



UNIVERSITÀ  
DEGLI STUDI  
DI PADOVA



**DIPARTIMENTO DI INGEGNERIA DELL'INFORMAZIONE**

**CORSO DI LAUREA IN INGEGNERIA DELL'INFORMAZIONE**

**ANALISI CONGIUNTA DI SEGNALI EEG ED EMG:  
REVISIONE CRITICA DELLO STATO DELL'ARTE E PROSPETTIVE  
FUTURE**

**Relatore:  
Prof. Leonardo Badia**

**Laureanda:  
Lavinia Verzotto**

**Correlatrice:  
Dott.ssa Giulia Cisotto**

**ANNO ACCADEMICO 2021 – 2022**

**16 novembre 2022**



**ANALISI CONGIUNTA DI SEGNALI EEG ED EMG:  
REVISIONE CRITICA DELLO STATO DELL'ARTE E PROSPETTIVE  
FUTURE**

RELATORE: Leonardo Badia  
CORRELATRICE: Giulia Cisotto  
LAUREANDA: Lavinia Verzotto  
16 novembre 2022



# Indice

---

Abstract	1
Capitolo 1 - Introduzione	3
Capitolo 2: Background	5
2.1 Introduzione ai segnali EEG	5
2.2 Introduzione ai segnali EMG	7
2.3 Modalità di fusione dei dati	8
2.3.1 Data-level fusion	9
2.3.2 Feature-level fusion: features EEG/EMG	10
2.3.3 Decision-level fusion: modelli di decisione	10
2.4 Motivazione della tesi	10
2.5 Domande di ricerca	11
Capitolo 3: Revisione critica dello stato dell'arte	13
3.1 Tabella e inquadramento generale della revisione	13
3.2 Feature e algoritmi più utilizzati	21
3.2.1 Feature nel dominio del tempo	21
3.2.2 Feature nel dominio della frequenza	22
3.2.3 Algoritmi per l'estrazione di feature	23
3.3 Fusion level e metodi di classificazione	27
3.4 Dataset e acquisizione dei segnali	29
Capitolo 4: Discussione	33
4.1 Confronto sulle modalità di fusione dei dati	33
4.2 Motivazioni per l'uso combinato di segnali EEG ed EMG	37

4.3 Setup e fruibilità	40
4.4 Take-home messages	42
Capitolo 5 – Conclusione	45
Bibliografia	47

## **Acronimi**

**AE** Approximate Entropy

**ANN** Artificial Neural Network

**AR** Autoregressive Coefficients

**ASB** Absolute Sub-band Power

**BCI** Brain-Computer Interface

**BP** Back Propagation

**CBTP** Correlation Between the band-limited Power Time-courses

**CD** Correlation Dimension

**CMC** Cortico-Muscular Coherence

**CNN** Convolutional Neural Network

**CS** Coupling Strength

**CSP** Common Spatial Pattern

**DBM** Deep Boltzmann Machine

**ERS/ERD** Event-Related Synchronization/Desynchronization

**FFT** Fast Fourier Transform

**FPPSD** Frequency with the Peak Power Spectral Density

**GA** Genetic Algorithm

**GS** Grid Search

**hHMI** Hybrid Human-Machine Interface

**ICA** Independent Component Analysis

**kNN** k-Nearest Neighbor

**KSVM** Kernel Support Vector Machine

**LDA** Linear Discriminant Analysis

**LLE** Largest Lyapunov Exponent

**LSTM** Long Short-Term Memory

**LSVM** Support Vector Machine with the Linear kernel

**MAV** Mean Absolute Value

**MAS** Mean Absolute Slope

**mHMI** Multimodal Human-Machine Interface

**MI** Motor Intention

**MLP** Multi-Layer Perceptron

**MPF** Mean Power Frequency

**PCA** Principal Component Analysis  
**PPSD** Peak Power Spectrum Density  
**PSD** Power Spectral Density  
**PSO** Particle Swarm Optimization  
**RMS** Root-Mean Square  
**RPR** Relative Power Ratio  
**SAE** Stacked Autoencoder  
**SD** Standard Deviation  
**SE** Spectral Energy  
**SNR** Signal-to-Noise Ratio  
**SR** Sparse Representation  
**SSC** Slope Sign Change  
**STFT** Short-Time Fourier Transform  
**SVM** Support Vector Machine  
**TDMI** Time Delayed Mutual Information  
**TFCMI** Time–Frequency Cross Mutual Information  
**V** Variance  
**VS-STE** Variable Scale Symbolic Transfer Entropy  
**WA** Willison Amplitude  
**WC** Wavelet Coherence  
**WES** Wavelet Energy Spectrum  
**WL** Waveform Length  
**WTC** Wavelet Transform Coefficients  
**ZC** Zero Crossing

## **Abstract**

Studi recenti hanno analizzato lo sviluppo di approcci di controllo ibridi basati su segnali cerebrali (EEG) e muscolari (EMG). È stato infatti dimostrato che le performance ottenute dalla combinazione di questi due tipi di segnali sono migliori rispetto a quando vengono usati singolarmente, specialmente nel campo della bio-robotica applicata a pazienti con deficit motori. In questa tesi vengono riportati i risultati più interessanti di questo campo applicativo, sulla base di una revisione sistematica dello stato dell'arte degli ultimi dieci anni. Vengono approfonditi gli aspetti che caratterizzano lo sviluppo di modelli ibridi EEG-EMG, ossia l'acquisizione dei dati, l'uso di algoritmi per l'estrazione di feature e in particolare i metodi di fusione e di classificazione, al fine di confrontare quali siano i vantaggi e gli svantaggi degli approcci analizzati, discutendone le principali limitazioni e come potrebbero essere superate in futuro.



# Capitolo 1 – Introduzione

---

Negli ultimi anni il campo della bio-robotica e delle human-machine interface ha trovato ampia applicazione nello sviluppo di tecnologie assistive e riabilitative, ad esempio lo sviluppo di protesi/ortesi, esoscheletri per attività terapeutiche e arti robotici [10, 11, 12]. Controllare questo tipo di sistemi richiede metodi e tecnologie sofisticate poiché interagendo con utenti, è necessario soddisfare determinati requisiti quali accuratezza, affidabilità e sicurezza.

Molte di queste soluzioni riabilitative si basano su segnali cerebrali (come EEG), altre invece dipendono da segnali muscolari (come EMG). L'uso di un solo tipo di segnali ha dimostrato diversi svantaggi: i segnali cerebrali hanno un rapporto segnale-rumore (SNR) molto basso e devono essere adattati al paziente per assicurarne l'affidabilità, mentre i segnali muscolari possono essere limitati dal fatto che i soggetti affetti da malattie neuromuscolari hanno una scarsa, se non nulla, attività muscolare [25].

Per superare i problemi dei singoli segnali EEG o EMG un approccio promettente è la combinazione dei due, in modo da sfruttare i vantaggi e ridurre le limitazioni di entrambi. Ad esempio, i segnali EEG possono compensare la mancanza di EMG o rimuovere l'effetto dell'affaticamento muscolare [28].

Per questo motivo, la combinazione di diversi segnali biologici per migliorarne l'uso pratico sta acquisendo con il tempo maggior interesse, in particolare vengono sviluppate delle BCI e mHMI derivanti da questa ibridazione [7, 13].

L'obiettivo di questa revisione consiste nel verificare in che modo vengono acquisiti i segnali, quali sono i metodi di fusione e gli algoritmi applicati, analizzare in che modo EEG combinate a EMG sono migliori in termini di prestazione rispetto ai segnali singoli e la loro utilità nel campo della riabilitazione motoria. Infine, definire quali aspetti si possono migliorare per permettere in futuro una maggior fruibilità da parte dell'utente di questi modelli.

La tesi è strutturata in tre capitoli:

- Capitolo 2 – Background: vengono introdotti i concetti di base che serviranno per la comprensione dei capitoli successivi. Sono descritti i segnali EEG ed EMG: come vengono generati, acquisiti e processati (2.1 e 2.2). In 2.3 vengono introdotte le modalità di fusione dei dati acquisiti da questi due tipi di segnali che saranno poi analizzate nel capitolo successivo. Nell'ultima parte (2.4 e 2.5) sono riportate le domande di ricerca e le motivazioni di questo elaborato;

- Capitolo 3 – Revisione critica dello stato dell’arte degli ultimi dieci anni: In 3.1 sono descritti i criteri di ricerca e selezione degli articoli usati per questa revisione ed è presente una tabella che riassume brevemente i dati utili ai fini della revisione. In 3.2 e 3.3 sono descritti e analizzati algoritmi, modalità di fusione e di classificazione dei dati e in 3.4 viene spiegato in che modo vengono processati i dati grezzi prima di essere usati per la classificazione;
- Capitolo 4 – Discussione: nell’ultimo capitolo vengono confrontate le modalità di fusione dei dati con relativi vantaggi/svantaggi (4.1), viene comprovata la superiorità (in termini di performance) della combinazione dei segnali rispetto all’uso dei singoli (4.2) e si cerca di capire se in futuro ci saranno dei miglioramenti nel campo della riabilitazione che permettano la fruibilità da parte dei pazienti (4.3). Infine, in 4.4 sono riportate sinteticamente le risposte alle domande di ricerca.

# Capitolo 2 – Background

---

In questo capitolo viene fornita una panoramica sui concetti che verranno analizzati e studiati nei capitoli successivi.

Vengono descritti i segnali EEG ed EMG, come vengono acquisiti i dati e che cosa rappresentano, in che modo vengono elaborati i segnali e quali sono i livelli di fusione che permettono la classificazione e successivamente le motivazioni di questa revisione e le domande alle quali verrà data una risposta nell'elaborato.

## 2.1 Introduzione ai segnali EEG

Durante l'attività cerebrale, la corteccia cerebrale genera delle correnti che derivano dalla sovrapposizione degli effetti delle eccitazioni sinaptiche [32], generate da un insieme molto esteso di neuroni. Queste correnti generano un campo elettrico sullo scalpo misurabile tramite segnali elettroencefalografici (EEG).

Tra la corteccia e lo scalpo sono presenti degli strati intermedi, che causano un'attenuazione del segnale. Per questo motivo la registrazione di segnali EEG avviene quando c'è una sincronizzazione di una grande quantità di neuroni [32].

Nei segnali EEG si manifestano dei ritmi cerebrali che hanno diverse frequenze e che delineano cinque bande di interesse [32]:

- Le onde *delta* ( $\delta$ ) hanno frequenza tra 0.5-4 Hz, vengono associate al sonno profondo ma possono essere presenti anche nello stato di veglia. È facile confondere la risposta di queste onde con altri segnali provenienti dai muscoli vicini (es. quelli del collo);
- Le onde *theta* ( $\theta$ ) hanno frequenza tra 4-7.5 Hz, vengono associate al sonno cosciente e sono legate alla meditazione. Sono solitamente affiancate ad altre frequenze e sembrano essere correlate allo stato di agitazione/tranquillità;
- Le onde *alpha* ( $\alpha$ ) hanno frequenza tra 8-13 Hz, vengono associate allo stato cosciente ma privo di attenzione e si trovano nella regione occipitale. Appaiono come un segnale sinusoidale e sono il ritmo più prominente tra quelli cerebrali;
- Le onde *beta* ( $\beta$ ) hanno frequenza tra 14-26 Hz, vengono associate al pensiero attivo e all'attenzione e si trovano normalmente negli individui adulti. La loro attività si colloca soprattutto nelle regioni frontali e centrali;

- Le onde *gamma* ( $\gamma$ ) hanno frequenza sopra i 30 Hz, sono rare e il loro rilevamento può essere usato come conferma per la presenza di malattie neurologiche.

Nella figura 2.1 vengono rappresentati i quattro ritmi principali.

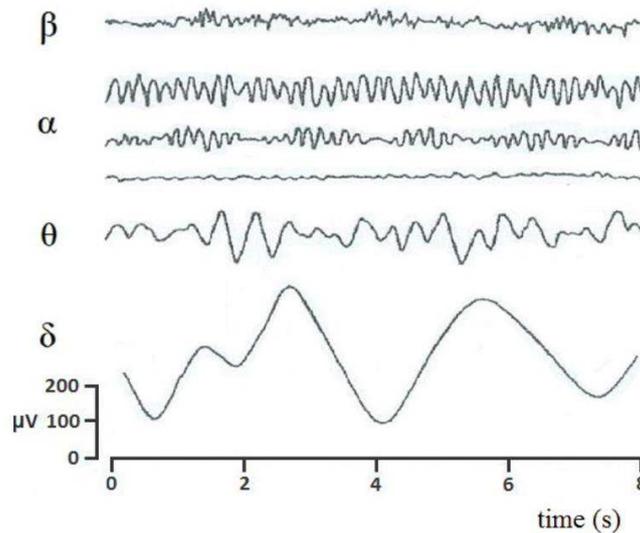


Figura 2.1: Esempi di segnali EEG nelle principali bande di frequenza. (Tratta da [32]).

Un sistema di acquisizione dei segnali EEG è composto da elettrodi, amplificatori e filtri.

Il posizionamento degli elettrodi segue il sistema 10-20 fornito dalla Federazione Internazionale delle Società di EEG e Neurofisiologia Clinica (IFCN) [32] e illustrato nella figura 2.2. Viene chiamato così perché considera alcune distanze costanti, utilizzando specifici punti di riferimento anatomici, da cui verrebbe eseguita la misurazione e quindi utilizza il 10 o il 20% di quella distanza come intervallo tra gli elettrodi.

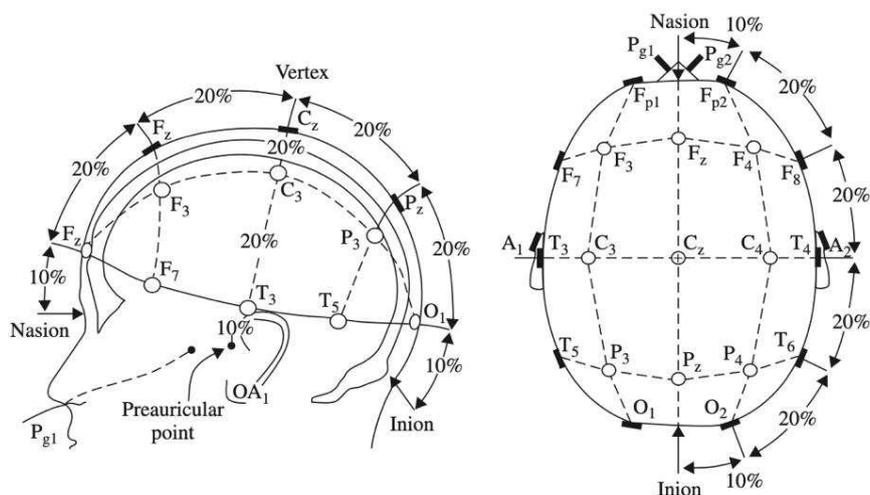


Figura 2.2: Posizionamento degli elettrodi secondo il sistema 10-20. (Tratta da [32])

Il segnale viene registrato dagli elettrodi, successivamente viene amplificato (poiché gli strati intermedi, tra cui scalpo e cranio, attenuano il segnale) e filtrato. Il filtro può essere applicato prima o dopo la conversione A/D e serve a ridurre il rumore e rendere il segnale adatto all'elaborazione.

Dopo l'acquisizione, i filtri agiscono sul segnale in modo da non provocarne l'alterazione, in particolare i filtri passa-alto (che hanno di solito una frequenza di cut-off minore di 0.5 Hz) vengono usati per rimuovere i disturbi a frequenze molto basse come la respirazione, mentre i filtri passa-basso vengono usati per rimuovere disturbi a frequenze più alte (50-70 Hz).

I segnali EEG sono spesso affiancati nella ricerca ai segnali EMG per studiare l'intenzione di movimento in pazienti che hanno scarsa forza muscolare con lo scopo di facilitarne la riabilitazione.

## **2.2 Introduzione ai segnali EMG**

L'elettromiografia (EMG) è una tecnica che tratta l'acquisizione e l'analisi dei segnali mioelettrici generati dalle fibre muscolari.

I segnali EMG si basano sui potenziali d'azione nella membrana delle fibre muscolari dati dalla polarizzazione e depolarizzazione, due processi chimici che si verificano nei muscoli in seguito al movimento [36]. In particolare, un segnale EMG grezzo rappresenta il potenziale d'azione dell'unità motoria.

L'ampiezza dei segnali EMG può variare in un range +/- 5 mV, tipicamente il supporto in frequenza varia tra 6 e 500 Hz e hanno una potenza spettrale compresa tra i 20 e i 150 Hz.

Prima che un segnale possa essere analizzato deve subire una conversione A/D e deve essere selezionata una frequenza di campionamento, che deve essere almeno il doppio della frequenza massima che ci si aspetta dal segnale. Le raccomandazioni scientifiche (proposte da SENIAM) consigliano una frequenza di campionamento di 1000 Hz o addirittura 1500 Hz per evitare la perdita di dati. [36]

La qualità della misurazione del segnale non dipende solo dalla scelta della frequenza di campionamento, ma soprattutto dalla preparazione della superficie e dal posizionamento degli elettrodi. La cute deve essere pulita e disinfettata in modo che raggiunga un'impedenza tra 5 e 50 kOhm (a questo scopo vengono utilizzati dei detergenti appositi), successivamente si può procedere al posizionamento degli elettrodi (che possono essere superficiali o sottocutanei) e che comprendono, oltre a quelli specifici per i movimenti analizzati, anche un elettrodo neutro di riferimento.

Dopo essere stato acquisito, il segnale EMG viene levigato per eliminare eventuali disturbi che possono essere causati dal battito cardiaco, dai muscoli adiacenti o anche dall'interferenza. A questo

proposito bisogna prestare particolare attenzione all'utilizzo dei filtri Notch (spesso impiegati per rimuovere il rumore) dal momento che questi possono rimuovere anche parte del segnale di interesse [11, 13, 22].

I segnali EMG sono usati nella ricerca scientifica per studiare l'analisi del movimento e quindi il controllo di dispositivi per la riabilitazione motoria (in figura 2.3 lo schema di acquisizione).

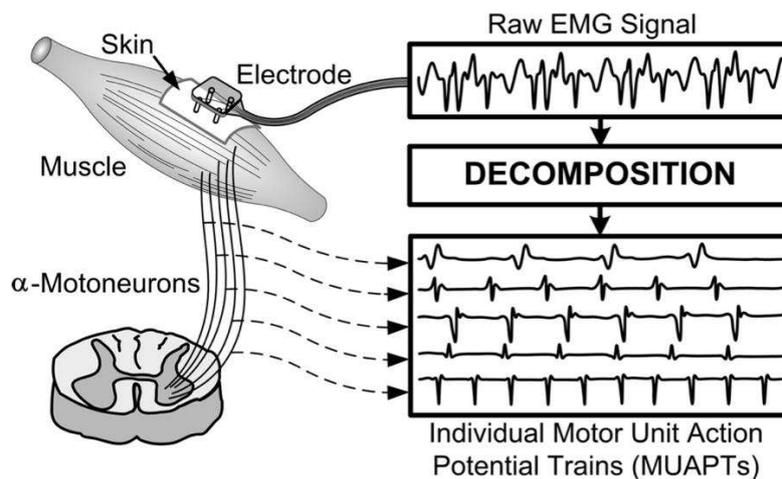


Figura 2.3: Schema di acquisizione di un segnale EMG. (Tratta da [36])

## 2.3 Modalità di fusione dei dati

I dati che vengono estratti dall'acquisizione dei segnali EEG ed EMG durante il movimento vengono filtrati e successivamente combinati per costruire dei modelli che permettano un'analisi più accurata. In questo paragrafo vengono descritti quali sono i tre metodi di fusione utilizzati per l'analisi dei segnali.

Esistono tre modalità di fusione dei dati provenienti da sensori (in questo caso elettrodi) per l'interpretazione di segnali EEG ed EMG:

- **Data-level-fusion:** i dati grezzi registrati dagli elettrodi vengono combinati a questo livello;
- **Feature-level-fusion:** dai dati grezzi vengono estratte delle feature che vengono combinate e poi passate al classificatore;
- **Decision-level-fusion:** le feature estratte dai dati vengono classificate e dal risultato della classificazione sulle diverse modalità di sensing (per es. EEG ed EMG, separati) viene presa la decisione.

Nella figura 2.4 viene illustrato in modo schematico come operano i tre livelli di fusione.

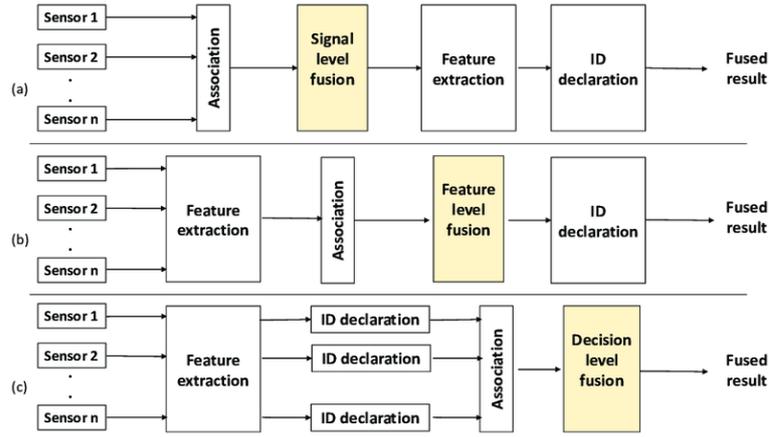


Figura 2.4: Schema dei tre livelli di fusione. (Tratta da [33])

### 2.3.1 Data-level-fusion

Nella fusione a livello di dato vengono combinate le informazioni acquisite da sensori multipli per ottenere delle valutazioni più specifiche rispetto a quelle di un singolo segnale [33].

Per la fusione dei dati di segnali EEG ed EMG l'analisi più utilizzata è la coerenza cortico-muscolare (CMC), che viene effettuata nel dominio della frequenza e che rappresenta in modo quantitativo l'interazione tra corteccia cerebrale e muscoli. Questo indice è utile perché l'interazione cambia da individuo a individuo, in particolare nel caso in cui siano presenti dei disturbi motori [2].

Per ottenere la CMC il processo è il seguente: ogni segnale è diviso in campioni della durata di 1 – 4 s e successivamente viene applicato un filtro passabanda per eliminare le frequenze che non portano informazioni rilevanti [37].

Siano  $S_x^{(i)}(f)$  e  $S_y^{(i)}(f)$ , con  $i = 1, 2, \dots, N$ , le potenze spettrali del segmento  $i$ -esimo dei segnali (rispettivamente EEG ed EMG). Sia  $S_{xy}^{(i)}(f)$  l' $i$ -esimo segmento della potenza spettrale mutua tra i segnali.  $S_x(f)$ ,  $S_y(f)$  e  $S_{xy}(f)$  sono le medie calcolate rispettivamente da  $S_x^{(i)}(f)$ ,  $S_y^{(i)}(f)$  e  $S_{xy}^{(i)}(f)$ , con  $i = 1, 2, \dots, N$ . La CMC di ogni segmento di prova è comunemente ottenuta come:

$$|CMC^{(i)}(f)|^2 = \frac{|S_{xy}^{(i)}(f)|^2}{S_x^{(i)}(f)S_y^{(i)}(f)}$$

$|CMC^{(i)}(f)|^2$  rappresenta la potenza spettrale mutua tra EEG ed EMG. Conseguentemente  $|CMC(f)|^2$  assume valori in un range 0 – 1. [37]

La coerenza tra i due segnali è forte se il valore della CMC si avvicina all'1.

Altri metodi di fusione dei dati di segnali EEG+EMG, citati nella Tabella 3.1, sono l'analisi di informazione mutua (MI) [24], la trasformata delle forme d'onda (WT) [4], e la CBPT [17]. Questi vengono descritti nel capitolo 4.1 e le performance confrontate con quella della CMC.

### **2.3.2 Feature-level-fusion: feature EEG/EMG**

Se la fusion avviene a livello di feature significa che i dati vengono ricavati da sensori multipli, da questi vengono ricavate delle feature nel dominio del tempo e della frequenza e successivamente combinate per formare dei vettori [31].

Le feature, che possono essere calcolate nel dominio del tempo o della frequenza, vengono elencate e descritte nei capitoli 3.2.1 e 3.2.2.

Il calcolo di determinati tipi di feature dipende dallo studio che si desidera effettuare che può riguardare il normale stato di riposo, la classificazione delle fasi del sonno, l'intenzione di movimento e il tipo di movimento effettuato.

In questo metodo di fusione, dopo aver acquisito i dati ed estratto le feature, queste ultime vengono consolidate in una feature singola grazie ad algoritmi descritti nel capitolo 3.2.

Gli algoritmi di fusione vengono usati per aggiornare e migliorare i modelli già esistenti.

### **2.3.3 Decision-level-fusion: modelli di decisione**

A questo livello le feature vengono classificate e i risultati ottenuti grazie ai diversi classificatori vengono combinati per prendere la decisione.

I criteri di decisione maggiormente utilizzati sono introdotti nel capitolo 3.3.

Questo livello di fusione consiste nel selezionare una decisione da una serie di ipotesi che provengono dalle feature classificate dalle singole modalità di segnali (solo EEG oppure solo EMG), e attraverso degli algoritmi (es. Bayes [7]) prendere la decisione finale.

Nei modelli di decisione si tiene conto del peso degli errori dei classificatori per arrivare all'ipotesi finale, il che ne migliora la performance. Per questo motivo nella maggior parte degli studi analizzati, soprattutto in quelli più recenti lo scopo è di creare delle reti neurali che operino a questo livello di fusione [4, 15, 25].

## **2.4 Motivazione della tesi**

Questa tesi aggiorna lo stato dell'arte e confronta in modo sistematico diversi modelli che usano simultaneamente segnali EEG ed EMG.

I segnali EEG ed EMG singolarmente hanno delle limitazioni (2.1 e 2.2) ma la loro combinazione è molto efficace per lo studio di dispositivi per la riabilitazione e del movimento in soggetti neurologicamente o muscolarmente debilitati.

In particolare, nel capitolo 4.2 verrà analizzato come lo studio di modelli e metodi di classificazione per EEG+EMG ha delle performance migliori in termini di accuratezza e precisione rispetto allo studio dei singoli segnali.

Per valutare le performance e sostenere se effettivamente la combinazione di segnali rappresenta un approccio migliore per lo studio del movimento vengono utilizzati alcuni parametri:

- *Accuratezza*: è la percentuale di azioni classificate correttamente;
- *Precisione*: le classificazioni sui diversi segnali sono in accordo tra loro;
- *Specificità*: capacità di classificare un segnale basandosi su altri che hanno caratteristiche simili.

Sono stati analizzati degli studi risalenti agli ultimi 15 anni e, se nei primi anni lo scopo dello studio era quello di verificare la stretta correlazione tra questi due tipi di segnali o progettare dei modelli le cui performance fossero migliori di quelli precedenti, ad oggi lo scopo principale è quello di applicare le conoscenze acquisite in campo pratico, sviluppando nuovi dispositivi che permettano al paziente di usufruirne nella vita di tutti i giorni.

## **2.5 Domande di ricerca**

Nello sviluppo dei capitoli centrali si cerca di trovare una risposta ad alcune domande mirate ad analizzare in modo specifico in che modo viene effettuato uno studio sulla correlazione e successiva applicazione di segnali EEG ed EMG e quali sono le caratteristiche che possono essere migliorate in futuro.

La tesi in particolare si focalizza su:

- 1- In che modo vengono acquisiti e processati i segnali: come vengono rilevati i dati e quali filtri si applicano per eliminare il rumore e i disturbi dal segnale grezzo (Cap 3.4);
- 2- La scelta del metodo di fusione dei dati: quali metodi di fusione dei dati acquisiti vengono utilizzati, per quale scopo, e quali sono i vantaggi dei tre livelli (Cap 4.1);
- 3- Gli algoritmi più efficaci: in che modo vengono estratte le feature e quali sono gli algoritmi utilizzati per la successiva classificazione che portano a percentuali di performance più alte (Cap 4.1);

- 4- I vantaggi della combinazione di segnali EEG+EMG: confronto tra gli studi che analizzano i segnali singolarmente e combinati tra loro (Cap 4.2);
- 5- La fruibilità in termini di setup: quando il modello di acquisizione dei dati è troppo invasivo o non permette di essere usato in tempo reale e quali sono gli aspetti che si possono migliorare per permetterlo (Cap 4.3).

# Capitolo 3 – Revisione critica dello stato dell'arte

---

## 3.1 Tabella e inquadramento generale della revisione

La tabella 3.1, che si trova nelle pagine seguenti, è stata compilata dopo aver letto ed esaminato trenta articoli riguardanti la misurazione congiunta di segnali EEG ed EMG.

Per la selezione degli articoli è stata data priorità agli studi su rivista piuttosto che su conferenza, impostando su Google Scholar un intervallo temporale dal 2010 al 2022.

Gli articoli selezionati presentano degli studi interessanti riguardanti l'acquisizione di segnali EEG ed EMG e ne verificano l'efficacia in termini di accuratezza, sensibilità e precisione rispetto all'uso di EEG ed EMG separato.

Nella tabella sono riportati i dati utili ai fini della review:

- *Scopo dello studio*: quali sono i fini e per quali applicazioni potrà essere usato in futuro;
- *Task*: movimenti che sono stati utilizzati per l'acquisizione dei segnali;
- *Dataset*: numero di partecipanti e setup per l'acquisizione dei segnali;
- *Pre-processing*: in caso sia stato effettuato;
- *Metodo*: vengono elencate le feature estratte da EEG/EMG, il fusion level e l'algoritmo di classificazione;
- *Performance*: in termini di accuratezza, precisione e altre metriche utili per comprovare la validità dello studio.

REF	SCOPO	TASK	DATASET	PRE-PROCESSING	METODO	PERFORMANCE
*Wang and Suppiah, 2022 [1]	Robotica riabilitativa per arti superiori	Afferrare e sollevare oggetti con diverse superfici (2 serie da 34 ripetizioni) e di diverso peso (6 serie da 34 ripetizioni) + 2 serie miste da 28 ripetizioni l'una	- <a href="#">Test su WAY-EEG-GAL dataset</a> -EEG: 32 canali a 500Hz (7 selezionati per estrarre le feature) -EMG: 5 canali a 4000Hz -12 partecipanti	-EEG: features estratte da TD e FD selezionate con algoritmo Boruta	I: MAV, SD, V, ASB, PPSD, FPPSD, SE II: MAV, WL, WA, MAS, AR III: decision IV: MLP, LSVM, SVM, kNN, LSTM LSTM è il classificatore migliore	Accuratezza: - 99.8% con rumore Gaussiano su segnali EEG - 89.7% con rumore Gaussiano su segnali EMG - 89.7% con rumore Gaussiano su EEG ed EMG
*Keihani et al., 2022 [2]	Maggior precisione nel rilevare segnali cortico-muscolari	Premere un pulsante con la mano e con il piede, aprire e chiudere la mano, flessione della pianta e del dorso del piede (20 ripetizioni di ogni movimento)	-EEG: 53 canali a 1200Hz -EMG: 4 canali bipolari a 1200Hz -15 partecipanti	-EEG: filtro passabanda 2-500 Hz + Notch e rimozione dei disturbi -EMG: filtro passabanda a 5-200 Hz HAPPE pipeline	I: CMC II: CMC III: data IV: SVM (SR), kNN (CMC)	Accuratezza: 88.12% (SVM), 50.83% (kNN) Specificità: 92.45% (SVM), 49.47% (kNN) Sensività: 83.85% (SVM), 52.17% (kNN)
*Wei et al., 2021 [3]	Riconoscimento delle fasi del GAIT per la riabilitazione degli arti inferiori	Cammino su un tapis roulant a 2.0 km/h, 1.4 km/h e 2.6 km/h, per ogni velocità 15 serie da 30s l'una	-EEG: 24 canali a 500Hz -EMG: 8 canali a 500Hz -7 partecipanti	-EEG: ricampionati a 1000Hz + ICA per eliminare disturbi -EMG: filtrati passabanda a 30-450 Hz + Notch	I: SSC, MPF II: SSC, MPF III: feature IV: SVM con ottimizzazione PSO	Accuratezza: -Caso 1 (SSC e MPS di EMG): 93.47% -Caso 2 (SSC e MPS di EMG + SSC di EEG): 95.58% -Caso 3 (SSC e MPS di EMG + MPF di EEG): 71.90%

*Zhang et al., 2021 [4]	Modello matematico per il movimento degli arti inferiori	15 sessioni da 5 ripetizioni di movimenti volontari degli arti inferiori	-EEG: 36 canali a 1000Hz -EMG: 2 canali a 1000Hz -6 partecipanti	-EEG: filtrati passabanda a 0,5-45Hz -EMG: filtrati passabanda a 20-200Hz + Notch	I: WC, RP (readiness potential) II: WC III: decision IV: Homology Analysis	-A 1Hz la coerenza tra EEG ed EMG è molto forte all'inizio del movimento -La fase delle EEG precede quella delle EMG
*Hong et al., 2021 [5]	Studiare l'efficacia dei set di feature per determinare le fasi del GAIT	Cammino su tapis roulant (15 sessioni di 30s)	-EEG: 21 canali a 500Hz -EMG: 8 canali a 500Hz -7 partecipanti	-EEG: filtrati passabanda a 0.5-50 Hz + Notch -EMG: filtrati passabanda a 10-250Hz + Notch	I: SSC II: SSC, MAV III: feature IV: LDA, KNN, KSVM ottimizzato con PSO, GS e GA	Accuratezza migliore: $98.56 \pm 1.34\%$ (KSVM)
Tryon and Trejos, 2021 [6]	Creare un modello CNN per estrarre informazioni da EEG ed EMG simultaneamente e migliorare l'utilizzo di esoscheletro	3 ripetizioni di flessione ed estensione del gomito, a 2 velocità diverse e con 3 pesi diversi	-dataset disponibile su richiesta -EEG: 6 canali a 4000Hz -EMG: 4 canali a 4000Hz -32 partecipanti	-EEG: filtrati passabanda a 0.5-40 Hz -EMG: filtrati passabanda a 20-500 Hz -Conversione del dataset in immagini per il CNN	I: STFT II: STFT III: data IV: classificatori basati su modello CNN (raggruppato, misto, solo EEG, solo EMG)	Accuratezza migliore (grouped fusion method): $80.51 \pm 8.07\%$
Tortora et al., 2020 [7]	Creare un hHMI per decodificare le fasi del GAIT degli arti inferiori	2 sessioni di 10 minuti di camminata su un tapis roulant, a 2.5 km/h e 3.5 km/h	-dataset disponibile su richiesta, <a href="#">preregistrato</a> -EEG: 64 canali a 2048Hz -EMG: 6 canali a 1000Hz -11 partecipanti	-EEG: filtrati a 1-98Hz e ricampionati a 512Hz -EMG: filtrati passabanda a 10-250 Hz	I: Frequenze (delta, theta, alpha, beta, gamma) II: Smooth Rectified III: decision IV: LSTM network paralleli	Precisione > 80% Accuratezza > 80%
*Hooda et al., 2020 [8]	Controllo di dispositivi robotici e riabilitazione per arti inferiori	Flessione plantare/dorsale piede dx/sx (5 sessioni da 10 minuti l'una)	-EEG: 12 canali a 2000Hz -EMG: 4 canali bipolari a 2000Hz -11 partecipanti	-EEG: filtrati a 0.1-40 Hz + Notch + CAR -EMG: filtrati a 10-500 Hz e filtrati passabanda a 50Hz	I: ERD/ERS II: MAV, ZC, WL, SSC III: decision IV: SVM	Accuratezza di previsione: $(96.58 \pm 2.37)\%$ Tempo di calcolo: $(51.89 \pm 1.15)$ ms

Liang et al., 2020 [9]	Stimare EMG da EEG per aumentare la potenza di un esoscheletro per il movimento degli arti superiori	Flessione ed estensione del braccio dx (15 ripetizioni)	-EEG: 7 canali a 45Hz -EMG: 1 canale a 45Hz -3 partecipanti	-EEG: filtrati a 0.1-45Hz -EMG: conversione A/D e filtrati a 0.7 Hz	I: Frequenze nelle bande < 45Hz analizzate con ICA e STFT II: Ampiezze dei segnali analizzate con ICA e STFT III: data IV: PCA	Correlazione tra EMG stimati e misurati (r-value): 0.78(±0.037)
Ferdiansyah et al., 2020 [10]	Create un sistema per il controllo di un'ortesi per movimenti degli arti superiori	Rilassamento, flessione ed estensione del braccio (4s ogni movimento, ripetuti per 3 serie da 10 minuti l'una)	-EEG: 4 canali -EMG: 2 canali -1 partecipante	-EEG/EMG: filtro passabanda a 2Hz + ICA	I: PSD, RPR II: RMS III: feature IV: SVM	Accuratezza: 90.3%
Gordleeva et al., 2020 [11]	Sistema di controllo in tempo reale di un esoscheletro per gli arti inferiori	Uso dell'esoscheletro per circa 90 minuti (prima usando MI e poi con movimenti reali)	-EEG: 7 canali a 500Hz -EMG: 8 canali -8 partecipanti	-EEG: filtrati passabanda a 8-15Hz + Notch a 50Hz -EMG: filtrati passabanda a 10-300Hz + Notch a 50Hz	I: CSP, ERD/ERS II: RMS, CSP III: decision IV: LDA	Accuratezza media: 78.3%
Zhang et al., 2019 [12]	Sistema mHMI per il controllo in tempo reale di una mano robotica	Uso della mano robotica: 10 movimenti della mano dx/sx usando MI (EEG) + 6 movimenti reali della mano dx/sx (EMG)	-EEG: 500Hz -EMG: 200Hz -6 partecipanti	-EEG/EMG: filtro Notch a 50Hz per rimuovere interferenza	I: ERD/ERS, valore medio della somma quadratica II: MAV, WL, ZC, SSC III: decision IV: SVM	Accuratezza classificazione: 93.83% Rate informazione: 47.41 bits/min
*Li et al., 2019 [13]	Controllo di un esoscheletro che permetta di salire e scendere una scala grazie ad un BCI+EMG	Uso dell'esoscheletro per salire/scendere una scala	-EEG: 40 canali a 500Hz -EMG: 2 canali a 150Hz -3 partecipanti	-EEG: filtrati passabanda a 5-30Hz + filtro Notch	I: ERD/ERS II: MAV III: data IV: back propagation neural network	ERA (EEG recognition accuracy) > 80%

*Mezzina et al., 2019 [14]	Nuova strategia per il rilevamento di una caduta pre-impatto	Camminata disturbata da movimenti per far perdere l'equilibrio	-EEG: 32 canali a 500Hz -EMG: 10 canali a 500Hz -6 partecipanti	-EEG: filtri passabanda a 1-40 Hz + Notch -EMG: filtri passabanda a 10-240 Hz + Notch	I: PSD (teta, alfa, beta) II: Trigger Extraction + MT selection III: decision IV: Muscular score AND (logical) Cortical Dynamics Change Detector	Sensibilità: 93.33%, Specificità: 99.82%
Sbargoud et al., 2019 [15]	Fusione dei dati EEG/EMG che sfrutta i vantaggi di entrambi per identificare i movimenti	10 serie da: 3 movimenti di mani (chiusura, apertura, rotazione) e 3 movimenti degli occhi (in alto, dx, sx)	-EEG: 1 canale a 512Hz -EMG: 2 canali a 1kHz -13 partecipanti	-EEG: filtri passabasso -EMG: filtri a 60-160 Hz e amplificati	I: WC II: WTC, energia III: decision IV: ANN + MLP	Migliora la classificazione del movimento della mano del 10%
*Chambon et al., 2018 [16]	Usare canali EEG multipli e altri segnali come EMG per studiare le fasi del sonno	Registrazioni dei parametri in 62 notti, ognuna di un soggetto diverso	-Dataset pubblico MASS -EEG: 20 canali -EMG: 3 canali	-EEG/EMG: filtro passabasso a 30Hz e ricampionati a 128Hz	I: PSD (delta, theta, alfa, beta, gamma) II: Energia III: feature IV: Softmax	Accuratezza: 87%
*Chowdhury et al., 2018 [17]	Sviluppare grazie a BCI un'ortesi per la neuro-riabilitazione della mano	40 movimenti della mano dx/sx portando un'ortesi (3 serie da 8 minuti)	-EEG: 6 canali a 512Hz -EMG: 4 canali a 512Hz -24 partecipanti (di cui 8 emiplegici)	-EEG: filtro passabanda a 8Hz-12Hz -EMG: filtro passabanda a 30Hz-50Hz	I: CBPT II: CBPT III: data IV: SVM	Accuratezza: 92.81% in soggetti sani e 84.53% in pazienti che hanno avuto ictus
Pan et al., 2018 [18]	Migliorare il controllo neuromuscolare di individui che hanno avuto un ictus	Stimolazione elettrica (ES) prima dell'allenamento sulla funzione della mano (per 8 settimane)	-dataset disponibile su richiesta -EEG: 16 canali -EMG: 2 canali -12 partecipanti (sopravvissuti ad un ictus)	-EEG: filtri a 1-100Hz + Notch a 60 Hz e campionati a 2000 Hz -EMG: amplificati e campionati a 1000Hz	I: CMC II: CMC III: data IV: FMA-UE (upper extremity subscale of the Fugl-Meyer Assessment)	La CMC nei pazienti che hanno subito ES è più alta (p = 0.004)

*Gao et al., 2018 [19]	Dimostrare che la coerenza cortico-muscolare è bidirezionale	Flessione del gomito, afferrare 5Kg e 10Kg (5 serie da 3 ripetizioni per ogni mano)	-EEG: 32 canali a 1000Hz -EMG: 12 canali a 1000Hz -13 partecipanti (di cui 5 post ictus)	-EEG: ICA per rimuovere disturbi -EMG: WD per rimuovere disturbi	I: CS II: CS III: data IV: VS-STE	Transfer Entropy (EEG-EMG): 0.5 Transfer Entropy (EMG-EEG): 0.18
*De Venuto et al., 2017 [20]	Sistema per l'elaborazione in tempo reale di segnali EEG ed EMG per valutare l'efficacia di una terapia per il Parkinson	Camminata naturale di 10 minuti x 10 volte (5 prima del trattamento e 5 dopo)	-EEG: 8 canali a 500Hz -EMG: 8 canali a 500Hz -1 partecipante affetto da Parkinson	-	I: FFT, MRP II: Trigger signal III: data IV: CPS (Cyber-Physical System, proposto in articoli precedenti) con implementazione FPGA	-Il tempo di co-contrazione si riduce del 23.6% dopo il trattamento -il numero delle co-contrazioni si riduce del 33% dopo il trattamento
*Ben Said et al., 2017 [21]	Classificazione congiunta di segnali EEG ed EMG utilizzando un approccio deep learning	Guardare video per 40 minuti e valutarli in una scala 1-9 secondo 4 criteri (likeness, valence, arousal, dominance)	- <a href="#">DEAP dataset</a> -EEG: 23040 campioni -EMG: 23040 campioni -32 partecipanti	-	I: PSD (theta, alpha, beta, gamma) II: energia, MAV, V III: decision IV: SAE/DBM + Softmax	L'approccio multimodale studiato è in grado di ricostruire i segnali EEG/EMG con una distorsione minima (12%/13.85%)
*Li et al., 2017 [22]	Classificazione dei movimenti per migliorare il controllo di protesi per arti superiori	5 serie da 40 movimenti della mano (pronazione, supinazione, chiusura, apertura) intervallati da non movimento	-EEG: 64 canali a 1000Hz -EMG: 32 canali a 1024Hz -4 partecipanti (amputati transomerati)	-EEG: filtrati passabanda a 0.05-100 Hz + Notch -EMG: filtrati passabanda a 10- 500 Hz + Notch	I: MAV, WL, ZC, SSC II: MAV, WL, ZC, SSC III: feature IV: LDA	Accuratezza media: 91.7%
*Liang et al., 2017 [23]	Stima dei segnali EMG basandosi su segnali EEG per il controllo di dispositivi di assistenza per gli arti superiori	65 serie di flessione ed estensione della spalla con un peso di 3Kg	-EEG: 7 canali -EMG: 1 canale a 1000Hz -2 partecipanti	-EEG: filtrati passabasso a 0.1-45Hz -EMG: filtrati passabasso a 0.7Hz	I: STFT II: energia III: Ricavati da EEG IV: PCA	Coefficiente di correlazione tra EMG ottenuti e stimati: 0.9

*Kim et al., 2017 [24]	Analizzare le differenze tra EMG ed EEG nelle connessioni cortico-muscolari e applicarle nella riabilitazione post ictus	3 sessioni di 14 movimenti: afferramento con mano dx/sx (attivo, passivo, immaginario)	-EEG: 64 canali a 2048Hz -EMG: 4 canali a 2048Hz -7 partecipanti	-EEG/EMG: filtrati passabanda a 4-100 Hz + Notch	I: TDMI II: TDMI III: data IV: Coherence Analysis	La coerenza tra EEG e EMG è presente nella banda beta durante il movimento: -media: 0.0644 -deviazione standard: 0.0384
*Fernandez-Vargas et al., 2016 [25]	Ricostruire i movimenti della mano in tempo reale per amputati transomerali	8 serie di movimenti del braccio (alzare e ruotare) e del gomito (flessione ed estensione)	-EEG: 16 canali a 1024Hz -EMG: 4 canali a 1024Hz -16 partecipanti	-EEG: FFT divisa in 10 bande da 4 Hz -EMG: divisione in bande di 1s	I: SNR, FFT II: MAV, SSC, V, RMS, WL, ZC, SSC III: decision IV: ANN	Coefficiente di correlazione (per i movimenti della mano): 0.809
*Geman et al., 2016 [26]	Identificare le task mentali in pazienti neurodegenerati	4 task mentali (alzare e riporre un oggetto con occhi aperti e chiusi, rilassamento, sbattere le palpebre)	-EEG: 32/16/8 canali a 250/500Hz -EMG: 2 canali -22 partecipanti (malati di Parkinson)	-EEG: filtrati passabanda a 0.1-100 Hz +rimozione dei disturbi -EMG: rimozione dei disturbi	I: AE, CD, LLE II: AE, CD, LLE III: data IV: ANN	Accuratezza media > 90%
Xie et al., 2013 [27]	Identificare metodo per l'intenzione di movimento con la fusione di feature EEG ed EMG	Estensione e flessione del ginocchio	-EEG: 128 canali a 1000Hz -EMG: 2 elettrodi -20 partecipanti (di cui 10 con lesione del nervo periferico)	-EEG: filtrati passabanda a 0.5-75Hz -EMG: filtrati passabanda a 0.016-1000Hz	I: Multiscale Entropy (MES) II: Multiscale Entropy (MES) III: feature IV: ELM (Extreme Learning Machine)	Accuratezza: 84.4% (ictus), 85.3% (lesione nervo periferico), 98.9% (individui sani)
Leeb et al., 2011 [28]	Controllo di un hBCI indipendentemente dall'affaticamento muscolare	Movimenti della mano dx/sx seguendo le istruzioni su uno schermo (4 serie da 15 movimenti dx + 15 movimenti sx)	-EEG: 16 elettrodi -EMG: 4 canali a 512Hz -9 partecipanti	-EEG/EMG: filtro passabanda a 0.1-100Hz + Notch	I: PSD II: Media e deviazione standard III: decision IV: Simple Fusion	Accuratezza: -affaticamento 10%: 90% -affaticamento 50%: 85% -affaticamento 90%: 73%

Rocon et al., 2010 [29]	mBCI per la soppressione dei tremori degli arti superiori grazie alla stimolazione elettrica	Toccare il naso con il dito indice dopo aver sentito un segnale acustico (movimento usato per stimolare il tremore)	-EEG: 3 elettrodi -EMG: 128 canali - 12 partecipanti (con tremore patologico)	-EEG: filtri passabanda	I: ERD II: Potenza ed energia III: decision IV: Frequency Fourier Linear Combiner	Stima dell'errore dell'ampiezza del tremore: $0,001 \pm 0,002$ rad/s
*Yang et al., 2010 [30]	Analizzare coerenza di segnali EEG-EMG e la loro potenza	Impugnare e contrarre mano (1 sessione da 200 movimenti)	-EEG: 64 canali a 250Hz -EMG: 2 canali -8 partecipanti	-EMG: filtri passabanda 1-1000 Hz	I: WTC, WES II: WTC, WES III: data IV: Coherence Analisys	Coerenza: 0.8 Coerenza con affaticamento muscolare < 0.8

Tabella 3.1: \*dataset disponibile online

## 3.2 Feature e algoritmi più utilizzati

Una feature è una misura distintiva estratta da un segmento di un pattern di dati, la loro estrazione semplifica la quantità di risorse necessarie per descrivere con precisione un'ampia serie di dati. Ciò è necessario per ridurre al minimo la complessità dell'implementazione, per ridurre i costi di elaborazione delle informazioni e per annullare la potenziale necessità di comprimere le informazioni. L'estrazione delle feature ha lo scopo di scegliere le caratteristiche o le informazioni più importanti che sono utili per la classificazione [10].

In questa sezione vengono analizzati le feature principali estratte da EEG/EMG e gli algoritmi utilizzati per l'estrazione.

### 3.2.1 Feature nel dominio del tempo

Le feature estratte dal dominio del tempo trovano maggior interesse nell'analisi dei segnali EMG [1, 8, 12] ma vengono usate anche per segnali EEG [1, 22] perché sono veloci da calcolare in quanto non richiedono alcuna trasformazione. Vengono calcolate analizzando l'ampiezza dei segnali d'ingresso, e i valori risultanti forniscono una misura dell'ampiezza, della frequenza e della durata della forma d'onda.

Dato un segnale  $x = [x_1, x_2, \dots, x_n, x_{n+1}, \dots, x_N]$ , con  $N$  il numero complessivo di campioni, le principali feature estratte dal dominio del tempo sono le seguenti:

*Media*: media dei valori dell'ampiezza del segnale nell'arco della sua durata.  $\mu = \frac{1}{N} \sum_{i=1}^n x_i$

*Varianza*:  $V = \frac{1}{N} \sum_{i=1}^n (x_i - \mu)^2$

*Mean Absolute Value (MAV)*:  $MAV = \frac{1}{N} \sum_{i=1}^n |x_i|$

*Standard Deviation (SD)*:  $SD = \sqrt{\frac{1}{N} \sum_{i=1}^n (x_i - \bar{x})^2}$

*Waveform Length (WL)*:  $WL = \sum_{i=1}^{n-1} |x_{i+1} - x_i|$

*Root Mean Square (RMS)*:  $RMS = \sqrt{\frac{1}{N} \sum_{i=1}^n |x_i|^2}$

*Slope Sign Change (SSC)*: numero di volte in cui la pendenza del segnale cambia. Si può usare una soglia (*threshold*) per eliminare il rumore del segnale:

$$SSC = \sum_{n=2}^{N-1} [f[(x_n - x_{n-1}) \cdot (x_n - x_{n+1})]]$$

$$f(x) = \begin{cases} 1, & \text{se } x \geq \text{soglia} \\ 0, & \text{altrimenti} \end{cases}$$

*Zero Crossing (ZC)*: numero di volte in cui il segnale passa per lo zero. Si può usare una soglia per eliminare il rumore:

$$ZC = \sum_{n=1}^{N-1} [\text{sgn}(x_n \times x_{n+1}) \cap |x_n - x_{n+1}| \geq \text{soglia}];$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{se } x \geq \text{soglia} \\ 0, & \text{altrimenti} \end{cases}$$

*Mean Power Frequency (MPF)*: frequenza media espressa come somma dei prodotti tra frequenze e potenze dell'*i*-esimo campione, divisa per la somma delle potenze.

$$MPF = \frac{\sum_{i=1}^M f_i \mathcal{P}_i}{\sum_{i=1}^M \mathcal{P}_i}$$

dove  $\mathcal{P}_i$  è l'*i*-esimo campione della potenza spettrale,  $f_i$  è la variabile di frequenza e  $M$  è l'armonica più alta considerata.

### 3.2.2 Feature nel dominio della frequenza

Le feature estratte nel dominio della frequenza vengono ricavate dalla potenza spettrale dei segnali (PSD), calcolata nelle diverse bande di frequenza descritte nel capitolo 2.1.

Queste feature, a differenza di quelle nel dominio del tempo, richiedono più risorse computazionali e per questo il loro uso è minore [33].

Le due feature principali estratte dal dominio della frequenza, oltre alla potenza spettrale sono:

*Frequency Mean (FMN)*:

$$FMN = \frac{\sum_{i=1}^M f_i PSD_i}{\sum_{i=1}^M PSD_i}$$

$$f_i = \frac{i \cdot \text{SampleRate}}{2M}$$

dove  $M$  è la lunghezza della PSD e  $i$  l'*i*-esimo campione della PSD.

*Frequency Median (FMD):*  $FMD = \frac{1}{2} \sum_{i=1}^M PSD$  con  $i$  ed  $M$  definiti come sopra.

Queste feature vengono estratte con maggior probabilità dai segnali EMG essendo state associate a fenomeni quali la fatica muscolare.

Le feature più usate in tutti i campi dell'analisi di segnali EEG invece sono le potenze relative alle bande di frequenza (delta, theta, alpha, beta e gamma), ma anche diversi rapporti tra le bande di frequenza sono ampiamente utilizzati come feature nell'analisi del segnale, ovvero  $\frac{\theta}{\alpha}$ ,  $\frac{\beta}{\alpha}$ ,  $\frac{\theta+\alpha}{\beta}$ ,  $\frac{\theta}{\beta}$ ,  $\frac{\theta+\alpha}{\alpha+\beta}$ ,  $\frac{\gamma}{\delta}$  e  $\frac{\gamma+\beta}{\delta+\alpha}$  [31].

Le feature estratte dalle bande di frequenza hanno un ruolo fondamentale nello studio dei segnali EEG perché sono collegate alla connettività funzionale. Ciò giustifica la necessità di un accurato filtraggio dei segnali, che eviti di filtrare le frequenze rilevanti, e suggerisce la possibilità di classificare le interazioni funzionali in base alla frequenza in cui la connettività tra due aree è più forte. [38]

### 3.2.3 Algoritmi per l'estrazione di feature

Di seguito sono elencati e descritti gli algoritmi più efficienti e quindi più usati per estrarre le feature precedentemente elencate.

**a. PCA (Principal Component Analysis):**

Analizza dataset molto grandi e ne facilita l'interpretazione riducendo le dimensioni del dataset senza perdere le informazioni [23]. I dati sono proiettati su assi ortogonali distribuiti in ordine di importanza. Questo metodo si basa sulla varianza dei segnali quindi uno svantaggio è che può portare alla classificazione sbagliata.

**b. ICA (Independent Component Analysis):**

Come PCA, riduce le dimensioni di un dataset. L'input sono delle componenti indipendenti che l'algoritmo cerca di identificare correttamente eliminando eventuali rumori [9].

**c. CSP (Common Spatial Pattern):**

Il presente metodo di estrazione si basa sul calcolo di un gruppo di filtri che rendono maggiore la varianza di una classe di segnali e riducono quella di un'altra classe di segnali. I segnali

sono definiti come una matrice  $E$  di dimensioni  $N \times T$ , dove  $N$  è il numero di canali e  $T$  sono i punti di campionamento. Successivamente vengono calcolate le matrici di covarianza normalizzate corrispondenti ai movimenti della parte destra e sinistra del corpo e sommate per ottenere la matrice di covarianza composta  $C_0 = C_l + C_r$ , che con la decomposizione degli autovalori può essere scritta come  $C_0 = U_0 \lambda_0 U_0^T$  dove  $U_0$  è la matrice degli autovalori e  $\lambda_0$  è l'autovalore diverso da zero della matrice diagonale. Attraverso una trasformazione lineare della matrice di covarianza si ottiene  $P = \lambda^{-1/2} U_0^T$ , e di conseguenza la matrice proiettiva  $W = U_c^T P$ . A questo punto i dati forniti dai segnali vengono trasformati nella matrice feature  $Z = WE$  [11].

**d. ERD/ERS (Event-Related Desynchronization/Synchronization):**

Si tratta di un'analisi che viene effettuata per valutare l'aumento delle onde cerebrali a seconda della frequenza. In particolare, si calcola la diminuzione/aumento percentuale della potenza in una specifica banda di frequenza a seguito di un movimento [8].

**e. BP (Back Propagation):**

Si usa per propagare la perdita di dati nel Neural Network, in modo da conoscere qual è la perdita di dati di ogni nodo della rete neurale. In questo modo è possibile sistemare il peso dei vari nodi per far sì che la perdita di dati sia minore possibile [13].

**f. Autoencoders:**

Sono degli algoritmi di machine learning che vengono usati sia per l'estrazione di feature che per la classificazione: viene compresso il dato eliminando il rumore e si cerca di riprodurre il dato originale basandosi su quello compresso.

Gli autoencoder, essendo un tipo speciale di rete neurale sono formati da tre livelli; i dati vengono forniti all'input, propagati al secondo livello e ricostruiti nel terzo [21].

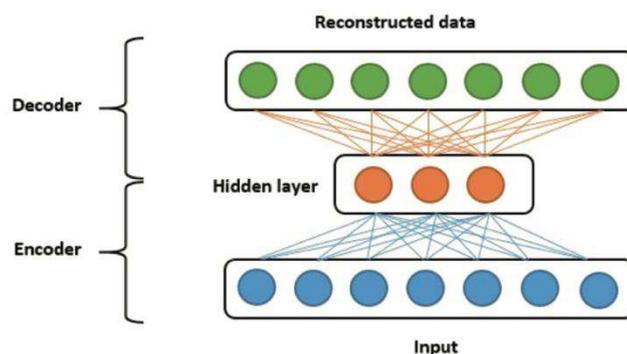


Figura 3.1: Rappresentazione schematica di un autoencoder. (Tratta da [21])

L'encoder trasforma i vettori  $x \in R^X$  in una rappresentazione  $h \in R^H$  attraverso una funzione  $f : h = f(Wx + b)$ . Il decoder ritrasforma  $h$  in una rappresentazione  $r \in R^R$ , che fa parte del terzo livello, attraverso una funzione  $g : r = g(W'h + b')$ .

**g. AR Coefficients:**

Metodo per l'estrazione di feature da segnali biologici.

Cerca di modellare il segnale grazie ai punti forniti da quest'ultimo:

$$x[n] = - \sum_{k=1}^p a_k x[n-k] + e[n]$$

dove  $p$  è il grado del modello AR,  $x[n]$  è il segnale compost di  $n$  punti,  $a_k$  è il coefficiente AR e  $e[n]$  è un termine che rappresenta il rumore bianco. Il problema di questo metodo è scegliere il grado corretto dal momento che un grado troppo basso non rappresenta il segnale correttamente ma uno troppo alto incorpora troppo rumore [31].

**h. FFT (Fast Fourier Transform):**

È un algoritmo che determina la Discrete Fourier Transform (DFT) molto più velocemente che calcolandola direttamente e ne riduce la complessità a  $O(N \log N)$ . È debole nell'analisi di segnali non stazionari come le EEG ma è veloce e può essere utilizzata per le applicazioni in tempo reale [20].

**i. WT (Wavelet Transform):**

È un metodo di estrazione delle feature usato quando si devono analizzare biosegnali. Grazie a questo metodo una qualsiasi funzione può essere espressa come una serie infinita di forme d'onda oscillanti. Può essere continua o discreta.

Nel caso continuo

$$CWT(a, b) = \int_{-\infty}^{\infty} x(t) \psi_{a,b}^*(t) dt$$

dove  $x(t)$  è il segnale non processato,  $a$  è la dilatazione e  $b$  la traslazione. Il complesso coniugato è

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right)$$

dove  $\psi(t)$  è l'onda oscillante. Lo svantaggio principale è che  $a$  e  $b$  cambiano continuamente. Nel caso discreto l'onda viene definita sulla base di una rappresentazione multiscale.

Si tratta del metodo migliore perché è il più adatto per l'analisi di cambiamenti dei segnali improvvisi e transitori e di pattern di dati irregolari [15].

Oltre agli algoritmi e ai metodi di estrazione delle feature elencati qui sopra, che vengono usati per estrarre le feature separatamente, vi sono due metodi che estraggono feature da EEG + EMG e che vengono usati quando la fusione è a livello di dati (*data-fusion*):

#### A. CA (Coherence Analysis):

Si effettua per esaminare le proprietà lineari dell'associazione tra muscoli e cervello durante il movimento.

I segnali vengono convertiti in componenti della frequenza e se ne calcolano *auto-spectrum* e *cross-spectrum* per poi calcolare la coerenza  $Coh_{x,y}(f)$

$$S_{xx}(f) = \frac{1}{n} \sum_{i=1}^n X_i(f) X_i^*(f)$$

$$S_{xy}(f) = \frac{1}{n} \sum_{i=1}^n X_i(f) Y_i^*(f)$$

$$Coh_{x,y}(f) = \frac{|S_{xy}(f)|^2}{S_{xx}(f) \times S_{yy}(f)}$$

Il significato del valore di coerenza (CL) è determinato da

$$Confidence\ limit = 1 - (1 - \alpha)^{1/(L-1)}$$

dove  $\alpha$  è un intervallo di affidamento del 95%, e L è il numero di segmenti di dati utilizzati nel calcolo della coerenza [18].

#### B. MI (Mutual Information Analysis):

Meno usata nell'analisi di segnali EEG ed EMG rispetto alla CA.

È correlata al concetto di entropia di un segnale, infatti questa analisi consiste nell'usare le informazioni fornite da una variabile (nel nostro caso EEG/EMG) per ricavare le informazioni riguardanti l'altra variabile (rispettivamente EMG/EEG) [23].

### 3.3 Fusion level e metodi di classificazione

Lo step successivo all'estrazione delle feature è la classificazione, in cui vengono elaborate le feature grazie a degli algoritmi che nel caso dello studio di segnali cortico-muscolari permettono di identificare il movimento. Dall'analisi degli articoli fatta per questa review si distinguono in termini di performance alcuni classificatori.

**a. SVM (Support Vector Machine):**

Questo classificatore può essere utilizzato con segnali lineari ma anche non lineari. Si basa sul costruire un iperpiano che viene usato come superficie decisionale per identificare le diverse classi così da massimizzare lo spazio tra una classe e l'altra [10].

**b. LDA (Linear Discriminant Analysis):**

È efficace per la classificazione di EEG ed EMG per i bassi requisiti computazionali. Lo scopo di questa analisi è quello di massimizzare la distanza tra le medie delle classi di dati e minimizzarne la deviazione standard [11].

Questa analisi prevede una classificazione di soglia basata su

$$(\vec{x}, \vec{w}) > c$$

dove  $\vec{x}$  è il dato da classificare,  $\vec{w}$  è un vettore normalizzato che definisce le classi di separazione dell'iperpiano e  $c$  è la costante di soglia. Successivamente  $\vec{w}$  e  $c$  sono calcolati:

$$\vec{w} = \Sigma^{-1}(\vec{\mu}_1 - \vec{\mu}_0),$$
$$c = \frac{1}{2}(T - \vec{\mu}_0^T \Sigma^{-1} \vec{\mu}_0 + \vec{\mu}_0^T \Sigma^{-1} \vec{\mu}_1)$$

dove  $\Sigma$  è la covarianza,  $\vec{\mu}_0, \vec{\mu}_1$  sono le medie delle classi da separare e  $T$  è la soglia scelta.

**c. kNN (K-Nearest Neighbor):**

Vengono calcolate le distanze di uno dei campioni della classe di prova rispetto a tutti i campioni della classe. La distanza minore dal campione fornisce la classe del campione di prova.

Il classificatore kNN prende in considerazione i k numeri più vicini al campione e usa la regola della maggioranza. k di solito è un numero piccolo e dispari. Un k maggiore aiuta a ridurre l'impatto del rumore del segnale ma aumenta la difficoltà di calcolo [5].

**d. CNN (Convolutional Neural Network):**

Questo modello, inizialmente sviluppato per l'elaborazione di immagini, ha dimostrato di essere molto preciso e di poter essere utilizzato anche per la classificazione di segnali bioelettrici. [6]

Il suo funzionamento prevede l'utilizzo di livelli di convoluzione che estraggono informazioni dalle immagini prima di inserirle nei tradizionali livelli dei network neurali. Esso non è solo in grado di apprendere dei modelli dai dati, come accade solitamente nel machine learning, ma impara automaticamente quali sono le informazioni rilevanti da estrarre dai dati in ingresso (invece di fare affidamento sulla selezione da parte dell'utente delle feature da utilizzare) [6].

Per trasformare il segnale vengono usati due metodi:

- Organizzare i segnali processati nel dominio del tempo per creare un'immagine del segnale;
- Calcolare la rappresentazione del segnale nel dominio del tempo e della frequenza per generare l'immagine.

**e. ANN (Artificial Neural Network):**

Le ANN sono reti elettroniche di neuroni basate sulla struttura neurale del cervello. Elaborano i dati uno alla volta, e imparano confrontando la classificazione dei dati (arbitraria) con una classificazione conosciuta; in seguito, gli errori della classificazione iniziale vengono reinseriti nella rete e usati per modificare l'algoritmo della rete per le successive iterazioni [15].

Un neurone in una ANN può essere rappresentato da:

- Un set di valori ( $x_i$ ) e il loro peso associato ( $w_i$ )
- Una funzione ( $g$ ) che somma i pesi e mappa i risultati in un output ( $y$ )

I neuroni sono organizzati in livelli: input, hidden, output.

L'input non è composto da neuroni ma dai valori dei dati che fanno da input al livello successivo. L'hidden sono i livelli successivi all'input, che possono essere molteplici. L'output è il livello dove sono presenti i nodi di ogni classe di dati. Un passo in avanti nella rete comporta l'assegnazione di un valore ad ogni nodo presente nell'output, e il dato è assegnato al nodo della classe con il valore più alto.

**f. MLP (Multilayer Perceptron):**

È una rete neurale che collega più livelli per mezzo di un grafo diretto, che significa che il percorso del segnale attraverso i nodi può avere una sola direzione. Ogni nodo, esclusi quelli

di input, ha una funzione di attivazione che non è lineare [15]. L'MLP utilizza come metodo di apprendimento la BP e poiché esistono più livelli di neuroni è una tecnica di deep learning.

**g. LSTM (Long Short-Term Memory):**

È un'implementazione del RNN (Recurrent Neural Network) ed è particolarmente efficace nel classificare EEG ed EMG per risalire alle fasi del gait [7].

**h. BC (Bayesian Classifier):**

È basato sull'idea che, se il sistema conosce la classe di appartenenza delle feature, ne riesce a predire il valore. Se invece la classe è sconosciuta usa Bayes per riconoscerla. Il sistema costruisce un modello probabilistico delle feature. La regola di Bayes può essere espressa in questo modo

$$P(h|D) = \frac{P(D|h)P(h)}{P(D)}$$

$P(D|h)$  è la probabilità che  $D$  contenga l'ipotesi  $h$  e  $P(h|D)$  è la probabilità a posteriori ovvero la probabilità che sia verificata l'ipotesi [33]. Lo svantaggio che ne deriva concerne l'elaborazione di assunzioni forti sulla distribuzione dei dati ma può essere utile quando si usa una combinazione di classificatori.

### 3.4 Dataset e acquisizione di segnali

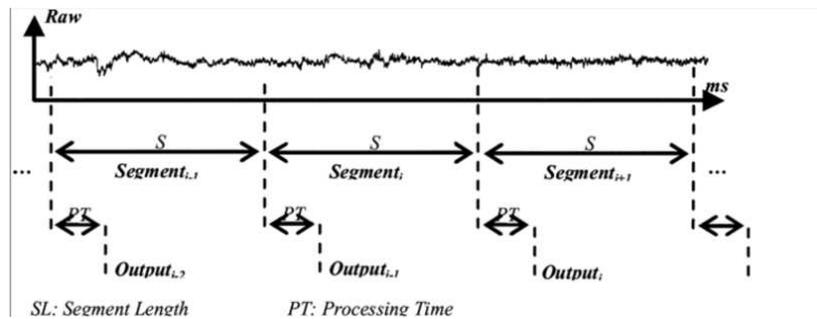
L'acquisizione di segnali EMG viene effettuata posizionando degli elettrodi in corrispondenza dei muscoli coinvolti nei movimenti analizzati dallo studio secondo due modalità: invasiva (nella quale gli elettrodi vengono inseriti sottopelle) e non invasiva (gli elettrodi sono superficiali).

Per ottenere i segnali EEG invece, vengono posizionati degli elettrodi secondo la configurazione standardizzata 10-20 [31] introdotta nel capitolo 2.1.

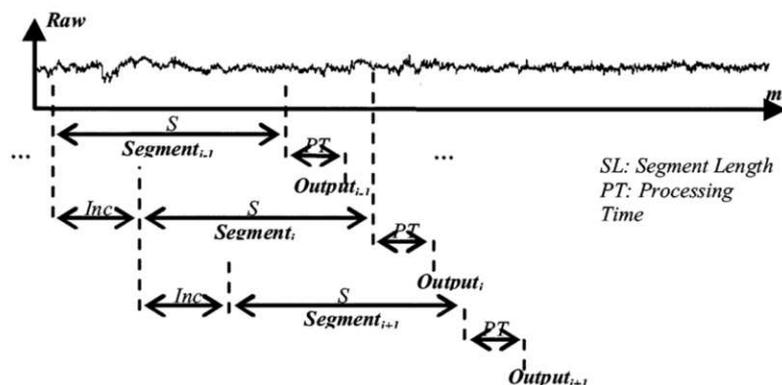
A seconda del tipo di studio che viene condotto sono presenti più o meno canali che registrano i segnali ad una frequenza decisa anch'essa dal tipo di analisi che si desidera effettuare. Il numero di canali influenza la precisione dei dati, ma è uno svantaggio nel momento in cui l'analisi viene effettuata per lo sviluppo di dispositivi quali protesi/ortesi per la riabilitazione poiché rendono il setup più invasivo e meno utilizzabile dal paziente.

I dati grezzi raccolti dagli elettrodi vengono segmentati prima dell'estrazione delle feature, secondo due modalità [34], illustrate nelle figure 3.2 e 3.3.

- disgiunta*: le lunghezze dei segmenti sono predefinite
- con sovrapposizione*: l'intervallo di tempo tra due segmenti è minore della lunghezza del segmento



(a) Figura 3.2: Segmentazione disgiunta. (Tratta da [34])



(b) Figura 3.3: Segmentazione con sovrapposizione. (Tratta da [34])

I segnali acquisiti dagli elettrodi portano, oltre all'informazione, anche interferenze e disturbi dovuti a vari fattori (es. sbattimento delle palpebre, movimenti incontrollati); per questo motivo prima di estrarre le feature viene effettuato un pre-processing che non ha una pipeline predefinita perciò viene scelto quello più adatto allo scopo dello studio [2]. Solitamente consiste nel filtrare i segnali segmentati e per farlo sono utilizzati quattro tipi di filtri:

- *passa-basso*: vengono rimosse le frequenze maggiori della frequenza scelta
- *passa-alto*: vengono rimosse le frequenze minori della frequenza scelta
- *passa-banda*: vengono rimosse le frequenze maggiori e minori della banda di frequenza selezionata
- *Notch*: rimuove una singola frequenza

Dall'analisi degli articoli riportati in tabella il filtro maggiormente usato è il Notch, combinato con uno degli altri tre. Il motivo è da ricercare nel fatto che ad ogni tipo di disturbo corrisponde una determinata frequenza ed il filtro Notch aiuta ad eliminarli in modo mirato.

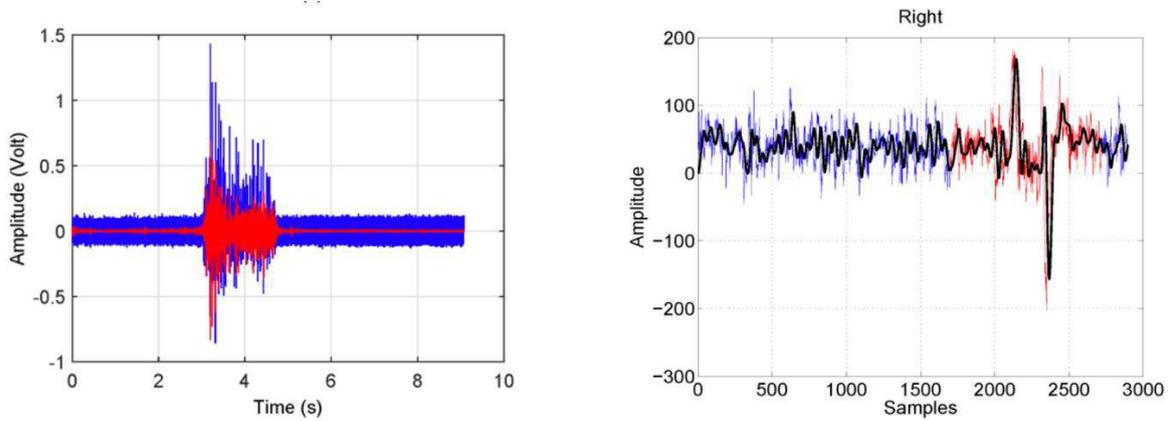


Figura 3.4: A sinistra un esempio di segnale EMG prima (blu) e dopo (rosso) averlo filtrato, a destra un esempio di segnale EEG prima (blu/rosso) e dopo (nero) averlo filtrato. (Tratta da [15])



# Capitolo 4: Discussione

---

## 4.1 Confronto sulle modalità di fusione dei dati

Come descritto nel capitolo 2.4 esistono tre modalità di fusione dei dati provenienti da sensori (in questo caso elettrodi) per l'interpretazione di segnali EEG ed EMG.

A livello di fusione dei dati il metodo più utilizzato per definire l'interazione cortico-muscolare è il calcolo della MSC (Mean Spectral Coherence). È stato dimostrato che la MSC fornisce una buona stima dell'interazione tra segnali cerebrali e muscolari se viene calcolata basandosi su più segmenti di dati [37].

In [17] viene stimata la relazione tra EEG ed EMG attraverso un metodo chiamato *Correlation Between the band-limited Power Time-courses* (CBPT), nel quale la dipendenza tra i due segnali (EEG/EMG) viene calcolata come correlazione: quando viene eseguita un'azione motoria, si verifica una sincronizzazione/desincronizzazione del ritmo sensomotorio (SMR) nella corteccia cerebrale. Allo stesso tempo l'attività delle EMG aumenta in corrispondenza del muscolo coinvolto nel movimento; calcolando la correlazione tra segnali durante i cambiamenti dell'SMR si ottiene un indice di interazione tra i due.

A differenza del MSC, che esamina le interazioni in una sola banda di frequenza, il CBPT riesce ad analizzare i cambiamenti corrispondenti ad un fenomeno cortico-muscolare su diverse bande di frequenza [17]. In aggiunta, raggiunge delle performance migliori in termini di accuratezza (92.81% nei pazienti sani e 84.53% nei pazienti che hanno avuto un ictus a differenza della CMC che raggiunge il 72.81% nei pazienti sani e il 69.53% nei pazienti con ictus) anche in caso di una classificazione basata su una singola task, il che è molto importante per l'uso di una Brain Computer Interface (BCI) finalizzata alla riabilitazione [17].

Nella figura 4.1 viene illustrato il calcolo della coerenza attraverso il metodo appena descritto.

Il classificatore CNN viene usato solitamente nella fusione a livello di feature e a livello di decisione. In [6] si verifica che può essere usato anche come tecnica di data-fusion. I segnali EEG-EMG vengono registrati simultaneamente e usati per sviluppare dei modelli CNN basati sul tempo-frequenza (spettrogrammi) e sul tempo (segnale filtrato).

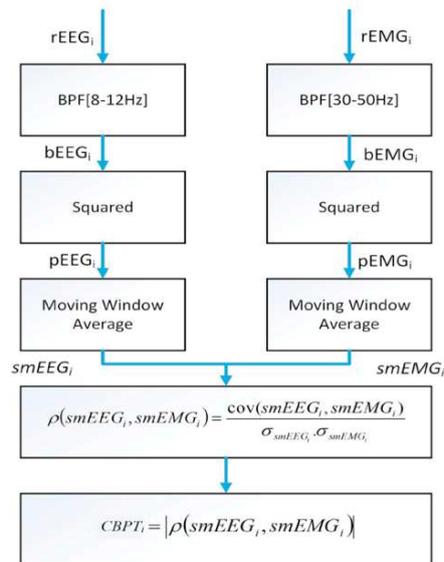


Figura 4.1: Calcolo della feature con CBPT. (Tratta da [17])

I tre modelli analizzati in [6] sono i seguenti:

- Raggruppato (*grouped*): i canali dei segnali dello stesso tipo vengono raggruppati insieme alla loro immagine in modo che la convoluzione avvenga inizialmente solo tra segnali dello stesso tipo;
- Misto (*mixed*): i canali EEG ed EMG vengono alternati per mischiare i tipi di segnale;
- *Stacked*: uno spettrogramma multicanale combina i diversi spettrogrammi dei segnali EEG ed EMG.

Successivamente viene studiata la classificazione di tutti i modelli CNN (spettrogrammi e segnali) e viene selezionato il modello migliore che in questo caso è quello raggruppato, che raggiunge un'accuratezza di  $80.51 \pm 8.07\%$  [Figura 4.2].

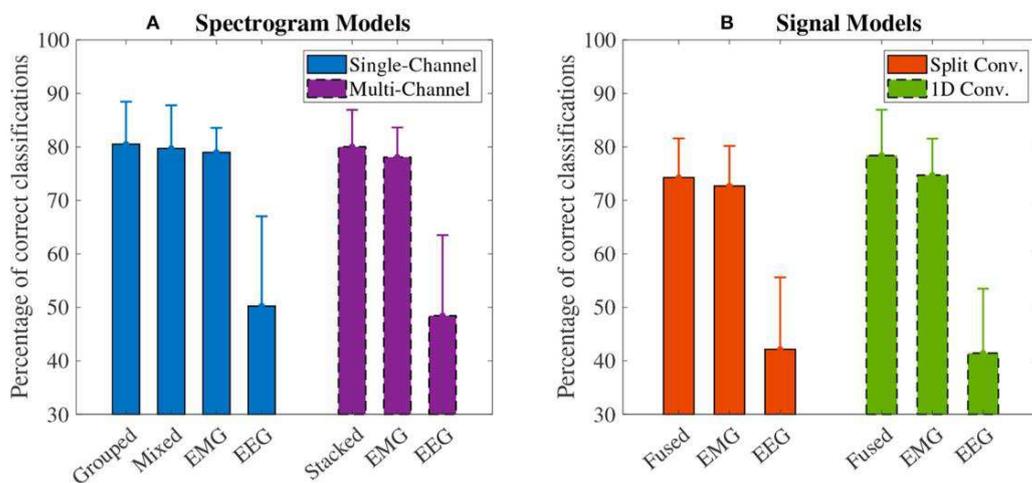


Figura 4.2: Confronto tra performance dei tre modelli proposti in [6] nel caso di spettrogrammi (a sinistra) e segnali filtrati (a destra). (Tratta da [6])

In [4] viene effettuata un'analisi di coerenza a livello di dati usando la WT per studiare le caratteristiche di omologia tra segnali EEG ed EMG.  $x(t)$  e  $y(t)$  rappresentano rispettivamente le sequenze di segnali EEG ed EMG. La *Wavelet Coherence* viene calcolata come

$$Wco_{xy}(a, b) = \frac{|S(W_{xy}(a, b))|}{\sqrt{S(|W_x(a, b)|^2)S(|W_y(a, b)|^2)}}$$

È un valore che ha un range [0, 1]: più è alto più è forte la coerenza tra i due segnali.

In [5] vengono comparati quattro metodi per la combinazione di feature (unidimensionale, bidimensionale, 21-dimensionale, 37-dimensionale) e la successiva classificazione delle fasi del gait, analizzando la loro efficacia. Il gait è lo studio del movimento di un individuo e viene usata nella riabilitazione per valutarne i progressi.

L'accuratezza migliore ( $98.56 \pm 1.34\%$ ) è quella del set 37-dimensionale classificato con KSVM.

Lo svantaggio di un set di feature così esteso è quello di aver bisogno di un tempo di esecuzione molto più alto rispetto agli altri set di feature e quindi non poterlo applicare in tempo reale ma solo off-line [5] (vedi Figura 4.3).

Classifier	Execution time (s)				
	One-dimensional feature set	Two-dimensional feature set	Twenty-one-dimensional feature set	Thirty-seven-dimensional feature set	Average
LDA	0.35	0.34	-	-	0.35
KNN	0.47	0.33	-	-	0.40
GS-KSVM	-	-	17.51	26.37	21.94
GA-KSVM	-	-	210.08	100.62	155.35
PSO-SVM	-	-	76.19	92.87	84.53

Figura 4.3: Confronto tra tempi di esecuzione dei classificatori sulle diverse combinazioni di feature. (Tratta da [5])

A livello di decision-level-fusion il classificatore migliore sia per segnali EEG che EMG risulta LSTM, che è basato su un Recurrent Neural Network.

La classificazione di segnali EEG è più complessa rispetto a quella di segnali EMG, poiché l'EEG ha un SNR molto più basso. L'EMG di un soggetto sano riesce a dare accuratezze oltre l'80%, mentre con l'utilizzo del solo EEG è molto difficile da raggiungere.

In [1] viene proposto un algoritmo per la decision-level-fusion che recupera le informazioni più efficaci dai due tipi di segnali basandosi sul grado di rumorosità dei segnali e sul peso dei risultati della classificazione (raggiungendo un'accuratezza del 89.7%): quando i dati EEG sono contaminati dà priorità al classificatore EMG, se i dati EMG sono leggermente contaminati dà comunque priorità al classificatore EMG avendo quest'ultimo un peso maggiore, mentre nel caso in cui i dati EMG siano contaminati in modo significativo dà la priorità al classificatore EEG.

In [12] si sviluppa un modello multimodal Human-Machine Interface (mHMI) che usa ERD/ERS e combina segnali EEG, EMG ed EOG sfruttando i vantaggi di ogni modalità per superare gli svantaggi e classificare nel modo più preciso possibile i movimenti (accuratezza 93.83%).

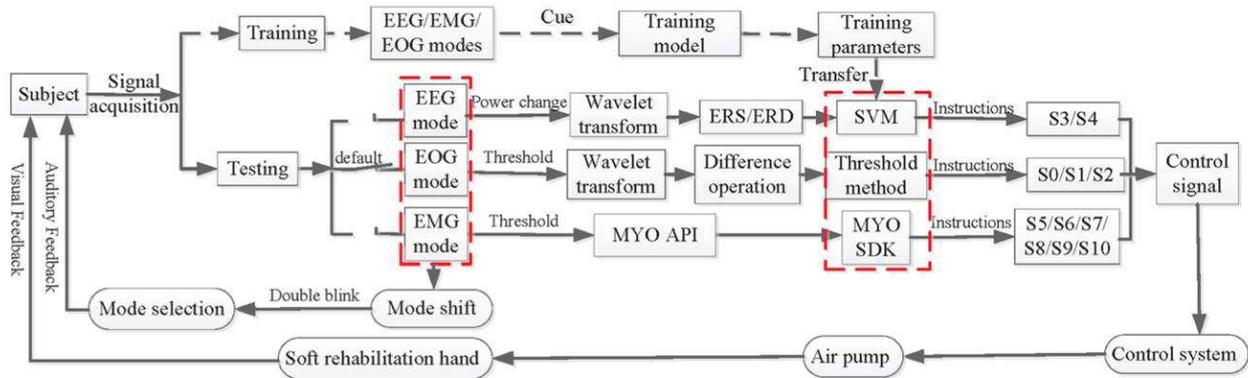


Figura 4.4: Modello mHMI proposto in [12]. (Tratta da [12])

Un altro mHMI viene proposto in [7], in particolare vengono usate due reti neurali LSTM parallele allenate da segnali EEG ed EMG per predire i movimenti degli arti inferiori. Le previsioni di entrambe le reti vengono integrate usando il metodo Bayesiano di fusione basato sull'incertezza di ogni classificatore. Questo garantisce delle performance più stabili, adattando i parametri di fusione ai cambiamenti dell'affidabilità dei segnali in ingresso. In breve, la rete EEG riconosce se il soggetto sta facendo un passo in avanti, mentre la rete EMG riconosce se il soggetto sta usando la gamba destra/sinistra. La classe  $c_i$  con  $Bel(c_i)$  maggiore viene scelta come decisione finale della classificazione. Nella figura 4.6 viene riportato l'approccio appena descritto nel caso in cui sia EEG che EMG prevedano la classe di appoggio (*stance*), ma le stesse considerazioni possono essere fatte se le due reti vengono usate per prevedere la classe di oscillazione/sospensione (*swing*).

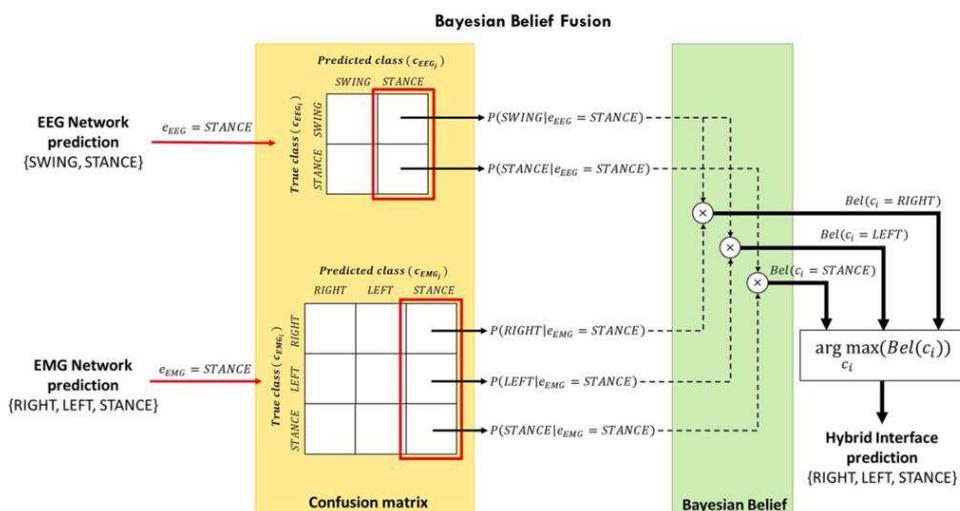


Figura 4.5: Modello mHMI proposto in [7]. (Tratta da [7])

La scelta di un livello di fusione piuttosto che un altro dipende dallo scopo dello studio. Il data-fusion-level viene scelto quando il modello sviluppato per la classificazione necessita come input la coerenza tra i due segnali, che può essere calcolata attraverso diversi metodi (es. WT, MSC) e in generale è il meno utilizzato tra i tre. Il feature-fusion-level è quello più utilizzato dal momento che il calcolo e la fusione delle feature richiede poco tempo e i modelli che la usano vengono utilizzati sia per lo studio/controllo ma anche per applicazioni pratiche. In termini di performance è accurato e la classificazione può essere fatta sia in tempo reale che off-line. Il decision-level-fusion viene utilizzato principalmente per lo sviluppo di hBCI [28, 29] e più recentemente per mHMI [7, 11, 12]. Le hBCI sono promettenti dal punto di vista dell'applicazione pratica perché riescono a garantire un'analisi in tempo reale dell'intenzione di movimento, essendo un'applicazione di diversi tipi di fusion tra EEG ed EMG.

## **4.2 Motivazioni per l'uso combinato di segnali EEG ed EMG**

Lo studio combinato di segnali EEG ed EMG viene effettuato per motivi diversi tra i quali la creazione di protesi ed ortesi per persone la cui mobilità è stata compromessa da amputazioni o problemi neurologici [8, 10, 12, 26], il controllo dei tremori e dei movimenti involontari dovuti a patologie [14, 18, 20] ma anche lo studio delle fasi del cammino [3, 5, 7].

Usare singolarmente segnali muscolari e cerebrali ha dimostrato di essere meno accurato della loro combinazione [15, 24, 27]. L'EEG si dimostra essere meno preciso dell'EMG e necessita di essere adattato al paziente per aumentarne la precisione. D'altra parte l'EMG non è accurata nel momento in cui la persona soffre di patologie che compromettono la forza muscolare [15].

Per questo motivo negli ultimi anni sono stati effettuati vari studi che hanno cercato di creare dei modelli ibridi Brain Computer Interface (hBCI) [13] per il rilevamento dell'intenzione di movimento. Le hBCI sono delle interfacce neurali che interpretano i segnali forniti dai muscoli e dal cervello per controllare dispositivi robotici riabilitativi.

I segnali provenienti da cervello e muscoli sono spesso misurati e trattati simultaneamente perché sono correlati tra loro. In [19], attraverso un'analisi VS-STE (Variable Scale Symbolic Transfer Entropy) viene provato che la coerenza cortico-muscolare è bidirezionale. Nei soggetti che hanno subito un ictus la quantità di dati trasmessi dal cervello ai muscoli per completare un movimento è

maggiore, il che dimostra che devono essere attivate più aree cerebrali per mantenere una stabilità di movimento [19]. Allo stesso tempo anche i segnali dai muscoli al cervello aumentano, probabilmente perché sono stati subiti dei danni alla parte della corteccia adibita alle funzioni motorie che impedisce di usarla in modo corretto. Questo studio prova che i segnali EEG ed EMG sono strettamente correlati tra loro e per questo motivo l'accuratezza di un'analisi aumenta nel momento in cui vengono studiati contemporaneamente.

Il controllo di dispositivi per la riabilitazione attraverso segnali EEG o EMG analizzati separatamente ha più applicabilità nel campo della riabilitazione; la rilevazione accurata dell'intenzione di movimento grazie alle EEG è molto importante nei soggetti disabili con scarsa attività muscolare e che hanno appena iniziato la riabilitazione, mentre i segnali EMG sono più adatti a soggetti in cui l'attività muscolare è presente o che sono già nelle fasi finali del percorso riabilitativo. Nel primo caso, il valore della correlazione tra il movimento reale e quello ricostruito è troppo basso e nei casi migliori raggiunge un valore di 0.6 [23].

Nel momento in cui si studia un approccio a qualsiasi livello di fusione (data, feature, decision) o la performance di un classificatore, il risultato prova che sia nei pazienti sani che in quelli malati l'accuratezza è maggiore quando si usa la combinazione di segnali EEG+EMG piuttosto che i segnali singoli [27].

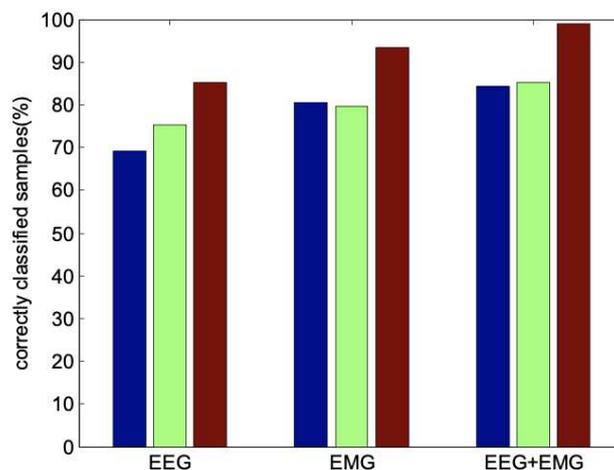


Figura 4.6: Il blu rappresenta i pazienti che hanno avuto un ictus, il verde i pazienti con disabilità traumatiche, il rosso i soggetti sani. (Tratta da [27])

In [23] e [9] viene studiato un nuovo approccio per stimare i segnali EMG dai segnali EEG. Con PCA si estraggono le componenti relative al movimento dai segnali EEG, la relazione tra EEG ed EMG viene espressa come equazione lineare da PCA e infine il segnale EMG viene stimato (vedi figura 4.7). Il modello creato per stimare EMG da EEG è lineare e viene descritto come

$$F = E' \cdot X = [E_{v1}, E_{v2}, E_{vy}] \cdot [z_1, z_2, y]^T$$

dove ogni componente principale  $f_v (v = 1,2)$  è una combinazione lineare di segnali EEG ed EMG, e il peso della combinazione lineare sono gli autovettori  $E_{v1}, E_{v2},$  e  $E_{vy} (v = 1,2)$  che corrispondono rispettivamente alle componenti principali del segnale EEG  $z_u (u = 1,2)$  e al segnale EMG misurato  $y$ .

In questo modo si dimostra il potenziale di utilizzo dei segnali EEG; affiancati agli EMG posso essere utili nello sviluppo di BCI [23].

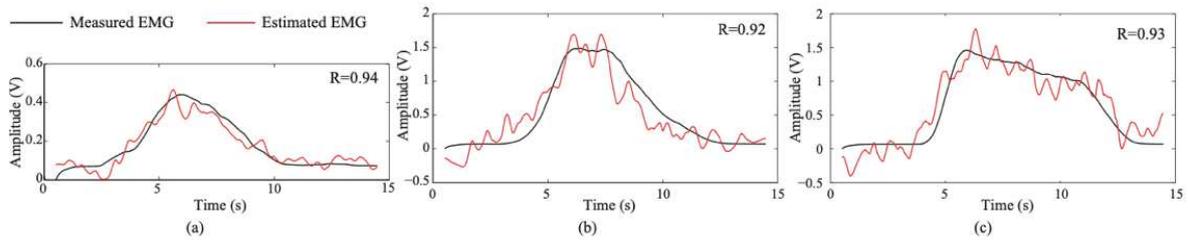


Figura 4.7: Confronto tra segnali EMG reali e stimati attraverso il modello sviluppato in [9]. (Tratta da [9])

In [4] viene sviluppato un modello matematico per spiegare le caratteristiche di omologia tra EEG ed EMG durante il movimento degli arti inferiori la cui struttura è riportata in figura 4.8.

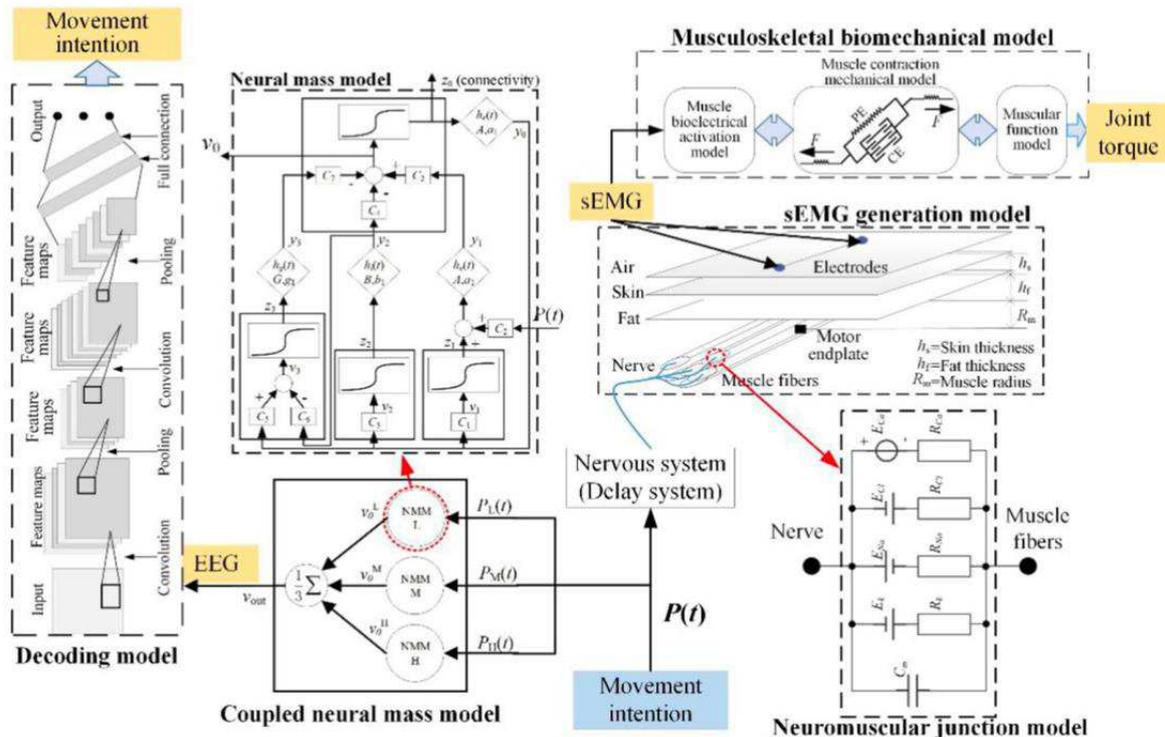


Figura 4.8: Modello matematico studiato in [4]. (Tratta da [4])

Quando un soggetto genera una Movement Intention (MI), è il cervello che attivandosi in un certo modo prepara il movimento (che noi possiamo “leggere” tramite EEG) e successivamente l’MI viene trasmessa agli arti attraverso un percorso neurale che rende possibile l’attivazione dei muscoli (di cui noi “leggiamo” l’attività tramite EMG). Quindi il modello matematico è formato da un Neural Mass Model (NMM) + un modello di giunzione neuromuscolare + un modello di generazione di segnali EMG + un modello di decodifica + un modello biomeccanico. Con  $P(t)$  si indica l’input dato dall’MI,  $P(t)$  trasmette alla corteccia motoria per generare i segnali EEG reali e quelli simulati dall’NMM. L’intenzione di movimento viene riconosciuta dal modello di decodifica. Nel frattempo,  $P(t)$  trasmette anche al muscolo per generare segnali EMG, simulati dal modello di giunzione neuromuscolare e da quello di generazione di EMG. In seguito, il movimento viene decodificato dal modello biomeccanico. Nel complesso questo modello prova che sia EEG che EMG sono attivati dalla stessa intenzione di movimento  $P(t)$  (i risultati sperimentali sono coerenti con l’ipotesi e la simulazione [4]) e fornisce una guida teorica per la fusione di questi due tipi di segnali.

### 4.3 Setup e fruibilità

Negli articoli analizzati (Tabella 3.1) l’obiettivo è spesso quello di trovare un algoritmo o un metodo di classificazione che abbia delle performance migliori rispetto a quelli già esistenti. In termini di applicabilità questo porta a domandarsi quanto il setup creato per l’elaborazione dei dati sia utilizzabile quotidianamente da chi ha problemi motori o di tipo neurologico.

In [11] viene analizzato un sistema di tipo decision-level-fusion che permette di analizzare i movimenti di un esoscheletro in tempo reale attraverso segnali EEG+EMG raggiungendo un’accuratezza del 78.3%. In questo studio vengono usati solo sette elettrodi per riuscire a controllare il dispositivo in tempo reale. Per una maggiore precisione il numero di elettrodi dovrebbe essere maggiore ma in questo modo il setup diventerebbe troppo invasivo.

Negli articoli in cui viene analizzata l’accuratezza di diverse combinazioni di canali (es. [22, 37, 39]), il risultato porta sempre a preferirne un numero maggiore. Un numero maggiore di canali permette infatti di avere più dati in ingresso ma nelle applicazioni pratiche è necessario un compromesso tra il numero di canali e le performance della classificazione.

Attualmente l'analisi congiunta di segnali EEG ed EMG viene effettuata per motivi di studio più che per scopi pratici. Nella maggior parte degli articoli viene fatta un'analisi degli algoritmi usati per la classificazione e l'estrazione di feature, dei metodi di classificazione e delle combinazioni di canali da usare per far sì che i dati in input siano sufficienti per implementare interfacce hHMI o sviluppare dispositivi quali protesi ed ortesi [9, 10, 13].

Spesso non viene tenuto conto della fruibilità da parte dell'utente, in particolare si riscontrano questi problemi:

- Il numero di canali attraverso i quali vengono registrati i segnali influenza la performance (in particolare maggiore è il numero di canali più precisa è la classificazione), ma in termini di utilizzo pratico più canali appesantiscono il setup;
- Un numero di feature maggiore porta ad una classificazione più accurata ma aumenta il tempo di esecuzione; quindi, può essere utilizzato per una classificazione off-line e non in tempo reale [5];
- La combinazione di feature analizzate dal classificatore modifica la performance della classificazione (certe combinazioni hanno un'accuratezza maggiore) [10]. Per questo è necessario studiare quali feature estrarre a seconda dello scopo dello studio in modo da migliorare l'affidabilità del dispositivo che si intende sviluppare/migliorare;
- Gli studi vengono spesso effettuati su pazienti sani. In futuro dovrebbero essere effettuati più esperimenti clinici per convalidare i metodi proposti con l'utente reale [6, 11, 24].

Altre limitazioni che sono state riscontrate negli articoli, e che riguardano il metodo di sviluppo dei trial, sono le seguenti:

- Se un soggetto non è familiare con le operazioni effettuate da una BCI, ciò influenza la classificazione e la velocità di controllo del trial iniziale, che serve poi alla corretta configurazione del sistema [13];
- L'ambiente sperimentale e il soggetto stesso che viene sottoposto all'esperimento possono avere un impatto sulla classificazione, ad esempio se il soggetto è nervoso la raccolta di dati può essere influenzata da diverse intensità di rumore [14].

Un modo per migliorare le performance e l'accuratezza potrebbe essere sviluppare un mHMI implementando un BCI [12, 28] o affiancare a segnali EEG/EMG anche segnali EOG (Electrooculography) che si sono dimostrati efficaci per migliorare le prestazioni di interfacce multimodali.

## 4.4 Take-home messages

Dalla revisione dello stato dell'arte dei modelli più recenti che usano simultaneamente le informazioni acquisite da sistemi EEG ed EMG e dalla tabella 3.1 si possono apprendere alcuni take-home messages, che rispondono alle domande di ricerca:

- 1- Dopo l'acquisizione dei segnali viene effettuato un pre-processing il cui scopo è quello di eliminare i disturbi, questo viene fatto grazie a dei filtri passa-alto [10], passabasso [16], passabanda [4] e al filtro Notch solitamente a 50 Hz. Il filtro Notch in particolare richiede attenzione perché lavorando a basse frequenze rischia di eliminare anche parti utili del segnale e non solo il rumore [12].
- 2- Una volta acquisiti i dati da sensori EEG ed EMG, questi vengono fusi in tre livelli:
  - Data-level-fusion: questo metodo di fusione è il meno utilizzato, viene scelto quando la classificazione si basa sulla coerenza tra due segnali (che solitamente viene calcolata con la MSC [2,18]). Nella tabella 3.1 si può notare che sono stati sviluppati nuovi metodi per il calcolo della coerenza che hanno performance migliori della CMC, per esempio CBPT ha un'accuratezza di 92.81% [17] che supera quella di CMC (88.12% [2]) se confrontata con lo stesso classificatore ovvero SVM;
  - Feature-level-fusion: È il metodo di fusione più diffuso perché raggiunge delle performance migliori rispetto ad altri (accuratezza 98.56% [5]), tuttavia è importante la scelta della combinazione di feature adatte allo scopo dello studio perché influenza la classificazione (accuratezza 95.58% usando SSC/MPF per EMG + SSC per EEG, che scende a 71.90% usando SSC/MPF per EMG + MPF per EEG [3]);
  - Decision-level-fusion: Le performance in termini di accuratezza raggiungono sempre valori intorno al 90% anche in presenza di disturbi causati da deficit neuromotori (accuratezza 89.7% [1]) dal momento che la decisione tiene conto del peso degli errori dei classificatori [33]. La performance dipende dalla scelta delle feature e dal classificatore scelto (accuratezza 89.7% con LSTM [1], 78.3% con LDA [11], 93.83% con SVM [12]).
- 3- La scelta dell'algoritmo di fusione e classificazione dei dati influenza la performance. Per questo è importante scegliere feature, algoritmi e classificatori a seconda dello scopo dello studio. Ad esempio, il classificatore LDA raggiunge un'accuratezza del 78.3% usato al decision-level-fusion [11] che si alza a 91.7% se usato al feature-level-fusion [22]. Anche la scelta delle feature può migliorare le performance (in [7] il classificatore LSTM raggiunge un'accuratezza di 82.7% ma in [1] si alza a 89.7%, in entrambi gli studi il livello di fusione è quello di decisione ma cambiano le feature estratte).

- 4- La combinazione di segnali EEG ed EMG in generale è migliore (accuratezza massima 93.83% [12]), ma se il soggetto è sano anche l'uso di EMG singolarmente raggiunge accuratze molto alte (max 93.47% [3]). Il vantaggio di poter disporre del segnale EEG è quando l'EMG è debole o patologico (aumento di accuratezza fino al 10% in più rispetto al solo EMG, grazie all'aggiunta di EEG [15]).
- 5- La maggior parte degli studi vengono effettuati su soggetti sani che non hanno deficit neuromotori [6, 11, 24], in aggiunta il setup è spesso invasivo perché un numero maggiore di canali aumenta l'accuratezza della classificazione [37] (accuratezza massima 91.7% con 32 canali EMG + 64 canali EEG contro accuratezza di 84.2% con 10 canali EMG + 10 canali EMG [22]) e lo stesso avviene con un numero maggiore di feature estratte (accuratezza 98.56% con un set di 37 feature a differenza di 84.78% con un set di 2 feature [5]). Per questo motivo in futuro lo scopo sarà quello di cercare un compromesso tra le performance e il numero di canali/feature estratte.



## Capitolo 5 – Conclusione

---

Al fine di sfruttare le tecniche basate su EMG-EEG e ridurre gli svantaggi di ciascuno dei due segnali, i metodi di controllo basati su EMG e EEG possono essere combinati per creare degli approcci di controllo ibrido basati su entrambi. In questa revisione, vengono esaminati gli approcci esistenti che utilizzano combinazioni di segnali EEG ed EMG per lo sviluppo di interfacce adibite alla riabilitazione [7, 13, 28, 29].

Sono stati analizzati i processi che portano allo sviluppo dei dati per l'applicazione pratica e ne sono state confrontate le caratteristiche principali quali l'estrazione delle feature e i metodi di classificazione.

In particolare, viene dimostrato come il livello di fusione dei dati e gli algoritmi di classificazione, scelti a seconda dello scopo dello studio, influenzino la performance finale [10].

Nella maggior parte degli studi esaminati, i segnali EMG ed EEG sono stati elaborati contemporaneamente, in questo modo la precisione dell'intero sistema può essere migliorata se la fusione viene eseguita in modo appropriato.

Negli approcci di controllo ibridi basati su EEG-EMG si verificano una serie di vantaggi. Gli approcci ibridi possono fornire miglioramenti in termini di performance come accuratezza e affidabilità rispetto all'uso individuale di metodi di controllo basati su EEG o EMG (Cap 4.3). La combinazione degli approcci di controllo EEG-EMG può migliorare il potenziale di applicazioni come protesi ed esoscheletri introducendo un ulteriore grado di libertà e migliorando la robustezza degli approcci di controllo. I segnali EEG, infatti, possono essere utilizzati per compensare alcuni problemi comuni dei segnali EMG, come gli effetti della fatica muscolare o del tremore indesiderato [28].

Tuttavia, ci sono ancora molte questioni da risolvere per migliorare l'efficacia dei metodi ibridi EEG-EMG per l'uso in applicazioni bio-robotiche. A volte l'efficacia dell'approccio combinato può essere inferiore a quella del solo EEG o EMG [3]. È importante considerare criticamente come combinare entrambi i segnali all'interno degli approcci di controllo al fine di ottenere risultati ottimali. Nel caso di applicazioni bio-robotiche come esoscheletri o protesi, esiste un'elevata possibilità che i segnali EEG vengano contaminati dal movimento. Inoltre, la maggior parte degli esperimenti è stata condotta su soggetti sani e non su soggetti neurodeblilitati [2,6,8].

Dal momento che il campo della bio-robotica è un'area di crescente interesse, i progressi dovrebbero avvantaggiare i pazienti su base clinica. In questo contesto, è importante che gli studi futuri conducano esperimenti più clinici al fine di convalidare i metodi proposti con l'utente reale. Da un

punto di vista metodologico, possono essere studiati nuovi metodi per combinare metodi di controllo individuali, come i metodi di fusione adattativa dei segnali EEG ed EMG. Ad esempio, un paziente con disturbo del movimento potrebbe non essere in grado di muovere un esoscheletro riabilitativo utilizzando i segnali EMG all'inizio, quindi una priorità maggiore può essere data ai metodi di controllo basati sull'EEG per controllare inizialmente tale dispositivo. Quando l'utente si abitua a questo processo riabilitativo, può essere dato più peso ai metodi di controllo basati sull'EMG. Inoltre, i risultati della ricerca come le correlazioni tra i segnali EEG ed EMG [19, 23, 9] possono essere considerati nei processi di progettazione per approcci di controllo ibridi basati su EEG-EMG.

In conclusione, con la tendenza attuale, possiamo vedere il potenziale per gli approcci di controllo ibridi basati su EEG-EMG da utilizzare nell'applicazione della bio-robotica, tuttavia, dovrebbero essere condotti ulteriori studi per migliorare l'efficacia e alla fine portare queste tecnologie fuori dall'ambiente del laboratorio.

# Bibliografia

---

- [1] Z. Wang and R. Suppiah, “Upper Limb Movement Recognition utilising EEG and EMG Signals for Rehabilitative Robotics” (2022), arXiv:2207.08650
- [2] Keihani A, Mohammadi AM, Marzbani H, Nafissi S, Haidari MR, Jafari AH (2022) “Sparse representation of brain signals offers effective computation of cortico-muscular coupling value to predict the task-related and non-task sEMG channels: A joint hdEEG-sEMG study”. *PLoS ONE* 17(7): e0270757. doi:10.1371/journal.pone.0270757
- [3] Wei PN, Zhang JH, Wang BZ and Hong J (2021) Surface Electromyography and Electroencephalogram-Based Gait Phase Recognition and Correlations Between Cortical and Locomotor Muscle in the Seven Gait Phases. *Front. Neurosci.* 15:607905. doi: 10.3389/fnins.2021.607905
- [4] Zhang X, Li H, Lu Z and Yin G (2021) Homology Characteristics of EEG and EMG for Lower Limb Voluntary Movement Intention. *Front. Neurobot.* 15:642607. doi: 10.3389/fnbot.2021.642607
- [5] P. Wei, J. Zhang, F. Tian, J.Hong, “A comparison of neural networks algorithms for EEG and sEMG features based gait phases recognition”, *Biomedical Signal Processing and Control* Volume 68 (2021) 102587, doi: 10.1016/j.bspc.2021.102587
- [6] J. Tryon and A. L. Trejos, “Evaluating Convolutional Neural Networks as a Method of EEG–EMG Fusion,” *Front. Neurobotics*, vol. 15, p. 692183, Nov. 2021, doi: 10.3389/fnbot.2021.692183.
- [7] Tortora, S., Tonin, L., Chisari, C., Micera, S., Menegatti, E., and Artoni, F. (2020). Hybrid human-machine interface for gait decoding through Bayesian fusion of EEG and EMG classifiers. *Front. Neurobot.* 14:582728. doi: 10.3389/fnbot.2020.582728

- [8] N. Hooda, R. Das, and N. Kumar, "Fusion of EEG and EMG signals for classification of unilateral foot movements," *Biomed. Signal Process. Control*, vol. 60, p. 101990, Jul. 2020, doi: 10.1016/j.bspc.2020.101990.
- [9] Liang, H.; Yu, Y.; Mochida, M.; Liu, C.; Ueda, N.; Li, P.; Zhu, C. "EEG-Based EMG Estimation of Shoulder Joint for the Power Augmentation System of Upper Limbs". *Symmetry* 2020, 12, 1851. doi: 10.3390/sym12111851
- [10] Faizal Adila Ferdiansyah et al 2020 *J. Phys.: Conf. Ser.* 1528 012033. doi: 10.1088/1742-6596/1528/1/012033
- [11] S.Y. Gordleeva, S.A. Lobov, N.A. Grigorev, A.O. Savosenkov, M.O. Shamshin, M. V. Lukoyanov, M.A. Khoruzhko, V.B. Kazantsev, Real-Time EEG-EMG human- machine interface-based control system for a lower-limb exoskeleton, *IEEE Access* 8 (2020) 84070–84081, doi:10.1109/ACCESS.2020.2991812
- [12] Zhang J, Wang B, Zhang C, Xiao Y and Wang MY (2019) "An EEG/EMG/EOG-Based Multimodal Human-Machine Interface to Real-Time Control of a Soft Robot Hand". *Front. Neurobot.* 13:7. doi: 10.3389/fnbot.2019.00007
- [13] Li, Z., Yuan, Y., Luo, L., Su, W., Zhao, K., Xu, C., et al. (2019). Hybrid brain/muscle signals powered wearable walking exoskeleton enhancing motor ability in climbing stairs activity. *IEEE Trans. Med. Robot. Bionics* 1, 218–227. doi: 10.1109/TMRB.2019.2949865
- [14] G. Mezzina, F. Aprigliano, S. Micera, V. Monaco and D. D. Venuto, "EEG/EMG based Architecture for the Early Detection of Slip-induced Lack of Balance," *2019 IEEE 8th International Workshop on Advances in Sensors and Interfaces (IWASI), 2019, pp. 9-14*, doi: 10.1109/IWASI.2019.8791252.
- [15] F. Sbargoud, M. Djeha, M. Guiatni, and N. Ababou, "WPT-ANN and Belief Theory Based EEG/EMG Data Fusion for Movement Identification," *Trait. Signal*, vol. 36, no. 5, pp. 383–391, Nov. 2019, doi: 10.18280/ts.360502.

- [16] S. Chambon, M. N. Galtier, P. J. Arnal, G. Wainrib and A. Gramfort, "A Deep Learning Architecture for Temporal Sleep Stage Classification Using Multivariate and Multimodal Time Series," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, no. 4, pp. 758-769, April 2018, doi: 10.1109/TNSRE.2018.2813138.
- [17] A. Chowdhury, H. Raza, Yogesh K. Meena, A. Dutta, G. Prasad, "An EEG-EMG correlation-based brain-computer interface for hand orthosis supported neuro-rehabilitation", *Journal of Neuroscience Methods Volume 312 (2019) Pages 1-11*, doi: 10.1016/j.jneumeth.2018.11.010.
- [18] Pan, LL.H., Yang, WW., Kao, CL. et al. Effects of 8-week sensory electrical stimulation combined with motor training on EEG-EMG coherence and motor function in individuals with stroke. *Sci Rep 8, 9217 (2018)*. doi:10.1038/s41598-018-27553-4
- [19] Gao, Y., Ren, L., Li, R., and Zhang, Y. (2018). Electroencephalogram- electromyography coupling analysis in stroke based on symbolic transfer entropy. *Front. Neurol.* 8:716. doi: 10.3389/fneur.2017.00716
- [20] De Venuto, D., Annese, V. F., Defazio, G., Gallo, V.L. and Mezzina, G. (2017) Gait analysis and quantitative drug effect evaluation in Parkinson disease by jointly EEG-EMG monitoring. *In: 2017 12th International Conference on Design & Technology of Integrated Systems in Nanoscale Era (DTIS), Palma de Mallorca, Spain, 04-06 Apr 2017*. doi: 10.1109/DTIS.2017.7930171
- [21] A. Ben Said, A. Mohamed, T. Elfouly, K. Harras and Z. J. Wang, "Multimodal Deep Learning Approach for Joint EEG-EMG Data Compression and Classification," *2017 IEEE Wireless Communications and Networking Conference (WCNC), 2017, pp. 1-6*, doi: 10.1109/WCNC.2017.7925709.
- [22] Li, X., Samuel, O. W., Zhang, X., Wang, H., Fang, P., and Li, G. (2017). A motion-classification strategy based on sEMG-EEG signal combination for upper-limb amputees. *J. Neuroeng. Rehabil.* 14, 1–13. doi: 10.1186/s12984-016- 0212-z

- [23] H. Liang et al., "Estimation of EMG signal for shoulder joint based on EEG signals for the control of upper-limb power assistance devices," *2017 IEEE International Conference on Robotics and Automation (ICRA)*, 2017, pp. 6020-6025. doi: 10.1109/ICRA.2017.7989712.
- [24] B. Kim, L. Kim, Y. H. Kim, S. K. Yoo, Cross-association analysis of EEG and EMG signals according to movement intention state, *Cognitive Systems Research Volume 44 (2017) Pages 1-9*. doi: 10.1016/j.cogsys.2017.02.001.
- [25] Fernandez-Vargas J, Kita K and Yu W (2016) Real-time Hand Motion Reconstruction System for Trans-Humeral Amputees Using EEG and EMG. *Front. Robot. AI* 3:50. doi: 10.3389/frobt.2016.00050
- [26] O. Geman et al., "Joint EEG — EMG signal processing for identification of the mental tasks in patients with neurological diseases," (2016) *24th European Signal Processing Conference (EUSIPCO)*, 2016, pp. 1598-1602, doi: 10.1109/EUSIPCO.2016.7760518.
- [27] Xie, P., Chen, X., Ma, P., Li, X., and Su, Y. (2013). "Identification method of human movement intention based on the fusion feature of EEG and EMG," in *World Congress on Engineering (London)*, 1–5
- [28] Leeb, R., Sagha, H., Chavarriaga, R., and Millan Jdel, R. (2011). A hybrid brain-computer interface based on the fusion of electroencephalographic and electromyographic activities. *J. Neural. Eng.* 8:025011. doi: 10.1088/1741-2560/8/2/025011
- [29] E. Rocon et al., "Multimodal BCI-mediated FES suppression of pathological tremor," (2010) *Annual International Conference of the IEEE Engineering in Medicine and Biology*, 2010, pp. 3337-3340, doi: 10.1109/IEMBS.2010.5627914.
- [30] Q. Yang, V. Siemionow, W. Yao, V. Sahgal and G. H. Yue, "Single-Trial EEG-EMG Coherence Analysis Reveals Muscle Fatigue-Related Progressive Alterations in Corticomuscular Coupling," in *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 2, pp. 97-106, April 2010, doi: 10.1109/TNSRE.2010.2047173.

- [31] Amjed S. Al-Fahoum, Ausilah A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *International Scholarly Research Notices*, vol. 2014, Article ID 730218. doi: 10.1155/2014/730218
- [32] Sanei S. and Chambers J.A., EEG Signal Processing. John Willey Sons Ltd, 1-34, 2007.
- [33] Khan, M.N.; Anwar, S. Paradox Elimination in Dempster–Shafer Combination Rule with Novel Entropy Function: Application in Decision-Level Multi-Sensor Fusion. *Sensors* 2019, 19, 4810. doi: 10.3390/s19214810
- [34] Christopher S, MdRasedul I, M Assad-Uz Z, Mohammad H R. A Comprehensive Study on EMG Feature Extraction and Classifiers. *Op Acc J Bio Eng & Bio Sci* 1(1)- 2018. OAJBEB.MS.ID.000104. doi: 10.32474/OAJBEB.2018.01.000104
- [35] Grosse P, Cassidy MJ, Brown P. EEG-EMG, MEG-EMG and EMG-EMG frequency analysis: physiological principles and clinical applications. *Clinical Neurophysiology : Official Journal of the International Federation of Clinical Neurophysiology*. 2002 Oct;113(10):1523-1531. doi: 10.1016/s1388-2457(02)00223-7.
- [36] P. Konrad, "The ABC of EMG," A practical introduction to kinesiological electromyography, vol. 1, 2005.
- [37] G. Cisotto, A. V. Guglielmi, L. Badia and A. Zanella, "Classification of grasping tasks based on EEG-EMG coherence," *2018 IEEE 20th International Conference on e-Health Networking, Applications and Services (Healthcom)*, 2018, pp. 1-6, doi: 10.1109/HealthCom.2018.8531140.
- [38] A. V. Guglielmi, G. Cisotto, T. Erseghe, and L. Badia, "Frequency-dependent functional connectivity of brain networks at resting-state," *Proceedings BMEiCON, November 2022*.
- [39] Cisotto, G., Capuzzo, M., Guglielmi, A.V. et al. Feature stability and setup minimization for EEG-EMG-enabled monitoring systems. *EURASIP J. Adv. Signal Process.* 2022, 103 (2022). doi: 10.1186/s13634-022-00939-3