con l'utilizzo di finestre adiacenti di lunghezza pari a 250 ms.

Valutando i valori di errore per ciascun sottogruppo di classi, si evince che la segmentazione peggiore varia: per 4 classi, si raggiunge l'errore massimo di 1.80% con l'impiego di finestre di lunghezza pari a 250 ms e incremento di 125 ms; per 5 classi, l'errore massimo di 10.85% è raggiunto con l'utilizzo di finestra adiacenti di lunghezza

pari a 250 ms; per 9 classi, si ha l'errore massimo di 29.63% in corrispondenza di finestre di lunghezza di 250 ms, con un incremento di 62 ms.

Verranno di seguito riportate le matrici di confusione relative alle segmentazioni migliore e peggiore media.

a. *Segmentazione migliore*: lunghezza finestra pari a 500 ms, incremento pari a 62 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 40):

		Classe esatta			
		R	FI 90°	I -30°	Ab 90°
Classe predetta	R	100%	0%	0%	0%
	FI 90°	0%	99,04%	0%	0,07%
	I -30°	0%	0%	98,90%	0,15%
	Ab 90°	0%	0,95%	1,09%	99,76%

Tabella 40: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 4 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione).

Si può osservare come l'accuratezza di stima di tutte le classi è superiore al 98.90% (valore relativo all'iperestensione a -30°), raggiungendo il 100% per la classe di rest .

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 41):

		Classe esatta				
		R	FI 90°	I -30°	Ab 90°	El 90° diag
Classe predetta	R	100%	0%	0%	0	0
	FI 90°	0%	88,82%	0%	0	5,76%
	I -30°	0%	0%	98,54%	0,15%	0,41%
	Ab 90°	0%	0%	0,72%	92,48%	13,04%
	El 90° diag	0%	11,17%	0,72%	7,35%	80,76%

Tabella 41: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 5 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale)

Si evidenzia che la classe maggiormente confusa è l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima dell'80.77%. Si osserva infatti che tale classe viene classificata erroneamente come abduzione a 90° (13.04% delle volte) e come flessione a 90° (5.77% delle volte).

Le classi con migliore accuratezza di stima risultano essere il rest e l'iperestensione a -30°, per i quali il valore di accuratezza è pari, rispettivamente, al 100% e al 98.54%.

Le restanti classi hanno un'accuratezza del 92.49% per l'abduzione a 90°, a causa della sua confusione con l'elevazione a 90° nel piano diagonale nel 7.36% dei casi, e del 88.83% per la flessione a 90°, a causa della sua confusione con l'elevazione a 90° nel piano diagonale pari a 11.17% delle volte.

Si può, quindi, evidenziare come il *mismatch* sia dovuto all'aggiunta della classe relativa all'elevazione a 90° nel piano diagonale. Ciò si può attribuire al fatto che tale movimento è una combinazione dei movimenti di abduzione e flessione.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 42):

		Classe esatta								
		R	Fl 45°	Fl 90°	Fl 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	97,07%	0%	0%	0%	0%	0%	0%	0%	0%
	Fl 45°	0%	64,33%	14,36%	2,57%	0%	0%	0%	10%	5,43%
	Fl 90°	0%	10,47%	51,47%	26,16%	0%	0%	0%	0,56%	0,66%
	Fl 110°	0%	7,28%	28,01%	56,85%	0%	0%	0%	0,32%	7,77%
	I -30°	0%	0,35%	0%	0%	96,35%	3,64%	0%	0%	0,16%
	Ab 45°	2,92%	0%	0%	0%	1,96%	86,95%	5,80%	14,24%	0,83%
	Ab 90°	0%	0%	0%	0%	0,43%	4,63%	81,87%	0%	11,37%
	El 45° diag	0%	11,53%	0%	0,07%	0,65%	4,43%	2,71%	65,52%	3,92%
	El 90° diag	0%	6,01%	6,14%	14,33%	0,58%	0,33%	9,60%	9,36%	69,81%

Tabella 42: Matrice di confusione relativa alla segmentazione L=500 ms, I=62 ms nel caso di 9 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono: la flessione a 90° (con accuratezza pari a 51.48%), che viene stimata come flessione a 110° (per il 28.01% dei casi), la

flessione a 45° (per il 14.37% dei casi) e con l'elevazione a 90° nel piano diagonale (per il 6.15% delle volte); la flessione a 110° (con accuratezza pari a 56.85%), che viene stimata come flessione a 90° (per il 26.17% dei casi), con l'elevazione a 90° nel piano diagonale (per il 14.33% delle volte) e con la flessione a 45° (per il 2.57% dei casi).

Le classi con migliore accuratezza di stima risultano essere il rest e l'iperestensione a -30° con un valore pari, rispettivamente a 97.07% e 96.36%.

Per le restanti classi, si possono fare le seguenti osservazioni:

- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (11.54% delle volte), flessione a 90° (10.47% dei casi), flessione a 110° (7.29%) ed elevazione a 90° nel piano diagonale (6.02%).
- La classe di elevazione a 45° nel piano diagonale viene confusa con l'abduzione a 45° (14.24% dei casi), con la flessione a 45° (10.00% dei casi) e con l'elevazione a 90° nel piano diagonale (9.36% dei casi).
- La classe di elevazione a 90° nel piano diagonale viene confusa con l'abduzione a 90° (11.37% dei casi), con la flessione a 110° (7.78% dei casi), con la flessione a 45° (5.43% dei casi) e con l'elevazione a 45° nel piano diagonale (3.93% dei casi).
- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (9.60% delle volte), con l'abduzione a 45° (5.81% delle volte) ed elevazione a 45° nel piano diagonale (2.71% delle volte).
- La classe di abduzione a 45° viene confusa con l'abduzione a 90° (4.64% delle volte), con l'elevazione a 45° nel piano diagonale (4.44% delle volte) e iperestensione a -30° (3.64%).

b. **Segmentazione peggiore:** lunghezza finestra pari a 250 ms, incremento pari a 62 ms.

Nel caso in cui il numero di classi sia pari a 4, la matrice di confusione risultante è la seguente (Tabella 43):

		Classe esatta			
		R	Fl 90°	I -30°	Ab 90°
Classe predetta	R	99,92%	0%	0%	0%
	Fl 90°	0%	97,92%	0,06%	0,07%
	I -30°	0,07%	0%	96,09%	0,42%
	Ab 90°	0%	2,07%	3,84%	99,50%

Tabella 43: Matrice di confusione relativa alla segmentazione L=250 ms, I=62 ms nel caso di 4 classi

(R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione).

Si può osservare come l'accuratezza di stima peggiore sia relativa all'iperestensione a -30° , con un valore pari a 96.09%, dovuto al mismatch con l'abduzione a 90° del 3.84%. Il valore migliore si ha invece in corrispondenza della fase di rest ed è pari al 99.93%.

Nel caso in cui il numero di classi sia pari a 5, la matrice di confusione risultante è la seguente (Tabella 44):

		Classe esatta				
		R	Fl 90°	I -30°	Ab 90°	El 90° diag
Classe Predetta	R	99,85%	0%	0%	0%	0%
	Fl 90°	0%	82,68%	0%	0%	5,25%
	I -30°	0,07%	0%	95,96%	0,28%	0,15%
	Ab 90°	0,07%	0%	2,91%	89,50%	13,95%
	El 90° diag	0%	17,31%	1,12%	10,21%	80,64%

Tabella 44: Matrice di confusione relativa alla segmentazione L=250 ms, I=62 ms nel caso di 5 classi (R=Rest, Fl=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che la classe maggiormente confusa è l'elevazione a 90° nel piano diagonale, con un'accuratezza della stima dell'80.64%. Si osserva infatti che tale classe viene classificata erroneamente come abduzione a 90° (13.95% delle volte) e come flessione a 90° (5.25% delle volte).

La classi con migliore accuratezza di stima risulta essere il rest, per il quale il valore di accuratezza è pari a 99.85%.

Le restanti classi hanno un'accuratezza pari a: 82.68% per la flessione a 90° , a causa della sua confusione con l'elevazione a 90° nel piano diagonale (nel 17.31% dei casi); 89.50% per l'abduzione a 90° , a causa della sua confusione con l'elevazione a 90° nel piano diagonale (il 10.21% delle volte); 95.96% per l'iperestensione a -30° , a causa della sua confusione con l'abduzione a 90° (per il 2.91% dei casi) e con l'elevazione a 90° nel piano diagonale (l'1.12% delle volte).

Si può, quindi, evidenziare come il *mismatch* sia dovuto all'aggiunta della classe relativa all'elevazione a 90° nel piano diagonale. Ciò si può attribuire al fatto che tale movimento è una combinazione dei movimenti di abduzione e flessione.

Nel caso in cui il numero di classi sia pari a 9, la matrice di confusione risultante è la seguente (Tabella 45):

		Classe esatta								
		R	FI 45°	FI 90°	FI 110°	I -30°	Ab 45°	Ab 90°	El 45° diag	El 90° diag
Classe predetta	R	94,52%	0%	0%	0%	0%	0%	0%	0%	0%
	FI 45°	0%	58,82%	14,05%	3,36%	0%	0%	0%	10,30%	7,65%
	FI 90°	0%	11,83%	48,82%	26,66%	0%	0%	0%	0,70%	1,42%
	FI 110°	0%	8,95%	25,76%	52,21%	0%	0%	0%	0,42%	6,00%
	I -30°	0%	0%	0%	0%	91,12%	6,80%	0,35%	0%	0%
	Ab 45°	5,47%	0,06%	0%	0%	4,37%	81,43%	7,80%	15,14%	2,32%
	Ab 90°	0%	0%	0%	0%	2,11%	5,67%	76,45%	0%	10,95%
	El 45° diag	0%	13,00%	0,27%	0,14%	1,12%	4,89%	2,26%	62,41%	5,10%
	El 90° diag	0%	7,32%	11,08%	17,61%	1,25%	1,19%	13,12%	11,00%	66,54%

Tabella 45: Matrice di confusione relativa alla segmentazione L=250 ms, I=62 ms nel caso di 9 classi (R=Rest, FI=Flessione, I=Iperestensione, Ab=Abduzione, El diag=Elevazione nel piano diagonale).

Si evidenzia che le classi maggiormente confuse sono: la flessione a 90° (con accuratezza pari a 48.82%), che viene stimata come flessione a 110° (per il 25.76% dei casi), la flessione a 45° (per il 14.06% dei casi) e con l'elevazione a 90° nel piano diagonale (per il 11.08% delle volte); la flessione a 110° (con accuratezza pari a 52.21%), che viene stimata come flessione a 90° (per il 26.67% dei casi), con l'elevazione a 90° nel piano diagonale (per il 17.61% delle volte) e con la flessione a 45° (per il 3.37% dei casi).

La classe con migliore accuratezza di stima risulta essere il rest con un valore pari a 94.52%.

Per le restanti classi, si possono fare le seguenti osservazioni:

- La classe di flessione a 45° viene stimata erroneamente come elevazione a 45° nel piano diagonale (13.01% delle volte), flessione a 90° (11.83% dei casi), flessione a 110° (8.95%) ed elevazione a 90° nel piano diagonale (7.32%).
- La classe di elevazione a 45° nel piano diagonale viene confusa con l'abduzione a 45° (15.15% dei casi), con l'elevazione a 90° nel piano diagonale (11.01% dei casi) e con la flessione a 45° (10.31% dei casi).
- La classe di elevazione a 90° nel piano diagonale viene confusa con l'abduzione a 90° (10.95% dei casi), con la flessione a 45° (7.65% dei casi), con la flessione a

110° (6.00% dei casi) e con l'elevazione a 45° nel piano diagonale (5.10% dei casi).

- La classe di abduzione a 90° viene confusa con l'elevazione a 90° nel piano diagonale (13.12% delle volte), con l'abduzione a 45° (7.80% delle volte) ed elevazione a 45° nel piano diagonale (2.27% delle volte).
- La classe di abduzione a 45° viene confusa con l'iperestensione a -30° (6,81% delle volte), con l'abduzione a 90° (5,67% delle volte) e con l'elevazione a 45° nel piano diagonale (4.90% delle volte).

Questo percorso di elaborazione fornisce risultati notevolmente peggiori rispetto al secondo metodo trattato.

Considerando la segmentazione migliore (lunghezza della finestra pari a 500 ms e incremento pari a 62 ms), che coincide per tutti e 3 i metodi di elaborazione, si osserva come l'errore di classificazione sui dati di test è minimo in corrispondenza del percorso 2 per qualunque sottogruppo di classi; mentre, nel confronto tra i percorsi 1 e 3, si notano valori di errore migliori o peggiori a seconda del sottogruppo di classi considerate (Tabella 46).




Tabella 46: Errore di classificazione sui dati di test per la segmentazione migliore (L=500 ms; I=62 ms) per i 3 percorsi di elaborazione, al variare del numero di classi.

Vengono di seguito riportati (Tabella 47), per tutti i 3 metodi di analisi svolti, i valori di accuratezza del movimento meglio classificato e peggio classificato all'interno di quel sottogruppo di classi.

		Percorso					
		1		2		3	
		min	max	min	max	min	max
Numero classi	4	94.88%	100%	100%	100%	98.91%	100%
	5	84.26%	99.24%	93.42%	100%	80.77%	100%
	9	63.02%	95.87%	78.17%	100%	51.48%	97.07%

Tabella 47: Valori di accuratezza del movimento peggio classificato (min) e meglio classificato (max) per i 3 percorsi di elaborazione, al variare del numero delle classi.

Si nota come, nel caso di 4 classi, i valori di accuratezza dei movimenti peggio classificati diminuiscono dal percorso 2, al percorso 3, fino al percorso 1; mentre, per i movimenti meglio classificati, tali valori rimangono costanti a 100%.

Per il caso a 5 e 9 classi, l'andamento dei valori di accuratezza dei movimenti peggio classificati cambia, decrescendo dal percorso 2, al percorso 1, fino al percorso 3.

Infine, i valori di accuratezza dei movimenti meglio classificati, per il caso a 9 classi, diminuiscono dal percorso 2, al percorso 3, fino al percorso 1.

Nella Tabella 48, sono esposti i movimenti meglio classificati e peggio classificati per ciascuno dei 3 metodi di elaborazione, al variare del numero di classi considerate.

		Percorso					
		1		2		3	
		Movimenti peggio classificati	Movimenti meglio classificati	Movimenti peggio classificati	Movimenti meglio classificati	Movimenti peggio classificati	Movimenti meglio classificati
Numero classi	4	I -30°	Ab 90°	-	-	I -30°	R
	5	Fl 90° El 90°d	R	El 90° d	R I -30°	El 90° d	R I -30°
	9	Fl 90° Fl 110°	R	Fl 90° Fl 110°	R I -30°	Fl 90° Fl 110°	R I -30°

Tabella 48: Movimenti peggio e meglio classificati per i 3 percorsi di elaborazione, al variare del numero delle classi.

Si nota come, nella quasi totalità dei casi, il rest è il meglio classificato.

Per quanto riguarda il secondo e il terzo metodo di elaborazione, si può notare come anche l'iperestensione a -30° , nel caso di 5 e 9 classi, appartenga ai movimenti meglio classificati.

Inoltre, per tutti i 3 percorsi, i movimenti peggio classificati, nel caso di 9 classi, sono la flessione a 90° e la flessione a 110° , poiché vengono confusi tra loro; mentre, nel caso di 5 classi, è l'elevazione a 90° nel piano diagonale.

Infine, nel caso di 4 classi, escludendo il secondo percorso, che presenta per tutti i movimenti un'accuratezza pari al 100%, si può osservare come, nei restanti percorsi, il movimento peggio classificato è l'iperestensione a -30° , in quanto, probabilmente, l'allontanamento troppo lieve rispetto alla posizione di rest fa sì che l'iperestensione venga confusa con quest'ultima.

7.4 Valutazione numerosità canali

Dopo aver selezionato il secondo percorso di elaborazione e la segmentazione $L=500$ ms e $I=62$ ms come la combinazione migliore, in termini di accuratezza di classificazione, si è voluto indagare se, riducendo il numero di canali di acquisizione sEMG, ci fossero delle variazioni nelle performance di classificazione. A tale scopo, si sono calcolate media e deviazione standard (SD) dei valori di *Root Mean Square* (RMS) per ogni canale, prendendo in considerazione le osservazioni di tutti gli otto soggetti per un dato movimento, ottenendo i seguenti grafici, relativi a ciascuno degli otto canali.




Figura 80: Media e SD dei valori di RMS per il canale 1, al variare della classe di movimento.




Figura 81: Media e SD dei valori di RMS per il canale 2, al variare della classe di movimento.




Figura 82: Media e SD dei valori di RMS per il canale 3, al variare della classe di movimento.




Figura 83: Media e SD dei valori di RMS per il canale 4, al variare della classe di movimento.




Figura 84: Media e SD dei valori di RMS per il canale 5, al variare della classe di movimento.




Figura 85: Media e SD dei valori di RMS per il canale 6, al variare della classe di movimento.




Figura 86: Media e SD dei valori di RMS per il canale 7, al variare della classe di movimento.




Figura 87: Media e SD dei valori di RMS per il canale 8, al variare della classe di movimento.

Integrando l'informazione di tutti i canali, si ottiene il seguente grafico (Fig. 88), che riporta i valori medi di RMS al variare del canale per tutti i nove movimenti.




Figura 88: RMS media per ciascun canale, per ogni classe di movimento.

Si può quindi notare che per i canali 2 (muscolo Gran Pettorale Sternale) e 8 (muscolo Gran Dorsale), il valore medio di RMS vari in modo trascurabile al variare della classe di movimento. Eliminando quindi tali canali, e riapplicando la segmentazione e il metodo di

elaborazione risultati migliori dalle precedenti analisi, si sono ottenuti i valori di accuratezza della classificazione, riportati nel grafico sottostante (Fig. 89), a confronto con quelli ottenuti con 8 canali.




Figura 89: Accuratezza di classificazione (%) sui dati di test, al variare del numero di classi e di canali.

Si nota come, la riduzione del numero di canali da 8 a 6 produce un incremento dell'errore irrilevante su 4 classi, pari al 1.28% nel caso di 5 classi e pari al 4.25% nel caso di 9 classi. Nei primi due casi, si può dunque pensare di ridurre il numero di canali di acquisizione del segnale sEMG da 8 a 6 canali, opportunamente selezionati, senza incorrere in un peggioramento significativo delle performance. Mentre, in caso di 9 classi, tale riduzione provoca un eccessivo peggioramento delle performance di classificazione.

Capitolo 8

Conclusioni

L'obiettivo di questo elaborato era quello di sviluppare un sistema di classificazione del segnale mioelettrico di superficie che classificasse correttamente il movimento intenzionale del soggetto, a livello della spalla.

Ci si è quindi focalizzati sull'acquisizione, l'elaborazione e sulla progettazione e implementazione di un sistema di classificazione del segnale mioelettrico di superficie basato sulla *Pattern Recognition*, andando a ricercare la migliore tecnica di elaborazione del segnale sEMG, tra diversi metodi scelti da quelli che hanno presentato i migliori risultati in letteratura. Tale valutazione è stata effettuata in termini di accuratezza della discriminazione tra un dato set di classi di movimento, per la specifica applicazione.

Si è potuto osservare come la scelta della segmentazione incida sulla bontà della classificazione. In particolare, a prescindere dal metodo di elaborazione utilizzato, la segmentazione migliore, prendendo in considerazione diverse lunghezze della finestra (250 ms e 500 ms) e diversi valori di incremento tra finestre (62 ms, 125 ms e 250 ms), è risultata essere la combinazione data dalla finestra lunga 500 ms con l'incremento pari a 62 ms. Questa tipologia di segmentazione permette di avere un flusso decisionale ogni 62 ms, tempo massimo in cui il processore montato sulla protesi deve elaborare i segnali elettromiografici acquisiti da ciascuno degli otto canali e fornire in uscita i comandi alla protesi.

Inoltre, un confronto quantitativo, in termini di accuratezza della classificazione, tra tre diversi metodi di elaborazione del segnale, accomunati dalla stessa tecnica di *feature reduction* (*Principal Component Analysis*) e di classificazione (*Linear Discriminant Analysis*), ha mostrato come il metodo di *feature extraction* incida in modo significativo sulla bontà della discriminazione ottenuta. In particolare, tra i metodi analizzati, il migliore si basa sull'estrazione di un *feature vector* definito nel dominio del tempo, costituito da: *Sample Entropy* (SampEn), *Cepstral Coefficients* (CC) di ordine quattro, *Root Mean*

Square (RMS) e *Waveform Length* (WL). Tale *feature vector* permette di ottenere un'accuratezza della classificazione pari al 92.56% nel discriminare un movimento all'interno di un set di nove classi di movimenti separati, pari al 97.39% se il set è costituito da cinque classi e pari al 100% se la scelta è limitata a quattro classi.

Per quanto riguarda la diminuzione del numero di canali di acquisizione, si può pensare di ridurlo da 8 a 6 canali, opportunamente selezionati, senza incorrere in un peggioramento significativo delle performance, nel caso in cui si tratti un problema di discriminazione tra 4 o al massimo 5 classi. Mentre, in caso di 9 classi, tale riduzione provoca un eccessivo peggioramento delle performance di classificazione e non è quindi consigliabile.

Tali risultati appaiono essere molto promettenti e si può quindi pensare di applicare questo protocollo di acquisizione e di elaborazione a protesi fisiche su soggetti amputati.

Si può quindi affermare che, seppur l'intero progetto non sia ancora arrivato al suo completamento, i progressi introdotti da questo elaborato hanno permesso di avvicinarsi in maniera significativa alla risoluzione di un problema che, allo stato dell'arte attuale, figura ancora irrisolto.

Per quanto riguarda gli sviluppi futuri di questo lavoro, si può pensare, in primo luogo, di integrare in maniera effettiva, il sistema di visione con il sistema di controllo mioelettrico e di testare tale sistema su una protesi fisica. Inoltre, si potrebbe sviluppare un'elettronica di controllo integrabile nella protesi. Successivamente, sarebbe interessante effettuare una valutazione anche su movimenti combinati.

Bibliografia

1. **Rodano, Prof. R.** Dispense del corso: Metodi e strumenti per la valutazione funzionale. *L'arto superiore*.
2. **Konrad, P.** The ABC of EMG. *A Pratical Introduction to Kinesiological Electromyography*. 2005, Vol. 1.
3. **www.seniam.org**.
4. **J.M. Miguelez, M.D. Miguelez, R.D. Alley.** Amputations about the shoulder: prosthetic management. 2000, p. 263-273.
5. **A. Davalli, R. Sacchetti.** Protesi per arto superiore. 2009.
6. **C. Lake, R. Dodson.** Progressive Upper Limb Prosthetic. 2006, p. 49-72.
7. **S. Fletchall.** Returning upper-extremity amputees to work. *The O&P Edge*. 2005, Vol. 48, 28-33.
8. **M.Nader.** Otto Bock Manuale protesi - Protesi per arto superiore. *Schiele & Shon*. 1990.
9. **E.Biotto.** Le protesi di arto superiore. *Università cattolica del Sacro Cuore*. 2008-2009.
10. <http://www.myoelectricprosthetics.com/>.
11. **C.W. Martin.** Upper Limb Prostheses. *WorkSafe BC Evidence-Based Practice Group*. February 2011.
12. <http://www.chalmers.se/en/news/Pages/World-premiere-of-muscle-and-nerve-controlled-arm-prosthesis.aspx>.
13. www.upperlimbprosthesis.info/BodyPoweredProsthesis (CONTROLLA!!).
14. **Valerio, F.** Tesi di Laurea Magistrale: Sistema di controllo per una protesi di arto superiore. *V Facoltà di Ingegneria, Politecnico di Milano*. 2010-2011.
15. **P.Gruppioni.** A New active Shoulder Prosthesis: From The Design To The First Clinical Application. 2008.

16. **J.Evans.** United States Patent Application Publication US2011/0257765 A1.
17. http://www.wpi.edu/Pubs/E-project/Available/E-project-031010-112312/unrestricted/HRRIQP_Final.pdf.
18. <http://www.jhuapl.edu/prosthetics/scientists/mpl.asp>.
19. **G.Li, Y. Yu, Y.Geng.** Electromiography Pattern-Recognition-Based Control of Powered Multifunctional Upper-Limb Prostheses. *Advances in Applied Electromyography book edited by Joseph Mizrahi.* 2011 .
20. **K. Englehart, B. Hudgins, P. Parker.** A wavelet-based continuous classification scheme for multifunction myoelectric control. 2001, p. 302-310.
21. **E.A Clancy, E.L Morin, R Merletti.** Sampling, noise-reduction and amplitude estimation issues in surface electromyography. *Journal of Electromyography and Kinesiology.* 2002, Vol. 12, p. 1–16.
22. **R.F. Weir, A.B. Ajiboye.** A heuristic fuzzy logic approach to EMG pattern recognition for multifunctional prosthesis control. *IEEE Trans. Neural Syst. Rehabil. Eng.* 2005, Vol. 13, p. 280 -291.
23. **F. Sebelius, L. Eriksson , H. Holmberg , A. Levinsson , G. Lundborg , N. Danielsen , J. Schouenborg , C. Balkenius , T. Laurell and L. Montelius.** Classification of motor commands using a modified self-organising feature map. *Med. Eng. Phys.* 2005, Vol. 27.
24. **L. J. Hargrove, K. Englehart and B. Hudgins.** A comparison of surface and intramuscular myoelectric signal classification. *IEEE Trans. Biomed. Eng.* 2007, Vol. 54, p. 847 -853.
25. **Gl. Li, A.E.Schultz, T.A. Kuiken.** Quantifying Pattern Recognition Based Myoelectric Control of Multifunctional Transradial Prostheses. *IEEE Transaction on Neural Systems and Rehabilitation Engineering.* 2010.
26. **K. Englehart, B. Hudgins.** A robust, real time control scheme for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.* 2003, Vol. 50, 7, p. 848-854.

27. **D. Farina, R. Merletti.** Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions. *Journal of Electromyography and Kinesiology*. 2000, Vol. 10, 5, p. 337–349.
28. **L. H. Smith, L. Hargrove , B. A. Lock and T. Kuiken.** Determining the optimal window length for pattern recognition-based myoelectric control: Balancing the competing effects of classification error and controller delay. *IEEE Trans. Neural Syst. Rehabil.Eng.* 2010, Vol. 19, 2.
29. **A. Phinyomark, A. Nuidod, P. Phukpattaranont, C. Limsakul.** EMG feature evaluation for improving myoelectric pattern recognition robustness. 2013.
30. **B. Hudgins, P. Parker, R. Scott.** A new strategy for multifunction myoelectric control. *IEEE Trans. Biomed. Eng.* 1993, Vol. 40, p. 82-94.
31. **Moradi, R. Boostani and M. H.** Evaluation of the forearm EMG signal features for the control of a prosthetic hand. *Physiol. Meas.* 2003, Vol. 24, p. 309 -319.
32. **M. Zardoshti-Kermani, B. C. Wheeler, K. Badie, and R. M. Hashemi.** EMG feature evaluation for movement control of upper extremity prostheses. *IEEE Trans. Rehab. Eng.* 1995, Vol. 3, p. 324 -333 .
33. **A. Phinyomark, C.Limsakul, P. Phukpattaranont.** A Novel Feature Extraction for Robust EMG Pattern Recognition. *Journal of Computing.* 2009a, p. 71-80.
34. **M. A. Oskoei and H. Hu.** Support vector machine-based classification scheme for myoelectric control applied to upper limb. *IEEE Transactions on Biomedical Engineering.* 2008, Vol. vol. 55, no. 8, p. pp. 1956-1965.
35. **Lei, M., Wang, Z.Z., Feng, Z.J.** Detecting nonlinearity of action surface EMG signal. *Physics Letters A.* (2001), p. 297-303.
36. **A.Phinyomark, C. Limsakul, P. Phukpattaranont.** EMG feature extraction for tolerance of 50 Hz interference. *Proceedings of 4th PSU-UNS International Conference on Engineering Technologies.* 2009b, p. 289–293.

37. **A. Phinyomark, A. Nuidod, P. Phukpattaranont, C. Limsakul,** Feature reduction and selection for EMG signal classification. *Expert Sysms and Applications*. 2012c, p. 7020-7431.
38. **C. Du, H. Lin, L. Shyu,** Tainsong Portable hand motion classifier for multi-channel surface electromyography recognition using grey relational analysis. *Expert Systems with Applications*. 2010, p. 4283–4291.
39. **A. Phinyomark, A. Nuidod, P. Phukpattaranont, C. Limsakul.** Feature extraction and reduction of wavelet transform coefficients for EMG pattern classification. *Electronics and Electrical Engineering*. 2012b, p. 27-32.
40. **H. Hu, M.A. Oskoei.** Myoelectric control systems-a survey. *Biomed. Signal Process. Control*. 2007, Vol. 2, p. 275 -294.
41. **K. Englehart, B. Hudgins, P. Parker, M. Stevenson.** Classification of the myoelectric signal using time-frequency based representation. *Med. Eng. Phys.* 1999, Vol. 21, p. 431-438.
42. **R.R. Coifman, M.V. Wickerhauser.** Entropy-Based Algorithms for Best Basis Selection. *IEEE Trans. Information Theory*. 1992, Vol. 38, 2, p. 713 -718.
43. **R. Coifman, N. Saito.** On local orthonormal bases for classification and regression. *Proc. ICASSP*. 1995, Vol. 3, p. 1529 -1532.
44. **X. Hu, Z. Wang, X. Ren.** (2005) Classification of surface EMG signal using relative wavelet packet energy. *Comput Meth Prog Bio*. 2005, Vol. 79, p. 189–195.
45. **G. Wang, Z. Wang, W. Chen, J. Zhuang.** Classification of surface EMG signals using optimal wavelet packet method based on Davies-Bouldin criterion. *Medical and Biological Engineering and Computing*. Vol. 44, p. 865-862.
46. **M.S. Hussain, M.B.I. Reaz, F. Mohd-Yasin, M.I. Ibrahimy.** Electromyography signal analysis using wavelet transform and higher order statistics to determine muscle contraction. *Expert Systems*. 2009, Vol. 26, p. 35–48.

47. **A. Phinyomark., C. Limsakul, P. Phukpattaranont.** Application of wavelet analysis in EMG feature extraction for pattern classification. *Meas. Sci. Rev.* 2011, Vol. 11, 2, p. 45-52.
48. **C. Buranachai, P. Thavarungkul, P. Kanatharana, I.V. Meglinski.** Application of Wavelet Analysis in Optical Coherence Tomography for Obscured Pattern Recognition. *Laser Physics Letter.* 2009, Vol. 6, 12, p. 892-895.
49. **N. Saito, R.R. Coifman.** Local Discriminant Bases and their application. *Journal of Mathematical Imaging and Vision.* 1995, Vol. 5, 4, p. 337-358.
50. **Englehart, K.** Signal Representation for Classification of the Transient Myoelectric Signal. *Ph.D. dissertation, Univ. New Brunswick, Fredericton, NB, Canada.* 1998.
51. **S.L.Jr Marple.** Digital spectral analysis with applications. 1987.
52. **I. Daubechies.** Ten lecture on wavelets. 1992. SIAM.
53. **A. J. Jain, R. P. W. Duin and J. Mao.** Statistical pattern recognition: A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence.* 2000, Vol. 22, 1, p. 4 -37.
54. **J.B. Kruskal.** Multidimensional scaling by optimizing goodness of fit to a nonmetric hypothesis. *Psychometrika.* Vol. 29, 1.
55. **T. Kohonen.** Generalizations of the self-organizing map. *International Joint Conference on Neural Networks.* 1993, Vol. 1, p. 457 - 462.
56. **A.D.C. Chan, G.C. Green.** Myoelectric control development toolbox. *30th Conf. Can. Med. Biol. Eng. Soc.* 2007.
57. **J.U. Chu, I. Moon, M.S. Mu.** A real-time EMG pattern recognition system based on linear-nonlinear feature projection for a multifunction myoelectric hand. *IEEE Trans Biomed Eng.* 2006, Vol. 53, p. 2232 -2239 .
58. **J. Ye, T. Li , T. Xiong , R. Janardan.** Using Uncorrelated Discriminant Analysis for Tissue Classification with Gene Expression Data. *IEEE/ACM Transactions on Computational Biology and Bioinformatics (TCBB).* 2004, Vol. 1, 4, p. 181-190.

59. **K. Fukunaga.** Introduction to Statistical Pattern Recognition, 2nd Edition. 1990.
60. **H. Golub, Charles F. van Van Loan.** Matrix Computations. *Johns Hopkins Studies in Mathematical Sciences.* 1996.
61. **J. Ye.** Multicriteria fuzzy decision-making method based on a novel accuracy function under interval-valued intuitionistic fuzzy environment. *Expert Systems with Applications.* 2009, Vol. 36, p. 6899–6902.
62. **D. Tkach, H. Huang, T. A. Kuiken.,** Study of stability of time-domain features for electromyographic pattern recognition. *J Neuroeng Rehabil.* 2010, p. 7-21.
63. **M. Barbero, R. Merletti, A. Rainoldi.** *Atlas of muscle innervation zones.* s.l. : Springer-Verlag, 2012.
64. **P. Kauffmann, K. Englehart, M. Platzner.,** Fluctuating EMG signals: investigating long-term effects of pattern matching algorithms. *Proceedings of 32nd annual international conference of the IEEE engineering in medicine and biology society.* 2010.
65. **A.J Young, L.J. Hargrove and T.A. Kuiken.** The effects of electrode size and orientation on the sensitivity of myoelectric pattern recognition systems to electrode shift. *IEEE Trans. Biomed. Eng.* 2011, p. pp.2537 -2544.
66. **A.J. Young, L.J. Hargrove, T.A. Kuiken.** "Improving Myoelectric Pattern Recognition Robustness to Electrode Shift by Changing Interelectrode Distance and Electrode Configuration", ,. *Biomedical Engineering, IEEE Transactions on.* p. On page(s): 645 - 652 Volum.
67. **J. Chu, I. Moon, S. Kim, M. Mun.** Control of multifunction myoelectric hand using a real-time EMG pattern recognition. *IEEE/RSJ International Conference on Intelligent Robots and Systems.* 2005, p. 3957-3962.

Appendice

```
function [angoloelevazione]=AngoloElevazione(tracks)

% Input:
% - tracks = matrice (numero frame)x(numero marker x 3). La riga i-esima mi dà le
%           coordinate 3D di tutti i marker, per il frame i-esimo.
% Output:
% - angoloelevazione = vettore di lunghezza pari al numero di frame, contenente i
%           valori dell'angolo di elevazione, in gradi.

labelSADX=6;
labelSPALLADX=2;
labelGOMITO=7;

SADX=tracks(:, [3*labelSADX-2:3*labelSADX]);
% Matrice Nframesx3. La riga i-esima mi dà le coordinate del marker SADX nel
frame
% i-esimo.
SADX=[inpaint_nans(SADX(:,1)),inpaint_nans(SADX(:,2)),inpaint_nans(SADX(:,3))];
% Sostituisco NaNs per i frame in cui il marker non è visibile.

SPALLADX=tracks(:, [3*labelSPALLADX-2:3*labelSPALLADX]);
% Matrice Nframesx3. La riga i-esima mi dà le coordinate del marker SPALLADX nel
% frame i-esimo.
SPALLADX=[inpaint_nans(SPALLADX(:,1)),inpaint_nans(SPALLADX(:,2)),inpaint_nans(SP
ALLADX(:,3))];
% Sostituisco NaNs per i frame in cui il marker non è visibile.

GOMITO=tracks(:, [3*labelGOMITO-2:3*labelGOMITO]);
% Matrice Nframesx3. La riga i-esima mi dà le coordinate del marker GOMITO nel
frame % i-esimo.
GOMITO=[inpaint_nans(GOMITO(:,1)),inpaint_nans(GOMITO(:,2)),inpaint_nans(GOMITO(:,
3))];
% Sostituisco NaNs per i frame in cui il marker non è visibile.

angoloelevazione=[];
for i=1:size(tracks,1) % Per ogni frame, calcolo l'angolo alla spalla
v1=[GOMITO(i,1)-SPALLADX(i,1),GOMITO(i,2)-SPALLADX(i,2),GOMITO(i,3)-
SPALLADX(i,3)];
v2=[SADX(i,1)-SPALLADX(i,1),SADX(i,2)-SPALLADX(i,2),SADX(i,3)-SPALLADX(i,3)];
```

```

angoloelevazione(i)=acosd(dot(v1,v2)/(norm(v1)*norm(v2)));
% 'acosd' dà il valore in gradi, mentre 'dot' calcola il prodotto scalare.
end

function [CampIFSteady]=InizioFineSteadyContraz(angoloelevazione,NumMovimento,
th)
% Input:
% - angoloelevazione = vettore di lunghezza pari al numero di frame cinematografico,
%                     contenente i valori dell'angolo di elevazione, in gradi;
% - NumMovimento = scalare, con 8 valori interi possibili (da 1 a 8);
% - th = scalare corrispondente a soglia da applicare su 'angoloelevazione'.
% Output:
% - CampIFSteady = matrice (numero fasi di contrazione Steady)x2, contenente, ad
%                 ogni riga i-esima, il numero di campione cinematografico a cui
%                 corrisponde l'inizio e la fine della fase Steady, per l'i-
%                 esima contrazione.

% Filtro 'angoloelevazione' con filtro passabasso alla frequenza di taglio
% normalizzata pari a 10/FNy, in modo da attenuare i picchi ad alta frequenza.
FNy=120/2;
[b,a] = butter(5,10/FNy,'low');
angoloelevazione=filtfilt(b,a,angoloelevazione);

if NumMovimento==1 || NumMovimento==2 || NumMovimento==3
    % NumMovimento==1: 0-45 sagittale
    % NumMovimento==2: 0-90 sagittale
    % NumMovimento==3: 0-110 sagittale

% Note per utilizzo dell' algoritmo semi-automatico:
% Verrà chiesto di cliccare sul grafico 2 volte, seguito da INVIO:
% 1°: scelgo th, in modo da considerare i due picchi minimi precedente
%     e seguente la fase Steady State.
% 2°: scelgo il campione da cui inizio a considerare il segnale.

% Dai grafici dell'angolo alla spalla, mi accorgo che lo steady ha inizio
% quando inizia il plateau successivo ai minimi dispari.
% Cerco quindi i minimi di interesse.

[ampiezzaMin1 PosMin1]=findpeaks(-angoloelevazione,'MINPEAKDISTANCE',230);
% findpeaks trova solo i massimi, quindi considero il segnale capovolto
ampiezzaMin1=-ampiezzaMin1;

figure,
title('Selezione minimi precedenti a inizio Steady state')

```

```

xlabel('tempo [s]')

plot([0:1/120:1/120*length(angoloelevazione)-1/120],angoloelevazione,'b');
hold on
plot(PosMin1/120-1/120,ampiezzaMin1,'*r')
hold on
legend('Angolo Elevazione','Minimi (1)', 'Location', 'BestOutside')
% Scelgo la soglia 'th' in modo da mantenere i minimi sottoglia
[x,th]=ginput;
i=find(ampiezzaMin1<th);
ampiezzaMin2=ampiezzaMin1(i);
PosMin2=PosMin1(i);

% Elimino minimi appartenenti ad ultimi campioni.
if PosMin2(end)>length(angoloelevazione)-60
    PosMin2(end)=[];
    ampiezzaMin2(end)=[];
end

plot(PosMin2/120-1/120,ampiezzaMin2,'*g')
hold on
legend('Angolo Elevazione','Minimi (1)', 'Minimi (2)', 'Location',
        'BestOutside')

% Chiedo istante da cui iniziare a considerare il segnale.
[X,Y]=ginput; % X è in secondi
X=X*120+1; % X è in termini di numero del campione cinematico (f=120 Hz)
i=find(PosMin2>X);
PosMin2=PosMin2(i);
ampiezzaMin2=ampiezzaMin2(i);

% Considero la derivata e valuto picchi. Considero i minimi dell'angolo
% spalla a cui corrisponde un picco nella derivata.
[ampDiff PosDiff]=findpeaks(abs(diff(angoloelevazione)), 'MINPEAKHEIGHT',0.1);

PosMin3=[];
for i=1: length(PosMin2)
    a=find(PosDiff>PosMin2(i)-115 & PosDiff<PosMin2(i)+115);
    if isempty(a)
    else
        PosMin3=[PosMin3 PosMin2(i)];
    end
end
ampiezzaMin3=angoloelevazione(PosMin3);

```

```

plot(PosMin3/120-1/120,ampiezzaMin3,'*m')
hold on
legend('Angolo Elevazione','Minimi (1)','Minimi (2)','Minimi (3)',
       'Location','BestOutside')

% Trovati i minimi corretti, si considerano solo i minimi dispari
PosMinPari=PosMin3(2:2:end);
PosMinDisp=PosMin3(1:2:end);
ampiezzaMinDisp=ampiezzaMin3(1:2:end);

plot(PosMinDisp/120-1/120,ampiezzaMinDisp,'ob')
legend('Angolo Elevazione','Minimi (1)','Minimi (2)', 'Minimi (3)','Minimi
       Dispari','Location','BestOutside')

% Cerco Inizio Steady State e Fine Steady State
CampISteady=[];
CampFSteady=[];
for i=1: length(PosMinDisp)
    if i<=length(PosMinPari)
        segmento=angoloelevazione(PosMinDisp(i): PosMinPari(i));
        [amp, loc]=findpeaks(segmento);
        massimo=max(amp);
        j=1;
        a=[];
        while isempty(a)
            if amp(j)>massimo-2
                a=loc(j)+PosMinDisp(i)-1;
                CampISteady(i)=a;
            else
                j=j+1;
            end
        end
        k=length(loc);
        b=[];
        while isempty(b)
            if amp(k)>massimo-2
                b=loc(k)+PosMinDisp(i)-1;
                CampFSteady(i)=b;
            else
                k=k-1;
            end
        end
    end
    hold on
    plot(CampISteady(i)/120-1/120,angoloelevazione(CampISteady(i)),'+r')

```

```

        hold on
        plot(CampFSteady(i)/120-1/120,angoloelevazione(CampFSteady(i)),'+g')
        hold on
    end
end
legend('Angolo Elevazione','Minimi (1)','Minimi (2)', 'Minimi (3)','Minimi
        Dispari','InizioSteady',' FineSteady','Location','BestOutside')
else
    % NumMovimento==4: Flesso-Estensione -30°
    % NumMovimento==5: Abd-Adduzione 45°
    % NumMovimento==6: Abd-Adduzione 90°
    % NumMovimento==7: Abd-Adduzione diagonale 45°
    % NumMovimento==8: Abd-Adduzione diagonale 90°
    [amp Pos]=findpeaks(angoloelevazione,'MINPEAKHEIGHT',th);
    a=diff([-600 Pos]);
    indice=find(a>300);
    CampISteady=Pos(indice);
    AmpInizioSteady=angoloelevazione(CampISteady);
    CampFSteady=[Pos(indice(2:end)-1) Pos(end)];
    CampFSteady=CampFSteady;
    AmpFineSteady=angoloelevazione(CampFSteady);
    figure,
    plot([0:1/120:1/120*length(angoloelevazione)-1/120],angoloelevazione,'b');
    hold on
    plot(CampISteady/120-1/120,AmpInizioSteady,'*m')
    hold on
    plot(CampFSteady/120-1/120,AmpFineSteady,'*k')
    xlabel('Tempo [s]')
    ylabel('Angolo Elevazione [°]')
    legend('Angolo
Elevazione','InizioSteady','FineSteady','Location','BestOutside')
end
CampIFSteady=[CampISteady;CampFSteady];
end

function [EMGsegm]= SignDetrendSegmen(EMGDATA, CampIFSteady, LunghezzaSegm,
IncrementoSegm)
% Input:
% - EMGDATA = matrice di dimensione (numero canali=8)x(numero campioni EMG);
% - CampIFSteady = matrice 2x(numero fasi steady), contenente:
%           1)nella 1°riga: campione cinematico di inizio fase steady;
%           2)nella seconda riga: campione cinematico di fine fase steady;
% - LunghezzaSegm = lunghezza del segmento in termini di ms (N.B: fsEMG=1000Hz->1

```



```

%             campione EMG ogni 1 ms);
% - IncrementoSegm: incremento tra un segmento ed il successivo in termini
%             di ms;
% Output:
% - EMGsegm = matrice 3D (numerocanali=8)x(lunghezza segmento)x(numero segmenti
%             individuati)

% Osservazioni: fsCinematica=120Hz, fsEMG=1000Hz.

InFineStEMG=round(((CampIFSteady-1)/120)*1000)+1);
for ch=1:8
    EMGDATA(ch,:)=detrend(EMGDATA(ch,:), 'constant');
end

j=1;
for i=1: size(InFineStEMG,2) % Per ogni fase di Steady,
    EMGsteady=EMGDATA(:, [InFineStEMG(1,i):InFineStEMG(2,i)]);
    % matrice (numero canali=8)x(numero campioni EMG fase steady 'i')
    k=1;
    while k+LunghezzaSegm<size(EMGsteady,2)
        EMGsegm(:,:,j)=EMGsteady(:, [k:k+LunghezzaSegm]);
        k=k+IncrementoSegm;
        j=j+1;
    end
end

function [Feature_SetA]=FeatureExtr1(fin_EMG, sogliaSSC)
%% Feature set A:
% TD Feature set di Hudgins (MAV, WL, ZC, SSC)
% Input:
% - fin_EMG = matrice (numero canali)x(numero campioni della finestra)
% - sogliaSSC = scalare
% Output:
% - Feature_SetA = matrice (numero canali)x (numero feature=4)

for i=1: size(fin_EMG,1) % Per ogni canale
    fin_esame=fin_EMG(i,:);

    % 1) MAV: Mean Absolute Value
    MAV(i)=(1/length(fin_EMG))*sum(abs(fin_esame));

    % 2) WL: Waveform Length
    WL(i)=sum(abs(diff(fin_esame)));

    % 3) ZC: Zero Crossing

```

```

% Ossia, il numero di volte che il segnale attraversa l'asse di ampiezza
% nulla
ZC_seg=0;
for m=1:length(fin_esame)-1
    if fin_esame(m+1)*fin_esame(m)<0
        ZC_seg=ZC_seg+1;
    end
end
ZC_seg(i)=ZC_seg;

% 4) SSC: Slope Sign Change
SSC=0;
for r=2:length(fin_esame)-1
    if (fin_esame(r)-fin_esame(r-1))*(fin_esame(r)-fin_esame(r+1))>=sogliaSSC
        SSC=SSC+1;
    end
end
SSC(i)=SSC;
end

MAV=MAV';           % vettore colonna (numero canali)x1
WL=WL';             % vettore colonna (numero canali)x1
ZC_seg= ZC_seg';    % vettore colonna (numero canali)x1
SSC=SSC';          % vettore colonna (numero canali)x1
Feature_SetA=[MAV, WL, ZC_seg, SSC];

function [Feature_SetB]=FeatureExtr2(fin_EMG)
%% Feature set B:
% TD Feature set di Phinyomark (SampEn, CC del 4° ordine, RMS, WL)
% Input:
% - fin_EMG = matrice (numero canali)x(numero campioni della finestra)
% Output:
% - Feature_SetB = matrice (numero canali)x(numero features=7)

for i=1: size(fin_EMG,1) % Per ogni canale
    fin_esame=fin_EMG(i,:);
    % 1) SampEn: Sample Entropy
    Samp=Samp_Entropy(fin_esame);
    % Samp=Samp_Entropy(segnale) scalare.
    SampEn(i)=Samp;

    % 2) CC: Cepstral coefficients
    modAR_4=ar(fin_esame, 4);
    AR4=-modAR_4.a(2:end);

```

```

CC1(i)=-AR4(1);
CC2(i)=-AR4(2)-(1-1/2)*AR4(2)*CC1(i);
CC3(i)=-AR4(3)-(1-1/3)*AR4(3)*CC2(i)-(1-2/3)*AR4(3)*CC1(i);
CC4(i)=-AR4(4)-(1-1/4)*AR4(4)*CC3(i)-(1-2/4)*AR4(4)*CC2(i)-(1-3/4)*AR4(4)
    *CC1(i);

% 3) RMS: Root Mean Squared
RMS(i)=sqrt((1/length(fin_esame))*sum(fin_esame.^2)); % RMS scalare

% 4) WL: Waveform Length
WL(i)=sum(abs(diff(fin_esame)));
end
SampEn=SampEn'; % vettore colonna (numero canali)x1
CC1=CC1'; % vettore colonna (numero canali)x1
CC2=CC2'; % vettore colonna (numero canali)x1
CC3=CC3'; % vettore colonna (numero canali)x1
CC4=CC4'; % vettore colonna (numero canali)x1
RMS=RMS'; % vettore colonna (numero canali)x1
WL=WL'; % vettore colonna (numero canali)x1

Feature_SetB=[SampEn, CC1, CC2, CC3, CC4, RMS, WL];

function SampEn=Samp_Entropy(segnale)
% Algoritmo tratto da articolo 'Detecting Ventricular Fibrillation by Fast
% Algorithm of Dynamic Sample Entropy' di Haiyan Li, 2009 (pg.1106)

N=length(segnale);
Phi=[];
% Parametri di r ed M tratti da Phinyomark (2013):
r=0.2*std(segnale); M=2;
for m=M:M+1
    X=zeros(N-m+1,m); % Inizializzo matrice X
    for i=1:(N-m+1)
        X(i,:)=segnale(i:i+m-1); % Ogni riga di X ha un vettore di dati lungo m
    end
    Phim=0;
    for i=1:(N-m+1)
        for j=i:(N-m+1) % Sfrutto simmetria D.
            mod=abs(X(i,:)-X(j,:));
            a=mod(1);
            if m==M
                if mod(2)>a
                    a=mod(2);
                end
            end
        end
    end
end

```

```

else
    if mod(2)>a
        a=mod(2);
    end
    if mod(3)>a
        a=mod(3);
    end
end
if a<r
    Phim=Phim+1;
    if i~=j
        Phim=Phim+1;
    end
end
end
end
Phi=[Phi ((1/(N-m+1))/(N-m))*Phim];
end
SampEn=-log(Phi(2)/Phi(1));

function [Feature_SetC]=FeatureExtr3(fin_EMG, sogliaMYOP, sogliaWAMP)
%% Feature set C:
% Per ciascuna finestra:
% - calcolo coefficienti di dettaglio del primo livello (cD1) tramite la
%   wavelet function db5;
% - ricostruisco segnale da cD1 (D1);
% - calcolo MYOP di D1.
%
% - calcolo coefficienti di dettaglio del primo livello (cD2) tramite la
%   wavelet function db7;
% - ricostruisco segnale da cD2 (D2);
% - calcolo ZC, WAMP, MAV di D2.
% Quindi, ad ogni finestra ho 4 features per canale [MYOP ZC WAMP MAV]

% Input:
% - fin_EMG = matrice (numero canali)x(numero campioni della finestra)
% - sogliaMYOP = (percentuale rispetto a massimo D1 di ciascun canale)tale da
%               evitare fluttuazioni a basso voltaggio o rumori di background
% - sogliaWAMP = scalare.
% Output:
% - Feature_SetC: matrice (numero canali)x(numero features=4) [MYOP ZC WAMP MAV]

for ch=1: size(fin_EMG,1) % Per ogni canale

```

```

fin_esame=fin_EMG(ch,:);

% Wavelet Decomposition a livello 1 con 'db5'
[C,L]=wavedec(fin_esame,1,'db5');
% C=[cA1, cD1]
% L=[lunghezza cA1, lunghezza cD1]
cD1=C(L(1)+1:end);

% Wavelet Reconstruction
D1=idwt([],cD1,'db5');
sogliaCh=sogliaMYOP*max(D1);

% MYOP di D1
WAMP=0;
for i=1:length(D1)
    if abs(D1(i))>=sogliaCh
        f=1;
    else
        f=0;
    end
    WAMP=WAMP+f;
end
MYOP=(1/length(D1))*WAMP;

% Wavelet Decomposition a livello 2 con 'db7'
[C,L]=wavedec(fin_esame,2,'db7');
% C=[cA2, cD2, cD1]
% L=[lunghezza cA2, lunghezza cD2, lunghezza cD1]
cD2=C(L(1)+1:L(1)+L(2));

% Wavelet Reconstruction
D2=idwt([],cD2,'db7');

% Calcolo ZC di D2
ZC=0;
for i=1:length(D2)-1
    if D2(i+1)*D2(i)<0
        ZC=ZC+1;
    end
end

% Calcolo WAMP di D2
WAMP=0;
for i=1:length(D2)-1
    if abs(D2(i)-D2(i+1))>=sogliaWAMP

```

```

        WAMP=WAMP+1;
    end
end

% Calcolo MAV di D2
MAV=(1/length(D2))*sum(abs(D2));

Feature_SetC(ch,:)= [MYOP ZC WAMP MAV];
end

function [TrainErr9Clas8Ch,TestErr9Clas8Ch, MatricePredNorm9Clas8Ch,
TrainErr4Clas8Ch,TestErr4Clas8Ch, MatricePredNorm4Clas8Ch, TrainErr5Clas8Ch,
TestErr5Clas8Ch, MatricePredNorm5Clas8Ch]=F1_PCA_LDAdet(path, nomefile)

load(fullfile(path,nomefile)); % Carico il file contenente i feature set di tutti
    % i soggetti e di tutte le classi.
Data=[]; % Matrice (numero Osservazioni totali)x(Numero Feature totali= Numero
    % canalix4 Feature)
Classe=[]; % Matrice (numero Osservazioni totali)x1: contenente valori 0 (Rest) e
    % da 1 a 8 (altri movimenti Steady)

for s=1:8 % Per ogni soggetto
    for m=1:8 % Per ogni movimento Steady
        file=eval(['Feature_SetA', num2str(s), num2str(m)]); % Considero il file
            % corrispondente al soggetto 's' e al movimento 'm'.
        numeroOss_s_m=size(file,3);
        for NumPiano=1: numeroOss_s_m % Prendo ogni "piano", (numero canali)x
            % (numero % Features=4)
            Oss= file(:, :, NumPiano); % e lo rendo un vettore riga, come sequenza
                % delle righe del piano.
            Data=[Data; reshape(Oss',1,[])]; % Riempio la matrice Data,
                % inserendo, ad ogni iterazione, una riga
                % relativa ad un'osservazione.
        end
        Classe=[Classe; m*ones(numeroOss_s_m,1)];
    end
end

file=eval(['Feature_SetA', num2str(s), '2R']); % Considero il file
    % corrispondente al soggetto e al movimento di Rest.
numeroOss_s_m=size(file,3);
for NumPiano=1: numeroOss_s_m
    Oss= file(:, :, NumPiano);
    Data=[Data; reshape(Oss',1,[])];
end
end

```

```

        Classe=[Classe; zeros(numeroOss_s_m,1)];
        Soggetto=[Soggetto; s*ones(numeroOss_s_m,1)];
end

% Divido la matrice Data in 2: TrainData e TestData;
% e la corrispondente matrice Classe: TrainClass e TestClass.

% Per la suddivisione, decido di mescolare i dati in modo random e poi
% considerare il primo 60% per generare il TrainData e l'ultimo 40% per
% creare il TestData.
NumOssTotali=size(Data,1);
IndRandom=randperm(NumOssTotali);

DataRandom=Data(IndRandom,:);
ClasseRandom=Classe(IndRandom);

NumOssTrain=round(0.6*NumOssTotali);

TrainData=DataRandom([1:NumOssTrain],:);
TrainClass=ClasseRandom(1:NumOssTrain);

TestData=DataRandom([NumOssTrain+1:end],:);
TestClass=ClasseRandom(NumOssTrain+1:end);

% Da qui in poi devo ripetere per
% -numero classi volute
% -numero canali voluti
% Quindi eliminando:
% - le colonne di TrainData e TestData corrispondenti ai canali non considerati,
% - le righe di TrainData, TestData, TrainClass, TestClass relative alle classi
% non volute

% Caso 1: numero classi=9 ; numero canali=8
% Caso 2: numero classi=4 (classe0:Riposo,classe2:FlessoEst90,classe4:FlessoEst
%       -30, classe6:AbdAdd90); numero canali=8
% Caso 3: numero classi=5 (classe0:Riposo,classe2:FlessoEst90,classe4:FlessoEst
%       -30, classe6:AbdAdd90, classe8: Diagonale90); numero canali=8

%% Caso 1: numero classi=9 ; numero canali=8
numClass=9;
%% Feature Reduction:
%1) Applico la PCA ai dati di training
[coeff,TrainDataPCA,latent]= princomp(TrainData);
% score: matrice (numero osservazioni di Training)x(numero componenti
%       principali,ovvero numero nuove features, che rimane pari al numero

```

```

%         feature originali)
% latent: vettore colonna lungo (numero componenti principali), contenente
%         gli autovalori della matrice di covarianza di TrainData.

VarSpiegata=(latent/sum(latent))*100; % vettore contenente la varianza spiegata
% da ciascuna componente principale
VarSpiegataCum=cumsum(VarSpiegata); % vettore contenente, ad ogni posizione 'i',
% la varianza spiegata dalle prime 'i' componenti principali

%2)Applico la matrice di coefficienti 'coeff' alla matrice dei dati di test.
% Per applicarla, bisogna
% a) sottrarre, ad ogni colonna della matrice TestData, la media della
% stessa colonna (ottenendo la matrice TestDataMenoMediaCol;
% b) moltiplicare TestDataMenoMediaCol e coeff.
MediaColonne=mean(TestData); % Vettore riga, contenente, ad ogni posizione, la
% media della colonna di TestData
MediaColonneMatr= repmat(MediaColonne,size(TestData,1),1); % Matrice con
% dimensione di TestData, avente ciascuna colonna
% contenente lo stesso valore, corrispondente alla
% media della colonna di TestData
TestDataMenoMediaCol=TestData-MediaColonneMatr; % Sottraggo media colonne
TestDataPCA=TestDataMenoMediaCol*coeff; % Ottengo (numero osservazioni)x(numero
% nuove feature)

%% Applico la funzione 'ldaclassify' ai dati ridotti con PCA
% Scelgo il massimo numero di componenti principali che mi permette di avere
% la pooled covariance matrix definita positiva, perchè altrimenti, la
% funzione 'classify' dà errore.
% Considero le prime 18 componenti principali, in quanto, per un numero
% superiore a 18, si osserva che la matrice di covarianza non è più definita
% positiva.

n=18; % Numero componenti principali
[TrainErr,TestErr,TrainPredict,TestPredict]=ldaclassify(TrainDataPCA(:, [1:n]),Tes
tDataPCA(:, [1:n]),TrainClass,TestClass);

% Per generare matrice di confusione relative ai dati di Test
MatricePred=zeros(numClass);
for oss=1:length(TestPredict)
    MatricePred(TestPredict(oss)+1,
TestClass(oss)+1)=MatricePred(TestPredict(oss)+1, TestClass(oss)+1)+1;
end
MatricePredNorm=( repmat(sum(MatricePred),numClass,1).\MatricePred)*100;
% MatricePredNorm è una matrice quadrata di dimensione pari al numero di

```



```

% classi (numClass), dove la posizione (i,j) è pari alla percentuale (tra
% le classificazioni della classe j-1) con cui il risultato della predizione
% mi dà la classe i-1, quando in realtà la classe corretta è la classe j-1.

MatricePredNorm9Clas8Ch=MatricePredNorm;
TrainErr9Clas8Ch=TrainErr;
TestErr9Clas8Ch=TestErr;

%% Caso 2: numero classi=4 (classe 0,2,4,6); numero canali=8
numClass=4;
% Elimino dai dati le classi non in analisi
PosizioniTrainClass=find(TrainClass==0|TrainClass==2|TrainClass==4|TrainClass==6)
TrainClassRid=TrainClass(PosizioniTrainClass);
TrainDataRid=TrainData(PosizioniTrainClass,:);

PosizioniTestClass=find(TestClass==0|TestClass==2|TestClass==4|TestClass==6);
TestClassRid=TestClass(PosizioniTestClass);
TestDataRid=TestData(PosizioniTestClass,:);

%% Feature Reduction:
%1) Applico la PCA ai dati di training
[coeff,TrainDataPCA,latent]= princomp(TrainDataRid);
MediaColonne=mean(TestDataRid);
MediaColonneMatr= repmat(MediaColonne,size(TestDataRid,1),1);
TestDataMenoMediaCol=TestDataRid-MediaColonneMatr;
TestDataPCA=TestDataMenoMediaCol*coeff;

n=18;
[TrainErr,TestErr,TrainPredict,TestPredict]=ldaclassify(TrainDataPCA(:,[1:n]),Test
tDataPCA(:,[1:n]),TrainClassRid,TestClassRid);
MatricePred=zeros(numClass);
for oss=1:length(TestPredict)
    MatricePred(TestPredict(oss)/2+1, TestClassRid(oss)/2+1)=MatricePred
    (TestPredict(oss)/2+1, TestClassRid(oss)/2+1)+1;
end
MatricePredNorm=(repmat(sum(MatricePred),numClass,1).\MatricePred)*100;
MatricePredNorm4Clas8Ch=MatricePredNorm;
TrainErr4Clas8Ch=TrainErr;
TestErr4Clas8Ch=TestErr;

%% Caso 3: numero classi=5 (classe 0,2,4,6,8); numero canali=8
numClass=5;
% Elimino dai dati le classi non in analisi
PosizioniTrainClass=find(TrainClass==0|TrainClass==2|TrainClass==4|TrainClass==6|

```

```

TrainClass==8);
TrainClassRid=TrainClass(PosizioniTrainClass);
TrainDataRid=TrainData(PosizioniTrainClass,:);

PosizioniTestClass=find(TestClass==0|TestClass==2|TestClass==4|TestClass==6|
TestClass==8);
TestClassRid=TestClass(PosizioniTestClass);
TestDataRid=TestData(PosizioniTestClass,:);

%% Feature Reduction:
%1) Applico la PCA ai dati di training
[coeff,TrainDataPCA,latent]= princomp(TrainDataRid);

MediaColonne=mean(TestDataRid);
MediaColonneMatr= repmat(MediaColonne, size(TestDataRid,1),1);
TestDataMenoMediaCol=TestDataRid-MediaColonneMatr;
TestDataPCA=TestDataMenoMediaCol*coeff;
%% Applico la funzione 'ldaclassify' ai dati ridotti con PCA
n=18;
[TrainErr,TestErr,TrainPredict,TestPredict]=ldaclassify(TrainDataPCA(:,[1:n]),
TestDataPCA(:,[1:n]),TrainClassRid,TestClassRid);
MatricePred=zeros(numClass);
for oss=1:length(TestPredict)
    MatricePred(TestPredict(oss)/2+1, TestClassRid(oss)/2+1)=
MatricePred(TestPredict(oss)/2+1, TestClassRid(oss)/2+1)+1;
end
MatricePredNorm=( repmat(sum(MatricePred), numClass,1) \MatricePred) *100;

MatricePredNorm5Clas8Ch=MatricePredNorm;
TrainErr5Clas8Ch=TrainErr;
TestErr5Clas8Ch=TestErr;

function [TrainErr,TestErr,TrainPredict,TestPredict] = ldaclassify(TrainData,
TestData,TrainClass,TestClass)
% Classifica tramite linear discriminant analysis (LDA)
% Input:
% - TrainData = Matrice (NxM) contenente i dati di training.
%           N = numero di osservazioni di training,
%           M = numero di features per ogni osservazione.
% - TestData = Matrice (GxM) contenente i dati di testing.
%           G = numero di osservazioni di testing.
% - TrainClass = Vettore lungo N contenente le classi reali di ciascun
%               osservazione di training.

```

```

% - TestClass = Vettore lungo G contenente le classi reali di ciascun
%             osservazione di testing.
% Output:
% - TrainErr = Errore di classificazione (%) per i dati di training
% - TestErr = Errore di classificazione (%) per i dati di testing
% - TrainPredict = Classe predetta per i dati di training
% - TestPredict = Classe predetta per i dati di training
TrainPredict = classify(TrainData,TrainData,TrainClass);
TestPredict = classify(TestData,TrainData,TrainClass);
TrainErr = sum(TrainPredict ~= TrainClass)/length(TrainClass)*100;
TestErr = sum(TestPredict ~= TestClass)/length(TestClass)*100;

function [CoeffSegnalino]=LDB1(segnalino,livDec,wname,Entr)
% Input:
% - segnalino = vettore lungo la dimensione della finestra
% - livDec = livello di decomposizione massimo
% - wname = wavelet madre usata per la decomposizione
% - Entr = entropia richiesta all'ingresso della 'wpdec'
% Output:
% - CoeffSegnalino = cell array di dimensioni (livDec)x((2^livDec)-1),
%                 contenente, per ogni posizione, i coefficienti del segnale
%                 di una finestra.

CoeffSegnalino = cell(livDec, (2^livDec)-1);
T = wpdec(segnalino,livDec,wname,Entr); % albero WPT del segnalino
% Estrazione coefficienti dall'albero e inserimento nel CoeffSegnalino
% tramite 'wpcoef'
for j=0:livDec
    for k=0:(2^j-1)% coefficienti per ogni sottospazio
        CoeffSegnalino{j+1,k+1} = wpcoef(T,[j k]);
    end
end

function [CoeffClasselCh]=LDB2(SegnaliTuttiSoglmov,livDec,wname,Entr)
% Input:
% - SegnaliTuttiSoglmov = matrice 1 x(lunghezza finestra)x(numero osservazione
per la classe)
% - livDec = livello di decomposizione massimo
% - wname = wavelet madre usata per la decomposizione
% - Entr = entropia richiesta all'ingresso della 'wpdec'
% Output:

```

```

% - CoeffClasse1Ch = cell array (1x1xnumero osservazioni di tutti i
%           soggetti, per una classe)
for f=1:size(SegnaliTuttiSog1mov,3) % per tutte le finestre
    CoeffClasse1Ch{1,1,f}=LDB1(SegnaliTuttiSog1mov(:, :, f), livDec, wname, Entr);
end

function [mappalClasse1Ch]= LDB3(SegnaliTuttiSog1mov, CoeffClasse1Ch, livDec)
% Input:
% - SegnaliTuttiSog1mov = matrice 1 x (lunghezza finestra) x (numero osservazione
per
%           la classe)
% - CoeffClasse1Ch = cell array (1x1xnumero osservazioni di tutti i
%           soggetti, per una classe)
% - livDec = livello di decomposizione massimo
% Output:
% - mappalClasse1Ch = matrice 3D (livDec) x ((2^livDec)-1) x (numero coefficienti del
%           primo nodo)

nmax=size(SegnaliTuttiSog1mov,2); % numero massimo coefficienti, che coincide a
% numero coeff. del primo nodo (che coincide
% con segnale originale)
mappalClasse1Ch=0.1*ones(livDec+1, 2^livDec, nmax); % Inizializziamo la matrice
% con valori a 0.1, in modo che, nelle posizioni in cui non verrà riempita, avrò
% valore noto 0.1.
for j=1: livDec+1
    for k=1:(2^(j-1))
        N=length(CoeffClasse1Ch{1,1,1}{j,k});
        for n=1:N
            Numeratore=0;
            Denominatore=0;
            for oss=1: size(SegnaliTuttiSog1mov,3)
                Numeratore=Numeratore+(CoeffClasse1Ch{1,1,oss}{j,k}(n))^2;
                Denominatore=Denominatore+(norm(SegnaliTuttiSog1mov(1, :, oss)))^2;
            end
            mappalClasse1Ch(j,k,n)=Numeratore/Denominatore;
        end
    end
end
end
end

```

```

function [EntrSimmetrica]=EntropiaSimmetrica(path,nomefile)
% Input:
% - path= percorso file contenente le mappe di tutte le classi (per tutti i
canali).
% - nomefile = file contenente la mappe.
% - Output:
% - EntrSimmetrica = matrice 3D (livello di decomposizione+1)x(2^(livello di
decomposizione-1))x(numero canali).
load(fullfile(path,nomefile));

EntrSimmetrica=[];
for ch=1:8
    EntrSim=9000*ones(livDec+1,2^livDec);
    for j=1:livDec+1
        k=1;
        while k<=2^(j-1) % Finchè k per quel j esiste
            EntrSimnodo=0;
            for p=1:8
                mappa_pch=eval(['mappaClasse', num2str(p), 'Ch',
                                num2str(ch)]);
                for q= p+1:9
                    mappa_qch=eval(['mappaClasse', num2str(q), 'Ch',
                                    num2str(ch)]);
                    oss=1;
                    while mappa_pch(j,k,oss)~=0.1 && oss<=size(mappa_pch,3)-1
                        EntrSimnodo= EntrSimnodo + (mappa_pch(j,k,oss) *
                                                    log2(mappa_pch(j,k,oss)/mappa_qch(j,k,oss)) +
                                                    mappa_qch(j,k,oss) * log2(mappa_qch(j,k,oss)/mappa_pch(j,k,oss)));
                        oss=oss+1;
                    end
                end
            end
            EntrSim(j,k)=EntrSimnodo;
            k=k+1;
        end
    end
    eval(['EntrSimmCh', num2str(ch), '=EntrSim;']);
    EntrSimmetrica=cat(3, EntrSimmetrica, EntrSim);
end

```

```

function [NodiMiglioriTuttiCanali]=BestBasis(path, file)
% Input:
% - path = percorso contenente il file relativo all'entropia simmetrica
% - file = file relativo all'entropia simmetrica
% Output:
% - NodiMiglioriTuttiCanali = cell array (numero canali)x1, contenente, per
% ogni canale, le coordinate identificative dei nodi migliori.

load(fullfile(path, file));

livDec=4;
J=livDec+1;
NodiMiglioriTuttiCanali=cell(8,1);

for ch=1:8 % per tutti i canali
    NodiMigliori=[];
    ESRanalisi=eval(['EntrSimmCh', num2str(ch)]);
    riga=1;
    for j=J-1:-1:1
        k=1;
        while k <=2^(j-1) % Finchè non ho finito i k per quel j
            Z = ESRanalisi(j,k);
            % se padre >=somma dei figli
            if Z >=(ESRanalisi(j+1,(2*k)-1) + ESRanalisi(j+1,(2*k)))
                NodiMigliori(riga,1:2)=[j,k];
                riga=riga+1;
            % se padre < somma dei figli
            else
                NodiMigliori(riga,1:2)=[j+1,2*k-1];
                riga=riga+1;
                NodiMigliori(riga,1:2)=[j+1,2*k];
                riga=riga+1;
                ESRanalisi(j,k)= ESRanalisi(j+1,(2*k)-1) + ESRanalisi(j+1,(2*k));
            end
            k=k+1;
        end
    end
    NodiMiglioriTuttiCanali{ch}=NodiMigliori;
end

```

```

function [pesi_neur, pos]=SOFM_train(DataTraining)
% Input: DataTraining = matrice (numero features)x(numero osservazioni di
%           Training)
% Output: pesi_neur = matrice (numero features)x(numero nodi)
% I valori scelti all'interno della funzione sono estratti da articolo Chu)

% Creo griglia di nodi (neuroni) 2D 40x40.

dim1=40;
dim2=40;
pos=gridtop(dim1,dim2); % Matrice 2(essendo lattice 2D) x 1600 (numero di
% nodi), contenente, ad ogni colonna, le coordinate di
% ciascun nodo.
plotsom(pos) % Visualizzo posizioni dei nodi
D=dist(pos); % Matrice simmetrica 1600 (numero di nodi) x 1600 (numero di nodi)
% contenente la distanza Euclidea tra i nodi. D(i,j)= distanza tra nodo % i e
nodo j.

% Inizializzo pesi dei neuroni con 'initsompc', il quale fa in modo che i
% pesi iniziali siano distribuiti nello spazio generato dalle 2 (essendo mappa
2D)
% componenti principali degli input. Distribuendo il peso in tal modo, si
accelera
% l'apprendimento del SOM, poichè la mappa parte da un ragionevole ordinamento
% dell'input space.

pesi_neur=initsompc(DataTraining,[dim1;dim2], pos); % Matrice (numero nodi =
% 1600)x(numero feature di ciascuna osservazione)
pesi_neur=pesi_neur'; % Matrice (numero feature di ciascuna
osservazione)x(numero
% nodi=1600)
sigma0=20;
tau1=2000;
tau2=2000;
nu0=0.9;

sigma=[]; % Alla fine del ciclo for_n, sarà un vettore riga 1x(numero
osservazioni
% training)
h=[]; % Alla fine del ciclo for_n, sarà una matrice n x (numero nodi = 1600)
nu=[]; % Alla fine del ciclo for_n, sarà un vettore riga 1x(numero osservazioni
% training)

for n=1:size(DataTraining,2) % Per tutte le osservazioni di training (vettori in

```

```

% input),
% 1. Calcolo la distanza Euclidea tra vettore in input e il vettore peso
% di ciascun nodo e pongo i valori nel vettore Dist_vetINPUT_vetPESOneuroni,
% che lo inizializzo come vuoto.
Dist_vetINPUT_vetPESOneuroni=[];

for j=1:(dim1*dim2) % Per tutti i nodi
    Dist_vetINPUT_vetPESOneuroni(j)= sqrt(sum((DataTraining(:,n)-
        pesi_neur(:,j)).^2));
end
% Dist_vetINPUT_vetPESOneuroni ha ora dimensioni: 1 x (numero nodi = 1600)

% 2. Cerco le coordinate 2D del nodo vincente: nodo a cui corrisponde un
% valore minimo di distanza dal vettore in input n-esimo.

[valore_peso_neurone_vincente,indice_neurone_vincente]=min(Dist_vetINPUT_vetP
ESOneuroni);
x_neurone_vincente=pos(1,indice_neurone_vincente); % Assume valori da 0 a 39
y_neurone_vincente=pos(2,indice_neurone_vincente); % Assume valori da 0 a 39

% 3. Calcolo distanza Euclidea di tutti i neuroni da neurone vincente.
Dist_posizione_neuroni_da_vincente=[]; % Vettore 1x(numero nodi:1600)
% contenente le distanze Euclidee dei neuroni da neurone vincente. Lo
% inizializzo come vuoto.
for j=1:(dim1*dim2)
    Dist_posizione_neuroni_da_vincente(j)= sqrt(sum((pos(:,j)-
        [x_neurone_vincente;y_neurone_vincente]).^2));
end

% 4. Calcolo h (neighborhooh function, centrato intorno a neurone vincente,
% che pesa l'aggiornamento di ogni neurone in base alla sua distanza dal
% neurone vincente).
sigma(n)=sigma0*exp(-n/taul); % sigma(n) è uno scalare
h(n,:)=exp(-(Dist_posizione_neuroni_da_vincente.^2)/(2*sigma(n)^2));

% 5. Calcolo Learning rate per lo step n.
nu(n)=nu0*exp(-n/tau2); % nu(n) è uno scalare

% 6. Aggiorno matrice peso dei neuroni (numero feature) x (numero neuroni)
for j=1:(dim1*dim2)
    pesi_neur(:,j)=pesi_neur(:,j)+nu(n)*h(n,j)*(DataTraining(:,n)-
        pesi_neur(:,j));
end
end
end

```



```

function [x_neur_vincente, y_neur_vincente]=SOFM_test(DataTest, pesi_neur, pos,
ClasseRealeTest)
% Input:
% - DataTest = matrice (numero features)x(numero osservazioni Test)
% - pesi_neur = matrice (numero features)x (numero nodi=1600)
% - pos = matrice 2(essendo griglia 2D) x (numero di nodi=1600), contenente, ad
%       ogni colonna, le coordinate di ciascun nodo.
% - ClasseRealeTest= vettore riga (1 x numero osservazioni Test) contenente la
%       classereale del DataTest.
%       Serve se voglio visualizzare nel piano x,y le coordinate
%       (x,y) per ogni osservazione, con colore dipendente dalla
%       classe.
% Output:
% - x_neur_vincente = vettore (1 x numero osservazioni Test), che indica la
%       coordinata x (che varia da 0 a 39) del neurone vincente
%       per quella osservazione.
% - y_neur_vincente = vettore (1 x numero osservazioni Test), che indica la
%       coordinata y (che varia da 0 a 39) del neurone vincente
%       per quella osservazione.

% Il neurone vincente, per ogni osservazione, si determina cercando il
% neurone per cui la distanza tra vettore peso e l'osservazione è minima.

% Per fare ciò, calcolo la distanza Euclidea tra ciascun vettore in input e
% il vettore peso di ciascun nodo.
Dist_vetINPUT_vetPESOneuroni=[];
x_neur_vincente=[]; % Creo vettore (1 x numero osservazioni di Test) contenente
% coordinata x del neurone vincente
y_neur_vincente=[]; % Creo vettore (1 x numero osservazioni di Test) contenente
% coordinata y del neurone vincente

for oss=1:size(DataTest,2)
    for neur=1:(size(pesi_neur,2))
        Dist_vetINPUT_vetPESOneuroni(neur)= sqrt(sum((DataTest(:,oss)-
            pesi_neur(:,neur)).^2));
    end
    % E' stato così creato un vettore riga (1x1600) che indica la distanza
    % tra l'osservazione 'oss' e ciascun neurone.
    % Cerco valore minimo e sua posizione nel vettore
    % Dist_vetINPUT_vetPESOneuroni

    [valore_peso_neurone_vincente, indice_neurone_vincente]=min(Dist_vetINPUT_vetP
ESOneuroni);
    % Trovo coordinata neurone vincente

```

```
x_neur_vincente(oss)=pos(1,indice_neurone_vincente);% Assume valori da 0 a 39
y_neur_vincente(oss)=pos(2,indice_neurone_vincente);% Assume valori da 0 a 39
end

% Visualizzo le osservazione nella griglia del SOFM.
figure,gscatter(x_neur_vincente,y_neur_vincente,ClasseRealeTest);
```