

UNIVERSITÀ DEGLI STUDI DI PADOVA

Dipartimento di Ingegneria dell'Informazione
CORSO DI LAUREA TRIENNALE IN INGEGNERIA BIOMEDICA

**Studio di modelli per interfacce
Uomo-Macchina basate su
rappresentazioni matriciali delle
componenti in frequenza di segnali EEG**

Supervisor

PROF. LUCA TONIN

Candidate

ELENA VARIOLA

Co-Supervisor

PHD ALESSIO PALATELLA

17 Luglio 2024

Anno Accademico 2023-2024

Abstract

Le brain-machine interface (BMI) rappresentano una tecnologia emergente che consente un'interazione diretta tra il cervello umano e dispositivi esterni, offrendo alle persone affette da gravi disabilità motorie la possibilità di comunicare con il mondo esterno attraverso il controllo di computer e dispositivi assistivi.

Nelle BMI basate su segnali EEG, la classificazione degli stati mentali degli utenti, ottenuti dall'analisi dell'attività cerebrale, gioca un ruolo fondamentale nelle prestazioni del sistema. Per questo motivo, questa tesi esplora modelli innovativi che combinano l'approccio riemanniano, spesso considerato stato dell'arte nel campo delle BMI, con il cross-frequency coupling (CFC) per ottenere features discriminanti ed affidabili, al fine di migliorare le prestazioni della classificazione nelle BMI. Le features estratte dai segnali EEG vengono rappresentate tramite matrici di covarianza simmetriche definite positive (SPD), includendo l'interazione tra fase e ampiezza delle diverse bande di frequenza.

I risultati sperimentali, osservati nell'ambito di un task di Motor Imagery (MI), dimostrano che l'approccio proposto offre significativi miglioramenti in termini di accuratezza di classificazione rispetto ai metodi tradizionali. In particolare, la combinazione dei diversi metodi di estrazione delle features ha mostrato una performance superiore rispetto all'utilizzo delle singole matrici

di covarianza, raggiungendo un'accuratezza media del 73,6%. Questi risultati evidenziano il potenziale delle metodologie proposte nel migliorare l'efficacia delle BMI, aprendo nuove strade per future ricerche e applicazioni.

Contents

Abstract	i
1 Introduzione	1
1.1 Brain-Machine Interface	1
1.1.1 Definizione di BMI	1
1.1.2 Modalità di interazione nelle BMIs	2
1.1.3 Motor Imagery	3
1.1.4 Closed-loop: principio di funzionamento delle BMI	5
1.1.5 Acquisizione del segnale cerebrale	8
1.2 Estrazione delle features	12
1.2.1 L'approccio della Geometria di Riemann	13
1.2.2 Pipeline per la classificazione	15
1.2.3 Cross-frequency coupling	17
2 Motivazioni ed obiettivi della tesi	21
3 Metodo	23
3.1 Protocollo di training	23
3.2 Acquisizione dei dati	24
3.3 Pre-processing	26
3.4 Estrazione delle features	27

3.4.1	Geometria di Riemann per la classificazione di EEG . . .	28
	Matrice di covarianza	28
	Distanza Riemanniana	29
	Proiezione nello spazio tangente	29
3.5	Metodi proposti	30
3.5.1	Baselines	30
3.5.2	Accoppiamento fase-ampiezza (PA Cov)	31
3.5.3	Accoppiamento fase-ampiezza diretto (dPAC Cov) . . .	32
3.5.4	Covarianza delle frequenze incrociate (crossFB Cov) . .	32
3.5.5	Vettorizzazione delle matrici di covarianza	33
3.5.6	Combinazione dei metodi proposti (Fusion)	34
3.6	Classificazione	35
3.6.1	Ridge Regression	35
3.6.2	Processo di Classificazione	36
4	Risultati	39
5	Discussione	43
6	Conclusioni	47
	References	51

1 | Introduzione

Lo sviluppo di nuove tecnologie come le brain-machine interfaces (BMIs) nasce dall'esigenza di migliorare significativamente la qualità della vita di persone affette da gravi disabilità motorie, come la sclerosi laterale amiotrofica (SLA), lesioni al midollo spinale, ictus o altre lesioni neuromuscolari, aiutato anche dalle ultime scoperte sul funzionamento del cervello e all'avvento di potenti apparecchiature informatiche a basso costo. Grazie a ciò sono stati sviluppati sistemi di comunicazione e controllo con l'obiettivo di fornire a tali utenti, potenzialmente completamente paralizzati, le capacità di comunicazione di base, consentendo loro di esprimere i propri desideri ai caregiver. Infatti, le BMIs permettono di comunicare con il mondo esterno senza utilizzare i tradizionali percorsi neuromuscolari.

1.1 Brain-Machine Interface

1.1.1 Definizione di BMI

La funzione del sistema nervoso centrale (SNC) è quella di rispondere agli eventi del mondo esterno o del corpo producendo output che servono alle necessità dell'organismo. Tutti gli output naturali del SNC sono di tipo neuromuscolare o ormonale, mentre una BMI fornisce al SNC un nuovo

output totalmente differente da quelli classici. Una BMI è un sistema che misura l'attività del SNC e la converte in un output artificiale che sostituisce, ripristina, potenzia, integra o migliora l'output naturale del SNC e quindi modifica le interazioni in corso tra il SNC il suo ambiente esterno o interno [1].

In altre parole, una BMI è un sistema di comunicazione e/o di controllo che permette un'interazione in tempo reale tra il cervello umano e dispositivi esterni, senza l'utilizzo dei normali canali di output del cervello, come nervi periferici e muscoli. L'intento di un utente si manifesta attraverso un cambiamento dei segnali cerebrali, il quale viene acquisito e tradotto dal sistema BMI in un output desiderato. Tuttavia, è fondamentale chiarire che le BMI non sono strumenti in grado di leggere la mente, nel senso di estrapolare informazioni da individui ignari o non consenzienti, invece esse consentono agli utenti di interagire con il mondo esterno utilizzando segnali cerebrali al posto dei movimenti muscolari. Difatti l'utente e la BMI operano in sinergia, collaborando tra loro [2].

1.1.2 Modalità di interazione nelle BMIs

Le modalità di interazione tra le BMI basate su elettroencefalogramma (EEG) e l'utente sono strettamente legate alla natura del compito mentale eseguito dall'utente e ai processi neurali coinvolti. E' dunque essenziale scegliere il paradigma più appropriato per manipolare correttamente un dispositivo neuroprotesico o di neuroriabilitazione [3, 4]. E' possibile suddividere tali modalità di interazione in due macrocategorie:

1. Paradigmi esogeni

L'attività cerebrale viene influenzata da stimoli esterni, come, ad esempio, flash luminosi o suoni. La stimolazione esterna può essere vi-

siva, uditiva o somatosensoriale. Il principio di funzionamento si basa quindi su un'alterazione dell'attività EEG che viene registrata e decodificata per poi controllare oggetti reali o virtuali o protesi esterne [4]. I paradigmi di stimolazione esterna più comunemente impiegati dai ricercatori sono basati su potenziali evocati steady-state (SSVEP) oppure sulla rilevazioni di segnali P300.

2. Paradigmi endogeni

Il segnale cerebrale considerato viene generato spontaneamente o volontariamente dal soggetto senza alcuna stimolazione esterna. La Motor Imagery (MI), ovvero l'immaginazione motoria, è il paradigma più esplorato tra tutte le modalità di interazione esogene, definite anche self-paced perché il soggetto controlla volontariamente e autonomamente il tempo e la durata dell'attività mentale senza alcuna stimolazione esterna o segnali che indichino quando iniziare o terminare l'attività [3].

1.1.3 Motor Imagery

Nel presente lavoro, il paradigma di maggiore interesse per la fase sperimentale sarà proprio la MI. L'immaginazione motoria è un processo cognitivo in cui un soggetto immagina di eseguire un movimento stando fermo. È uno stato dinamico durante il quale la rappresentazione di una specifica azione motoria viene attivata internamente senza alcuna produzione motoria effettiva. In altre parole, l'immaginazione motoria richiede l'attivazione consapevole delle regioni cerebrali coinvolte anche nella preparazione ed esecuzione del movimento, accompagnata da un'inibizione volontaria del movimento effettivo [5]. Un numero sempre crescente di studi [6] ha dimostrato che l'immaginazione motoria porta all'attivazione delle stesse aree cerebrali

del movimento effettivo. Secondo questa visione, la principale differenza tra esecuzione e immaginazione è che in quest'ultimo caso l'esecuzione sarebbe bloccata a un certo livello corticospinale [6].

La ricerca neurofisiologica sulla corteccia sensomotrice ha dimostrato che le bande di frequenza μ (8-12 Hz) e β (18-26 Hz) sono influenzate dal movimento reale, dalla preparazione al movimento e dall'immaginazione del movimento [7]. Questi ritmi, registrati dalla corteccia sensomotrice, sono modulati in termini di energia in risposta a eventi specifici, fenomeno noto come desincronizzazione evento-correlata (ERD) e sincronizzazione evento-correlata (ERS). L'ERD rappresenta una riduzione della potenza dei ritmi μ e β nella corteccia sensomotrice durante gli eventi di immaginazione motoria, mentre la sincronizzazione evento-correlata (ERS) indica un aumento della potenza che avviene tipicamente dopo l'evento MI. L'ERD e l'ERS dei ritmi μ e β mostrano pattern spaziali distinti durante i compiti di immaginazione motoria, relativi a diverse parti del corpo umano come mano destra, mano sinistra e gambe [8]. Numerosi esperimenti hanno dimostrato che gli individui possono imparare a utilizzare l'immaginazione motoria per controllare (ridurre o aumentare) la potenza dei ritmi sensomotori [9]. Pertanto, l'immaginazione motoria rappresenta un paradigma efficace per lo sviluppo di un sistema BMI indipendente basato sui ritmi sensomotori. La Figura 1.1 illustra i grafici spaziotemporali di ERD ed ERS durante l'esecuzione motoria e l'immaginazione motoria seguendo un paradigma di calibrazione. L'ERD sostenuto è osservabile nelle bande alfa e beta, mentre un ERS di breve durata è visibile solo nella banda beta. Sia l'ERD che l'ERS sono osservati nelle aree sensomotorie. Questi risultati supportano l'idea che l'immaginazione motoria attiva le stesse aree cerebrali dell'esecuzione motoria, rendendola efficace per lo sviluppo di sistemi BMI basati sui ritmi sensomotori [10].

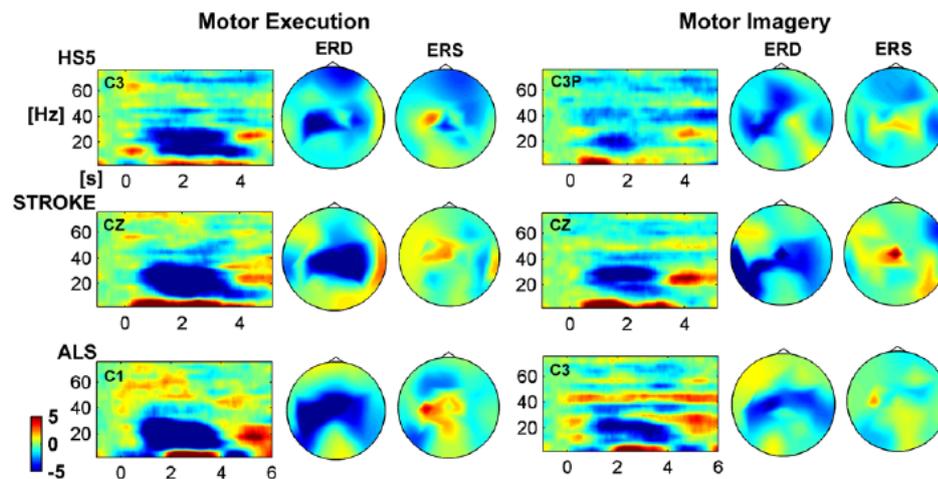


Figure 1.1 Grafici spaziotemporal di ERD e ERS [10]

1.1.4 Closed-loop: principio di funzionamento delle BMI

L'efficacia e il successo di una BMI dipendono dall'interazione tra l'utente e il sistema stesso. Tale interazione è permessa dall'architettura “*closed-loop*”, come illustrato nella Figura 1.2, sulla quale si basano le BMI. La struttura a ciclo chiuso prevede che l'utente impari a gestire in maniera autonoma l'attività cerebrale in risposta al feedback fornito dal decodificatore in tempo reale. Parallelamente il decodificatore viene aggiornato nel tempo al fine di adattare i suoi modelli matematici al cambiamento delle fluttuazioni nel cambiamento dell'attività celebrale durante i compiti mentali eseguiti dall'utente. La collaborazione dinamica tra utente e macchina viene definita come apprendimento reciproco [11].

L'architettura a ciclo chiuso è articolata in sei stadi [12]:

1. **Acquisizione del segnale:** misurazione dei segnali cerebrali grezzi che riflettono l'attività mentale dell'utente.
2. **Pre-processing del segnale:** pulizia e filtraggio dei dati di input al fine di migliorare le informazioni rilevanti contenute nei segnali grezzi.

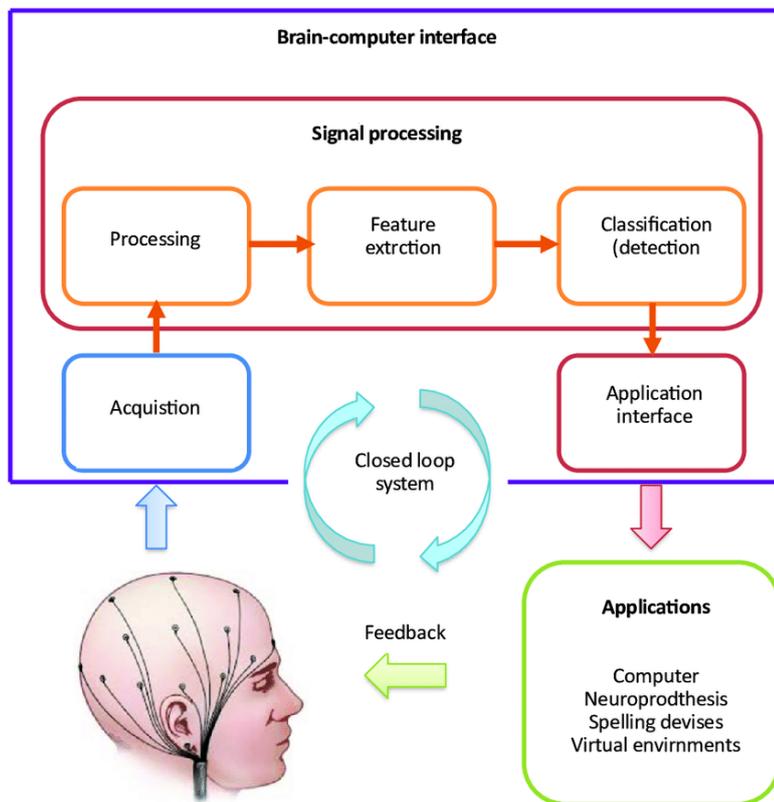


Figure 1.2 BMI closed loop

3. **Estrazione delle features:** descrizione e rappresentazione dei segnali tramite un insieme di valori significativi. Questo processo consente di ridurre la complessità dei dati e di focalizzarsi sugli aspetti più pertinenti per l'analisi successiva.
4. **Classificazione:** assegnazione ad una classe dell'insieme di features estratte dai segnali entro un determinato intervallo temporale. Questa classe rappresenta il tipo di pattern di attività cerebrale rilevato, come ad esempio l'immaginazione del movimento della mano sinistra o della mano destra. Gli algoritmi impiegati per effettuare questa assegnazione sono denominati classificatori.
5. **Traduzione in comando:** associazione di un comando specifico al mod-

ello di attività cerebrale identificato nei segnali dell'utente. Ad esempio, il riconoscimento del movimento immaginato della mano sinistra potrebbe essere tradotto nel comando "sposta il cursore a sinistra". Questo comando viene poi utilizzato per controllare applicazioni come un editor di testo (speller) o un robot.

6. **Feedback:** assistenza dell'utente nella modulazione della propria attività cerebrale, migliorando così il controllo sulla BMI. Infatti, l'utilizzo efficace di una BMI è una competenza che richiede apprendimento e perfezionamento continuo.

L'utilizzo delle BMIs si sviluppa in due fasi: una prima fase di addestramento offline e una seconda fase operativa online.

Nella fase di addestramento offline, il sistema viene calibrato per garantire un funzionamento affidabile. Questa calibrazione è fondamentale e viene effettuata preregistrando un set di dati di addestramento dall'utente, nel quale l'utente esegue ripetutamente ciascun compito mentale di interesse secondo le istruzioni fornite. Poiché i segnali cerebrali sono altamente specifici per ogni individuo, è necessario che la calibrazione sia personalizzata. Durante questa fase, l'algoritmo di classificazione viene messo a punto e vengono selezionati i canali e le caratteristiche del segnale ottimali. La scelta delle caratteristiche si basa su diversi fattori: le features selezionate devono essere fortemente correlate al compito mentale eseguito dall'utente e devono essere altamente discriminative tra le diverse classi di segnali. Inoltre, devono essere scelte in modo da minimizzare l'influenza del rumore e degli artefatti presenti nei segnali, devono essere stabili nel tempo, ossia devono mantenere la loro rilevanza e discriminabilità su diverse sessioni di utilizzo e devono essere computazionalmente efficienti da calcolare, in modo da garantire una risposta rapida del sistema [13].

Nella fase operativa online, il sistema riconosce i pattern di attività cerebrale precedentemente misurati e li traduce in comandi. Questo processo consente al sistema BMI di interpretare le intenzioni dell'utente e tradurle in azioni concrete tramite degli attuatori. La calibrazione effettuata nella fase offline è essenziale per il successo di questa fase, in quanto garantisce che il sistema possa identificare con precisione i pattern di attività cerebrale dell'utente [12].

1.1.5 Acquisizione del segnale cerebrale

I metodi di acquisizione del segnale cerebrale possono essere classificati in due principali categorie: metodi non invasivi e metodi invasivi. Le tecniche non invasive si basano sulla rilevazione di segnali elettrocorticografici mediante elettrodi posizionati sulla superficie dello scalpo. Tra queste tecniche, si annoverano quelle che sfruttano le risposte emodinamiche, come la risonanza magnetica funzionale (fMRI) e la spettroscopia funzionale nel vicino infrarosso (fNIRS), oltre a quelle che registrano l'attività elettrica cerebrale, come l'EEG e la magnetoencefalografia (MEG).

Invece, le tecniche invasive accedono direttamente all'attività neuronale, registrando i picchi di attività dei singoli neuroni o i potenziali di campo locali mediante microelettrodi impiantati nelle aree corticali o subcorticali del cervello. Questi metodi permettono una misurazione molto dettagliata e precisa dell'attività cerebrale, sebbene comportino rischi e complessità maggiori rispetto ai metodi non invasivi. [3].

Nel presente lavoro il metodo di acquisizione di interesse è l'EEG. Tale tecnica è anche quella maggiormente adoperata dai ricercatori grazie alla sua facilità d'uso e alla natura non invasiva di questo approccio. Nello specifico, l'EEG è una tecnica che misura in tempo reale, tramite elettrodi appli-

cati sullo scalpo, piccole correnti elettriche che riflettono l'attività cerebrale [14]. Il segnale EEG è caratterizzato da un'elevata risoluzione temporale che permette di rilevare l'attività cerebrale con un precisione nell'ordine dei millisecondi. Tuttavia, i vantaggi dell' EEG sono spesso accompagnati da ostacoli come la bassa risoluzione spaziale, dovuta alla sovrapposizione di segnali provenienti da neuroni in posizioni molto vicine tra loro e la difficoltà di gestire i rapporti segnale-rumore.

La posizione degli elettrodi sullo scalpo è determinata seguendo il sistema internazionale 10–20 illustrato nella Figura 1.3, che utilizza due punti di riferimento fondamentali sulla testa: il nasion e l'inion. Il nasion è situato alla sommità del naso, all'altezza degli occhi, mentre l'inion si trova sulla protuberanza ossea alla base del cranio. Partendo da questi punti di riferimento, il cranio viene diviso dai piani trasversale e mediano. Le posizioni degli elettrodi vengono quindi stabilite marcando questi piani a intervalli del 10% e del 20%. Le lettere che identificano ciascuna posizione degli elettrodi corrispondono a specifiche regioni cerebrali. Ad esempio, A rappresenta il lobo dell'orecchio, C indica la regione centrale, Pg si riferisce alla nasofaringea, P alla parietale, F alla frontale, Fp alla frontale polare e O alla zona occipitale. Questo sistema di posizionamento assicura che gli elettrodi siano collocati in modo preciso e standardizzato, permettendo una corretta acquisizione dei dati EEG [15].

Un segnale EEG registrato dal cuoio capelluto mostra un'ampiezza dell'ordine dei microVolt e presenta frequenze comprese tra 1 Hz e 100 Hz. Un metodo frequentemente adottato per la classificazione delle forme d'onda del segnale EEG si basa sull'analisi delle frequenze. Differenti bande di frequenza sono correlate a diversi stati mentali, permettendo di associare specifiche frequenze a particolari condizioni cognitive [15]:

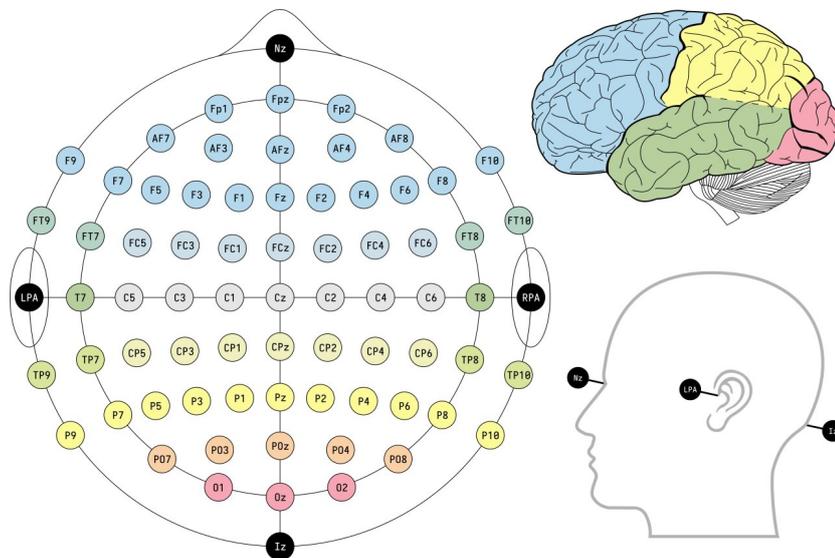


Figure 1.3 Posizionamento degli elettrodi: sistema 10-20 nell'elettroencefalografia

1. **Delta [0.1-4 Hz]**: queste onde mostrano un'ampiezza che diminuisce gradualmente con l'età nei bambini. Negli adulti, i ritmi delta sono prevalentemente osservati durante il sonno profondo e sono raramente presenti durante lo stato di veglia. Un'elevata quantità di attività delta in adulti svegli è considerata anomala e può essere associata a patologie neurologiche.
2. **Theta [4-8 Hz]**: in un adulto sveglio normale, le frequenze theta sono registrate in quantità limitata. Frequenze theta più elevate sono osservabili nei bambini e negli adulti durante stati di sonnolenza o meditazione. Un'attività theta significativa negli adulti svegli è spesso associata a condizioni neurologiche patologiche. La banda theta è stata collegata a diversi processi cognitivi, come il calcolo mentale e la consapevolezza cosciente, oltre che alla concentrazione meditativa.
3. **Alpha [8-13 Hz]**: queste onde si osservano principalmente nella regione occipitale del cervello. La loro ampiezza aumenta quando gli occhi

sono chiusi e il corpo è rilassato, mentre diminuisce quando gli occhi sono aperti e viene eseguita un'attività mentale. Questi ritmi riflettono principalmente il processamento visivo nell'area occipitale e possono essere associati alle funzioni mnemoniche. Inoltre, evidenze scientifiche mostrano che l'attività alfa è correlata allo sforzo mentale, poiché un incremento dell'attività mentale causa una soppressione delle onde alfa, specialmente nelle aree frontali. s

4. **Betha [13-30 Hz]**: vengono registrate principalmente nelle regioni frontali e centrali del cervello, sono associate alle attività motorie. I ritmi beta si desincronizzano durante il movimento reale o l'immaginazione motoria. In condizioni di riposo senza attività motoria, le onde beta mostrano una distribuzione simmetrica. Tuttavia, durante un movimento attivo, l'ampiezza delle onde beta si attenua e la loro distribuzione simmetrica viene alterata.
5. **Gamma [30-100 Hz]**: la presenza di onde gamma nell'attività cerebrale di un adulto sano è correlata a determinate funzioni motorie o percezioni e ad attività mentali elevate.

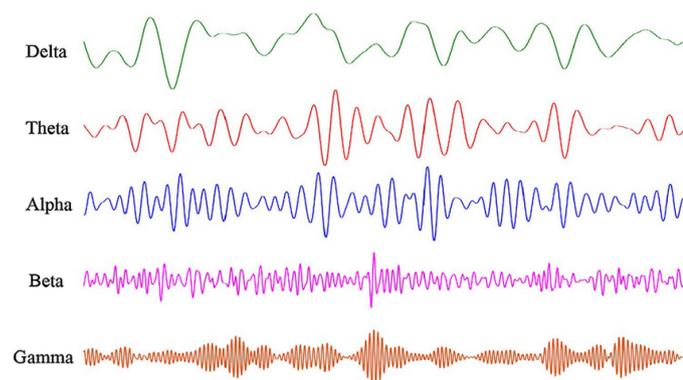


Figure 1.4 Forme d'onda del segnale EEG

1.2 Estrazione delle features

Una delle fasi più importanti, ma allo stesso tempo più complesse nella progettazione di una BMI è l'elaborazione del segnale a causa della complessità dei processi coinvolti nel cervello [14]. L'elaborazione del segnale, come visto in precedenza, può essere suddiviso in tre fasi: il pre-processing, l'estrazione delle features e la classificazione. Questo capitolo si concentra nello specifico su alcuni aspetti riguardanti l'estrazione delle features, che consiste nel descrivere i segnali EEG attraverso un insieme di valori che descrivono le informazioni rilevanti al fine di classificarle successivamente ed identificare lo stato mentale dell'utente. La procedura di selezione delle caratteristiche è strettamente correlata al compito mentale eseguito dall'utente e alle corrispondenti risposte neurali, fondamentali per discriminare efficacemente le intenzioni dell'utente [3]. Si identificano tre fondamentali fonti di dati utilizzate per l'estrazione delle caratteristiche dai segnali EEG [16]:

1. **Informazioni spaziali:** Questa categoria descrive l'origine spaziale del segnale rilevato. In pratica, questo implica la selezione di specifici elettrodi EEG o un maggiore focus su alcuni sensori rispetto ad altri, utilizzando segnali provenienti da regioni cerebrali precise e riducendo al minimo il contributo di altre aree.
2. **Informazioni spettrali (o in frequenza):** Questo tipo di informazioni descrive la variazione della potenza del segnale EEG in specifiche bande di frequenza. In altre parole, si tratta di utilizzare la potenza spettrale del segnale come caratteristica distintiva per l'analisi e la classificazione.
3. **Informazioni temporali:** Questa categoria descrive la variazione dei segnali EEG nel corso del tempo. Concretamente, ciò comporta l'utilizzo dei valori dei segnali EEG per intervalli temporali specifici, anche se non

necessariamente per tutti, o per finestre temporali diverse.

L'integrazione di queste tre categorie di dati consente di ottenere una rappresentazione completa e precisa dei segnali EEG, aumentando l'efficacia della BMI nel riconoscere e interpretare gli stati mentali dell'utente. In generale, è cruciale sfruttare diverse fonti di informazioni a seconda del tipo di BMI utilizzata. Ad esempio, le BMI che si basano sull'attività oscillatoria dell'EEG, come quelle fondate sulla MI, tendono a dare maggiore importanza alle informazioni spaziali e spettrali. Al contrario, le BMI che si basano sui potenziali evocati (PE) si focalizzano principalmente sulle informazioni spaziali e temporali. L'uso combinato di queste informazioni permette di adattare il sistema alle specifiche esigenze del compito mentale da eseguire, ottimizzando così la performance complessiva della BMI.

1.2.1 L'approccio della Geometria di Riemann

Le attuali BMI, nonostante le promettenti applicazioni, presentano ancora numerose limitazioni. Un ostacolo significativo all'ampia adozione delle BMI basate su elettroencefalografia è la loro scarsa robustezza e affidabilità [17, 18]. Questi sistemi tendono a riconoscere frequentemente comandi errati dall'utente, con conseguente bassa precisione e ridotto tasso di trasferimento delle informazioni [18, 19]. Inoltre, le BMI basate su EEG sono molto sensibili al rumore, come i movimenti dell'utente [20] e alla non stazionarietà dei segnali EEG [21]. Oltre a queste problematiche, un ulteriore limite è rappresentato dai lunghi tempi di calibrazione necessari. Per massimizzare le prestazioni, è fondamentale raccogliere numerosi esempi di addestramento EEG da ciascun utente, al fine di calibrare specificamente la BMI [22]. Pertanto, per rendere le BMI utilizzabili nella pratica, è essenziale che siano robuste in vari contesti, nel tempo e tra utenti diversi, con tempi di cali-

brazione ridotti al minimo.

Affrontare queste sfide richiede nuove metodologie e strumenti, in particolare nell'ambito dell'elaborazione e della classificazione dei segnali EEG. In questo contesto, gli approcci riemanniani stanno emergendo come una soluzione promettente poiché permettono la manipolazione diretta delle matrici di covarianza dei segnali EEG [23]. Le matrici di covarianza sono particolarmente utili perché catturano le dipendenze spaziali tra i canali EEG, fornendo una rappresentazione più ricca del segnale. Inoltre, lo spazio di Riemann utilizza solo matrici simmetriche definite positive (SPD), garantendo così proprietà matematiche che rendono l'elaborazione dei segnali più robusta e affidabile. Tali approcci stanno guadagnando interesse tra un numero crescente di ricercatori, poiché offrono una nuova prospettiva per migliorare l'affidabilità e l'efficacia delle BMI, affrontando le problematiche legate alla non stazionarietà e alla sensibilità al rumore dei segnali EEG.

La geometria riemanniana è un ampio ramo della matematica che riveste un'importanza significativa nello studio delle proprietà e delle strutture degli spazi multidimensionali [24]. Essa va oltre i limiti della geometria euclidea, includendo le proprietà geometriche delle curve e delle superfici, rendendo così la geometria applicabile anche negli spazi non euclidei [25]. Inoltre, lo spazio tangente riemanniano calcolato su un punto risulta essere un classico spazio euclideo.

Lo spazio delle matrici SPD indicato con $\mathcal{P}_n = \{X \in \mathbb{R}^{n \times n} \mid X = X^T, \text{eig}(X) > 0\}$, è composto da matrici in cui tutti gli autovalori sono strettamente positivi. In questo contesto, è possibile definire una distanza euclidea e due distanze riemanniane differenti:

1. Distanza Euclidea:

$$\delta_e(X_A, X_B) = \|X_A - X_B\| \quad (1.1)$$

$$\delta_e(X_A, X_B) = \sqrt{\langle X_A - X_B, X_A - X_B \rangle} \quad (1.2)$$

2. Distanza Riemanniana (AIRM) [23]:

$$\delta_r(X_A, X_B) = \|\log(X_A^{-\frac{1}{2}} X_B X_A^{-\frac{1}{2}})\| \quad (1.3)$$

dove $\log(\cdot)$ corrisponde al logaritmo della matrice.

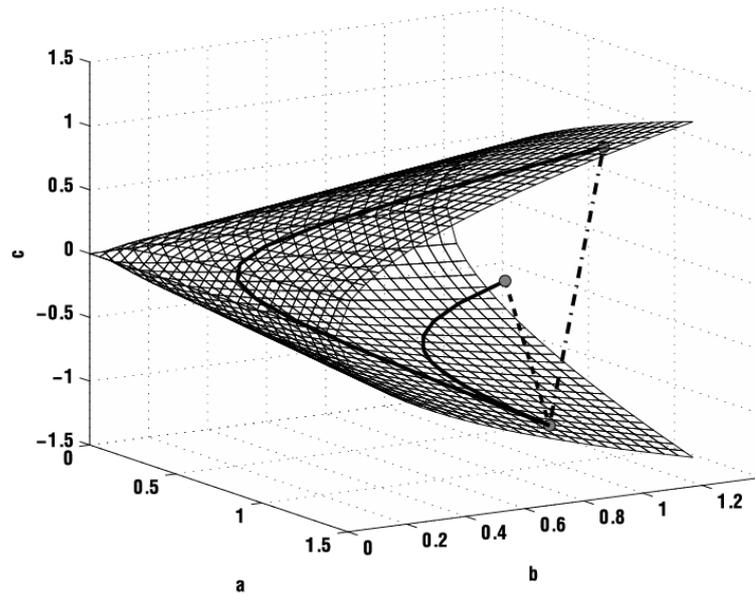


Figure 1.5 Distanza Euclidea e Distanze Riemanniane

La Figura 1.5 mostra come esempio il confronto tra le distanze euclidee (linee tratteggiate dritte) e le distanze riemanniane (linee solide curve) misurate tra matrici SPD 2×2 .

1.2.2 Pipeline per la classificazione

Le BMI, come illustrato precedentemente, sono progettate secondo alcuni passaggi standard al fine di processare e classificare i segnali EEG e tradurli in un comando. Questo processo generalmente include: pre-processare i segnali,

ad esempio applicando un filtro passa-banda, l'estrazione delle sorgenti utilizzando filtri spaziali come il Common Spatial Pattern (CSP), l'estrazione di un vettore di features dal segnale risultante, ad esempio la potenza delle bande di segnale, e la classificazione di questo vettore di features utilizzando un classificatore basato su vettori come il Linear Discriminant Analysis (LDA). Nella fase di estrazione delle sorgenti, la pipeline spesso richiede la stima e la manipolazione delle matrici di covarianza. Gli approcci Riemanniani possono essere utilizzati in questa fase per migliorare l'estrazione delle sorgenti

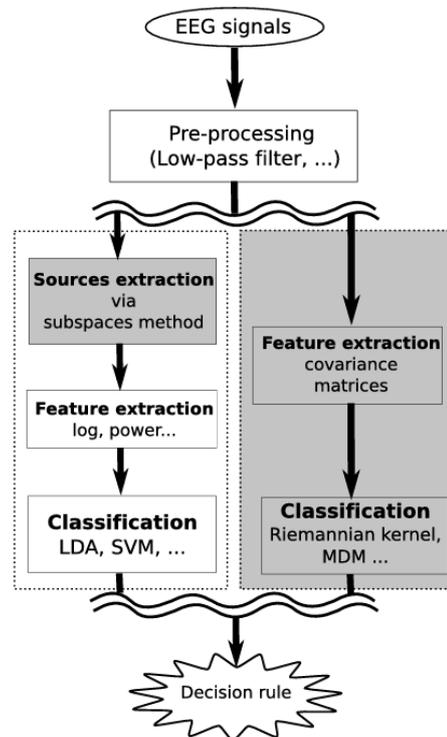


Figure 1.6 Esempio di pipeline di elaborazione dei segnali in una BMI

In alternativa, come evidenziato dalla Figura 1.6, poiché la pipeline BMI coinvolge la stima e la manipolazione delle matrici di covarianza, l'intero processo può essere progettato attorno a tali matrici utilizzando la geometria Riemanniana. In altre parole, la pipeline di una BMI completamente Rie-

manniana consiste nel pre-processare i segnali, rappresentarli come matrici di covarianza e classificarli utilizzando decoders basati sulla geometria Riemanniana. Questa nuova pipeline di elaborazione risulta più semplice poiché non richiede più l'estrazione delle sorgenti. Infatti, le informazioni spaziali necessarie per l'estrazione delle sorgenti sono già disponibili nelle rappresentazioni delle matrici di covarianza [23].

1.2.3 Cross-frequency coupling

L'attività oscillatoria cerebrale è stata associata ad una vasta gamma di processi cognitivi, tra cui il processo decisionale, l'elaborazione del feedback e la memoria di lavoro. L'elettroencefalografia consente lo studio delle variazioni nella potenza delle oscillazioni e il loro accoppiamento nel tempo. Diverse forme di sincronizzazione neuronale tra bande di frequenza sono state proposte come meccanismi fondamentali del *binding* neuronale. Il cervello umano è modellato come una rete complessa con una topologia distribuita, che consente un'elaborazione delle informazioni parallela e specializzata. Per integrare le informazioni tra regioni cerebrali specializzate, sono necessari meccanismi di sincronizzazione neuronale tra oscillazioni di diverse bande di frequenza [26]. Le oscillazioni ad alta frequenza riflettono l'elaborazione locale delle informazioni nella corteccia, mentre le oscillazioni a bassa frequenza mediano il flusso di informazioni attraverso reti corticali più estese [27]. Le diverse bande di frequenza svolgono ruoli computazionali distinti, facilitando la sincronizzazione necessaria per il processamento cognitivo. Ad esempio, le oscillazioni gamma sono cruciali per la percezione visiva, mentre le oscillazioni alfa nella regione occipitale indicano una ridotta attenzione visiva [26]. Il cross-frequency coupling (CFC) si riferisce all'interazione tra diverse bande di frequenza. Esistono tre tipi di accoppiamento tra frequenze: CFC

fase-ampiezza, CFC fase-fase e CFC ampiezza-ampiezza. Il tipo di CFC più studiato è il phase-amplitude coupling (PAC), ovvero l'accoppiamento fase-ampiezza, che modula l'ampiezza delle oscillazioni ad alta frequenza in relazione alla fase delle oscillazioni a bassa frequenza.

Il CFC fase-ampiezza fornisce un mezzo efficace per integrare l'attività su scale spaziali e temporali diverse e permette di descrivere la dipendenza statistica tra la fase di un ritmo cerebrale a bassa frequenza e l'ampiezza del componente ad alta frequenza dell'attività cerebrale elettrica. La rilevanza teorica della relazione tra fase a bassa frequenza e ampiezza ad alta frequenza è stata evidenziata da scoperte recenti [28] che indicano la frequente sincronizzazione dei ritmi cerebrali a bassa frequenza con eventi sensoriali esterni e motori, così come dai processi cognitivi interni associati alla presa di decisioni, motivazione e memoria. In altre parole, la sincronizzazione della fase a bassa frequenza, combinata con il CFC fase-ampiezza, offre un meccanismo convincente per coordinare la computazione e la comunicazione basate su eventi ad alta frequenza con gli eventi di stato esterni e interni più lenti che influenzano la percezione, la cognizione e l'azione [28].

I metodi convenzionali per calcolare il PAC si basano sulla trasformata di Hilbert [26] dei dati neurofisiologici filtrati in banda passante per estrarre dal segnale le componenti in ampiezza e fase. L'approccio tradizionale al calcolo del PAC si compone dei seguenti tre passaggi:

1. filtraggio passa-banda dei dati di input nelle bande di interesse, ad esempio theta e gamma;
2. applicazione della trasformata di Hilbert per estrarre le serie temporali di ampiezza e fase da ciascuna banda di frequenza di interesse;
3. quantificazione della relazione tra le serie temporali di fase e ampiezza.

In conclusione, l'integrazione del CFC nella fase di elaborazione del segnale

nelle BMI, in particolare in quelle basate sull'immaginazione motoria, offre significativi vantaggi teorici e pratici. Il CFC, caratterizzando l'interazione tra oscillazioni neuronali di diverse bande di frequenza, permette di cogliere la complessa dinamica del cervello umano che non può essere rilevata attraverso l'analisi di singole bande di frequenza. La capacità del CFC di riflettere l'interazione tra diverse regioni cerebrali e bande di frequenza è cruciale per comprendere i meccanismi di scambio di informazioni della corteccia cerebrale durante compiti cognitivi. Integrare il CFC nell'estrazione delle caratteristiche EEG consente una più stretta correlazione tra le misure di attività cerebrale e le informazioni rilevanti per la classificazione. Questo non solo facilita una maggiore precisione nella decodifica dei segnali, ma anche un'analisi più approfondita dei processi cognitivi e delle risposte neurali, migliorando complessivamente l'efficacia delle BMI [29].

2 | Motivazioni ed obiettivi della tesi

L'estrazione delle features dai segnali EEG è cruciale nelle *Brain-Machine Interface*, poiché influisce significativamente sulle prestazioni del sistema. Le BMI si basano sull'interpretazione accurata dei segnali cerebrali per tradurre l'attività mentale in comandi utilizzabili, rendendo essenziale che le caratteristiche estratte dai segnali EEG siano rappresentative e discriminanti rispetto agli stati mentali desiderati. In questo contesto, lo sviluppo di tecniche di estrazione delle features sempre più efficaci è fondamentale per il progresso e l'applicabilità pratica delle BMI.

Le attuali metodologie di estrazione delle features nelle BMI si focalizzano spesso su tecniche tradizionali. Tuttavia, queste tecniche possono non essere sufficientemente robuste per catturare la complessità e la variabilità dei segnali EEG [6]. Recenti studi hanno dimostrato che il CFC, in particolare il PAC, può fornire informazioni aggiuntive cruciali che migliorano la discriminazione degli stati mentali [30]. L'integrazione del PAC nelle tecniche di estrazione delle caratteristiche permette di migliorare la sensibilità e la specificità delle BMI.

L'obiettivo principale di questo lavoro è introdurre e validare sperimentalmente un algoritmo innovativo per ottenere features discriminanti affidabili dai segnali EEG, al fine di migliorare le prestazioni della classificazione nelle BMI. Questa tesi propone di esplorare l'efficacia di un metodo che combina

l'approccio riemanniano con il CFC, utilizzando il PAC per l'estrazione delle features e il calcolo di matrici SPD di covarianza inter-canale. La sperimentazione è condotta nell'ambito della MI basata su EEG, un paradigma in cui ai partecipanti è richiesto di immaginare il movimento di specifici arti senza eseguire alcun movimento fisico. Questo approccio sfrutta l'attivazione delle stesse aree cerebrali coinvolte nel movimento reale, permettendo di utilizzare le informazioni EEG per il controllo delle BMI.

Il metodo proposto si articola in tre fasi principali. In primo luogo, vengono calcolate le matrici SPD di covarianza utilizzando i segnali EEG pre-processati e integrando il PAC per catturare le interazioni tra bande di frequenza distinte. Queste matrici rappresentano le features dei segnali EEG in uno spazio di covarianza, particolarmente adatto per l'analisi geometrica riemanniana. Successivamente, le matrici SPD ottenute vengono proiettate su un manifold riemanniano, dove tecniche di classificazione specifiche per tale spazio geometrico, vengono applicate per discriminare gli stati mentali associati alle diverse condizioni di MI. Infine, l'efficacia del metodo proposto viene validata confrontando le prestazioni di classificazione con quelle ottenute utilizzando tecniche tradizionali di estrazione delle caratteristiche. Questo approccio mira a migliorare le BMI riemanniane introducendo caratteristiche neurofisiologiche innovative, non esplorate nelle convenzionali BMI riemanniane, con l'obiettivo di fornire una rappresentazione più ricca e discriminante dei segnali EEG, migliorando l'affidabilità delle BMI.

3.1 Protocollo di training

I dati del segnale EEG sono stati acquisiti nell'ambito di un lavoro di ricerca pregresso che propone un protocollo di training innovativo che esplora l'uso BMI collaborative (cBMI). Questo approccio, che si basa sulla cooperazione di due soggetti, è stato testato attraverso il controllo endogeno di un braccio robotico reale tramite una BMI basata sulla MI. Come discusso precedentemente, un paradigma endogeno consente ai soggetti di avviare autonomamente compiti mentali senza la necessità di stimoli esterni rendendo l'interazione con il sistema robotico più naturale. Tuttavia, raggiungere prestazioni soddisfacenti nell'utilizzo delle BMI basate sull'immaginazione motoria rappresenta una sfida impegnativa per i soggetti, che richiede un lungo ed intenso allenamento. Basse prestazioni potrebbero causare frustrazione negli utenti. Al fine di superare questa difficoltà, i ricercatori hanno proposto la cBMI, un metodo di allenamento alternativo in cui due soggetti sono contemporaneamente coinvolti nello stesso task e l'output delle loro BMI viene combinato per migliorare l'accuratezza della decodifica o aumentare il numero di comandi. La logica sulla quale si fonda questa tecnica all'avanguardia prevede che la presenza di un secondo soggetto possa aiutare quello meno competente a completare l'attività, riducendo stati mentali neg-

ativi. Questo approccio permette quindi di aumentare sia le prestazioni complessive, ma anche di favorire l'apprendimento di entrambi i soggetti [31].

3.2 Acquisizione dei dati

I partecipanti coinvolti nell'acquisizione del segnale EEG sono sei soggetti sani, con un'età media di 25 ± 2 anni, suddivisi in tre coppie (G1-C7, G2-D7, C9-C8). Le sessioni di rilevazione si sono svolte tra Dicembre 2023 e Gennaio 2024.

La sperimentazione comprende sei sessioni, ciascuna suddivisa in tre *run*. La sessione iniziale (Giorno 0) ha coinvolto la calibrazione e la valutazione del decodificatore BMI di ciascun soggetto. Le sessioni successive (Giorno 1-5) si sono concentrate su *run* in tempo reale, durante le quali i soggetti hanno testato il decodificatore addestrato, riaddestrandolo se necessario, e successivamente hanno controllato il braccio robotico in collaborazione con un altro soggetto.

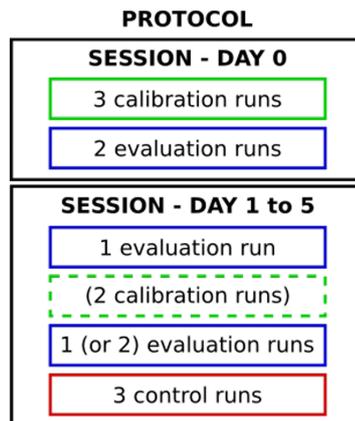


Figure 3.1 Divisione delle sessioni

È stato impiegato un paradigma di MI a 2 classi in cui ai soggetti è stato richiesto di immaginare il movimento dei loro piedi o delle loro mani.

Le *run* possono essere di tre tipi:

1. *Calibration*: E' stato chiesto al soggetto di eseguire 10 prove di immaginazione delle mani, 10 prove di immaginazione dei piedi e prove di riposo, fornendo sempre un feedback positivo con l'interfaccia visiva.
2. *Evaluation*: Il feedback è controllato dall'output della BMI e al soggetto è stato chiesto di eseguire 10 prove per ciascuna classe di MI.
3. *Control*: I soggetti controllano il braccio robotico utilizzando la cBMI proposto. Durante il controllo del robot, l'output del decodificatore BMI di ciascun soggetto nella coppia è stato fuso per consentire il controllo collaborativo del sistema robotico.

Tuttavia, i dati di interesse per il presente lavoro riguardano esclusivamente le *run* di calibration ed evaluation.

Durante le fasi di controllo, i partecipanti sono stati incaricati di guidare un braccio robotico dalla posizione iniziale a uno dei cinque oggetti target disposti su un cerchio con raggio di 50 cm di fronte al robot. Ai partecipanti è stato concesso di osservare il robot e lo spazio di lavoro su un monitor, dove è stato sovrapposto un feedback visivo. All'inizio di ogni prova, è stato presentato ai partecipanti un oggetto target da selezionare, indicato da un punto blu, per 1 s (periodo di cue). Successivamente, il movimento del robot è stato avviato in base all'output del cBMI. Una volta sufficientemente vicino a un oggetto, il robot ha eseguito autonomamente la presa, è tornato alla posizione iniziale e una nuova prova è stata avviata. In ciascun *run*, i partecipanti sono stati invitati a selezionare ciascuno dei cinque oggetti due volte, per un totale di dieci prove.

I dati elettroencefalografici sono stati acquisiti tramite un amplificatore attivo a 64 canali operante a una frequenza di campionamento di 512 Hz. Successivamente sono stati selezionati 20 elettrodi tra quelli illustrati nella

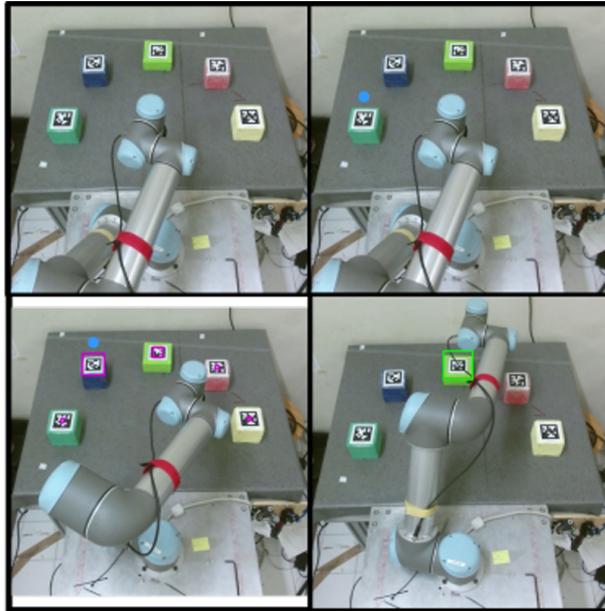


Figure 3.2 Feedback visivo per il controllo del braccio robotico

figura 1.3 per rilevare i pattern neurali correlati alla MI: FC5, FC1 FC2, FC6, C3, CZ, C4, CP5, CP1, CP2, CP6, FC3, FCZ, FC4, C5, C1, C2, C6, CP3, CP4.

3.3 Pre-processing

I dati del segnale EEG sono stati forniti sotto forma di una matrice di dimensioni $T \times M$ dove, T è il numero di campioni e M è il numero di canali.

In primo luogo, il segnale EEG è stato filtrato tramite filtri Butterworth, una tipologia di filtri caratterizzata da una risposta in ampiezza monotona. Nel dettaglio sono stati progettati due filtri: un filtro Butterworth passa-alto e passa-basso di ordine 4. Entrambi i filtri sono stati successivamente applicati alle matrici del segnale EEG al fine di ottenere un filtro passa-banda.

Dopo l'applicazione dei filtri si ottiene una matrice $T \times M$ che rappresenta il segnale EEG filtrato, ovvero privato del rumore e delle bande di

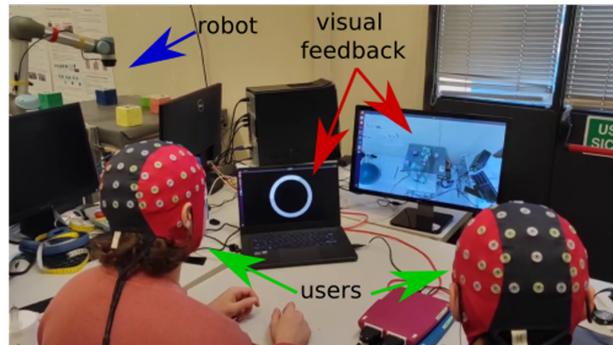


Figure 3.3 Set-up sperimentale in cui entrambi i soggetti controllano il manipolatore

frequenza non di interesse.

Dopodichè, dalla matrice del segnale EEG vengono selezionate esclusivamente le finestre di campioni corrispondenti al *continuous feedback* di ciascun evento, ovvero dell'immaginazione motoria di entrambi i piedi oppure dell'immaginazione motoria di entrambe le mani. I dati ottenuti vengono inseriti in due matrici di dimensione $T \times M$: una nella quale sono inseriti i dati del segnale EEG corrispondente all'immaginazione motoria dei piedi e una a quella delle mani.

3.4 Estrazione delle features

In questo studio, le features dei segnali EEG sono state estratte utilizzando matrici di covarianza incrociate, che tengono conto sia della varianza che della covarianza dei segnali registrati dai diversi canali EEG. L'analisi delle matrici di covarianza come features si presta ad un'esplorazione nello spazio geometrico riemanniano in quanto tali matrici sono simmetriche e definite positive. In particolare, nel contesto di questa tesi, vengono proposte tre matrici SPD che tengono conto delle fasi e delle ampiezze dei segnali all'interno e tra le diverse bande di frequenza. Nello specifico, le bande di frequenza che

sono state considerate sono: δ : 1-4 Hz, θ : 4-8 Hz, α : 8-13 Hz, β : 13-30 Hz, γ : 30-90 Hz. È importante notare che un segnale oscillatorio, come l'elettroencefalogramma (EEG), è caratterizzato sia da ampiezze che da fasi, e le interazioni tra queste caratteristiche all'interno delle diverse bande di frequenza possono avere un ruolo cruciale nell'organizzazione delle reti neurali su larga scala e nell'integrazione delle attività cerebrali tra diverse regioni funzionali [32]. Le tre matrici di covarianza sono state valutate sia singolarmente che in combinazione, al fine di determinarne l'efficacia nel catturare le relazioni complesse tra le attività cerebrali rappresentate dai segnali EEG.

3.4.1 Geometria di Riemann per la classificazione di EEG

Come descritto in precedenza, nel campo delle applicazioni delle BMIs vengono sfruttate delle tecniche che fanno anche uso di uno spazio diverso da quello euclideo come per esempio la geometria di Riemann.

Matrice di covarianza

Sia $X \in \mathbb{R}^{T \times M}$ la matrice di campioni di segnale EEG filtrato con M canali e T campioni. La sua matrice di covarianza è definita come:

$$C_X = \frac{1}{T-1} X X^T \in \mathbb{R}^{M \times M}. \quad (3.1)$$

Gli elementi sulla diagonale rappresentano l'autocovarianza del segnale di ciascun canale, mentre gli elementi al di fuori di essa contengono la covarianza di ciascuna coppia di canali. Quando il numero di campioni temporali è abbastanza grande rispetto al numero di canali, la covarianza stimata è empiricamente a rango completo, ovvero caratterizzata dal numero massimo di righe o colonne linearmente indipendenti, e quindi SPD.

Distanza Riemanniana

Lo spazio di Riemann può essere inteso come uno spazio curvo dove la covarianza viene calcolata lungo geodetiche, ovvero curve che rappresentano la lunghezza minima tra due punti su una superficie curva.

Date due matrici di covarianza C_1 e C_2 che costituiscono due punti dello spazio curvo, la distanza δ_r è una distanza che rispetta la curvatura originale dello spazio ed è definita dall'equazione 1.3

Proiezione nello spazio tangente

Su una superficie liscia M , i vettori tangenti possono essere definiti in $p \in M$, e l'insieme dei vettori tangenti definisce uno spazio euclideo chiamato spazio tangente T_p . Quando l'insieme delle matrici SPD è concentrato localmente, lo spazio tangente è l'approssimazione locale dello spazio dell'insieme delle matrici SPD. Sia $\{C_i\}_{i=1,2,\dots,N}$ un insieme di matrici SPD, la proiezione di C_i sullo spazio tangente in C è definita come:

$$v_i = \text{Upper} \left(\log \left(\bar{C}^{-\frac{1}{2}} C_i \bar{C}^{-\frac{1}{2}} \right) \right) \in \mathbb{R}^{M(M+1)/2} \quad (3.2)$$

dove $\text{Upper}(\cdot)$ è un operatore di semivettorizzazione che applica pesi unitari agli elementi della diagonale e $\sqrt{2}$ agli elementi fuori dalla diagonale di una data matrice e $\log(\cdot)$ è il logaritmo matriciale principale. In questo lavoro, C è stimato dalla media Riemanniana dell'intero insieme di matrici SPD. Il tangent space mapping (TSM) è una tecnica utilizzata per facilitare la classificazione di matrici simmetriche definite positive, come le matrici di covarianza, proiettando queste matrici complesse in uno spazio più semplice e lineare (spazio tangente). Poiché lo spazio tangente è uno spazio euclideo, il TSM consente di classificare le matrici SPD vettorizzate applicando qualsiasi

classificatore basato su vettori..

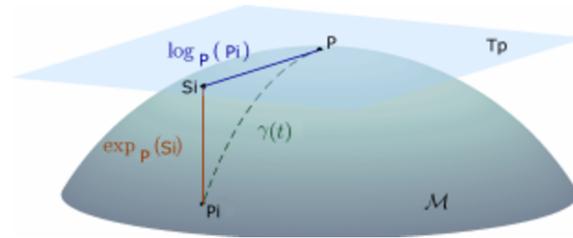


Figure 3.4 Spazio tangente del manifold

3.5 Metodi proposti

Di seguito vengono illustrati i metodi di estrazione delle features dei quali è stata valutata l'efficacia sperimentale. Su ciascuna delle matrici, risultanti dall'elaborazione del segnale EEG tramite filtri passa-banda per l'estrazione delle frequenze di interesse, viene calcolata la matrice di covarianza. La metodologia usata prevede la suddivisione del segnale di ciascun canale EEG in finestre di dimensione fissa, pari a 512 campioni pari ad un secondo di segnale. Sulle finestre si agisce attraverso un processo di traslazione, con uno spostamento di 32 campioni rispetto alla finestra precedente. Su ciascuna finestra di dati così ottenuta, viene calcolata la matrice di covarianza. Questo procedimento viene iterato su tutte le finestre, generando infine una matrice di covarianza tridimensionale.

3.5.1 Baselines

I primi due approcci di estrazione delle features rappresentano le linee guida, i cui risultati saranno successivamente confrontati con quelli ottenuti mediante metodi più innovativi al fine di valutare la loro efficacia.

Ciò che distingue tra loro questi primi due metodi sono le bande di frequenza con cui il segnale EEG viene filtrato nella fase di pre-processing.

1. **Primo metodo:** il segnale EEG viene filtrato con la coppia di bande di frequenza $[\theta, \alpha]$. Questa coppia è stata scelta in quanto è nota per essere associata ai cambiamenti del carico mentale [33].
2. **Secondo metodo:** la matrice di dati del segnale EEG viene filtrata con la coppia di bande di frequenza $[\beta, \gamma]$.

In entrambi gli approcci, il segnale EEG viene filtrato con le due bande di frequenza distinte in modo tale da ottenere poi due matrici di covarianza che verranno successivamente concatenate lungo la dimensione delle features.

3.5.2 Accoppiamento fase-ampiezza (PA Cov)

La scelta di esplorare il CFC fase-ampiezza è stata guidata dalle evidenze scientifiche che sottolineano la sua importanza nei processi cognitivi, come la memoria e la presa di decisioni [34, 35]. Il segnale originale viene filtrato due volte in maniera distinta sulle bande β e γ . Per estrarre le fasi e le ampiezze del segnale è stata utilizzata la trasformata di Hilbert [35]. Successivamente, è stata generata una matrice di dati definita:

$$X_{PA} = \begin{pmatrix} \cos(\phi_{f_L}(t)) \\ \sin(\phi_{f_L}(t)) \\ a_{f_H}(t) \end{pmatrix} \in \mathbb{R}^{3M \times T} \quad (3.3)$$

dove $\phi_{f_i}(t)$ indica la fase delle basse frequenze e $a_{f_h}(t)$ l'ampiezza delle alte frequenze in un dato istante t calcolate per ciascun canale. L'approccio descritto porta alla generazione di una matrice di covarianza tridimensionale delle dimensioni $finestre \times 3 * canali \times 3 * canali$.

3.5.3 Accoppiamento fase-ampiezza diretto (dPAC Cov)

Come nel metodo precedente il segnale originale viene filtrato due volte in maniera distinta sulle bande β e γ . La matrice di covarianza del CFC fase-ampiezza misura come le variazioni di fase e ampiezza dei segnali EEG di un singolo canale sono correlate con quelle degli altri canali. Viene inizialmente costruita la matrice di dati:

$$X_{dPAC} = \begin{pmatrix} \frac{|a_{f_H} e^{i\phi_{f_L}(t)}|_{ch1}}{\sqrt{T} \sum_{t=1}^T a_{f_H}(t)_{ch1}^2} \\ \frac{|a_{f_H} e^{i\phi_{f_L}(t)}|_{ch2}}{\sqrt{T} \sum_{t=1}^T a_{f_H}(t)_{ch2}^2} \\ \vdots \\ \frac{|a_{f_H} e^{i\phi_{f_L}(t)}|_{chM}}{\sqrt{T} \sum_{t=1}^T a_{f_H}(t)_{chM}^2} \end{pmatrix} \in \mathbb{R}^{M \times T} \quad (3.4)$$

dove $e^{i\phi_{f_L}(t)}$ rappresenta la formula di Eulero della fase ϕ_{f_L} . Il numeratore è il valore assoluto del segnale complesso di ciascun canale, mentre il denominatore è un fattore di normalizzazione basato sull'ampiezza di ciascun canale. Si ottiene quindi una matrice di features C_{dPAC} trdimensionale di dimensioni *finestre* \times *canali* \times *canali*.

3.5.4 Covarianza delle frequenze incrociate (crossFB Cov)

Il terzo metodo proposto permette di valutare l'interazione tra bande di frequenza diverse all'interno del segnale EEG. La coppia di bande di frequenza scelta per questa analisi è composta dalle bande β e γ , in quanto queste sono risultate essere le più efficaci in tutti i soggetti coinvolti nello studio [35]. Per applicare questo metodo, il segnale EEG è stato filtrato nelle bande di frequenza specifiche, β e γ , ottenendo così due matrici di segnale EEG separate. Queste due matrici sono state poi concatenate lungo la dimensione dei canali, creando una singola matrice composta dai segnali EEG filtrati nelle

due bande di frequenza specificate:

$$X_{\text{crossFB}} = \begin{pmatrix} X_{\beta}(t) \\ X_{\gamma}(t) \end{pmatrix} \in \mathbb{R}^{2M \times T} \quad (3.5)$$

Successivamente, con il metodo di finestatura è stata calcolata la matrice di covarianza $C_{\text{crossFB}} \in \mathbb{R}^{2M \times 2M}$. La matrice di covarianza così ottenuta permette di rappresentare due tipi di correlazioni: le correlazioni all'interno della stessa banda di frequenza e le correlazioni tra bande di frequenza diverse. In particolare la matrice di covarianza è strutturata in modo tale che la correlazioni all'interno della stessa banda di frequenza siano rappresentate dagli elementi lungo la diagonale principale, mentre le correlazioni tra bande di frequenza diverse sono rappresentate dagli elementi fuori da essa.

3.5.5 Vettorizzazione delle matrici di covarianza

Quando si intende utilizzare una matrice di covarianza come features in un classificatore, la scelta più naturale è vettorizzarla. Questo consente di trattare la matrice come un vettore, rendendola compatibile con qualsiasi algoritmo di classificazione basato su vettori. Per ottenere questo risultato, è necessario applicare un'operazione di semi-vettorizzazione su ciascuna delle cinque matrici precedentemente costruite, come descritto nella formula 3.2. In particolare, la vettorizzazione viene eseguita su ciascuna matrice bidimensionale corrispondente a una finestra della matrice di covarianza. Questo significa che per ogni finestra della matrice di covarianza tridimensionale si genera un vettore ottenendo una matrice bidimensionale di dimensioni $\text{finestre} \times \text{features}$, che verrà poi utilizzata nel classificatore. In riferimento alle matrici di covarianza ottenute tramite le baselines, si erano ottenute due matrici di covarianza separate, una per ciascuna banda di frequenza appli-

cata. In questo caso specifico, viene applicato il TSM su ciascuna matrice di covarianza per la singola banda di frequenza. Dopodichè, le matrici vettorizzate di features vengono concatenate lungo la dimensione delle features, ottenendo anche in questo caso una matrice bidimensionale di dimensioni $finestre \times features$

3.5.6 Combinazione dei metodi proposti (Fusion)

Dopo aver valutato singolarmente i singoli metodi di estrazioni delle features, si è valutata la loro prestazione combinando tra loro tali approcci. Questo ultimo metodo, che consiste quindi l'unione dei precedenti, prevede di partire dalla tre matrici di covarianza PA, dPAC e crossFB, sulle quali è già stato applicato il TSM, e concatenare tra loro le tre matrici vettorizzate lungo la dimensione delle features. Questo vettore concatenato contiene diverse scale di caratteristiche, inclusi molteplici filtri di banda di fase, ampiezza e valori di PAC. Sul vettore risultante dalla concatenazione è stata applicata una normalizzazione che elabora i dati affinché abbiano una media zero e una deviazione standard unitaria in modo tale da garantire un confronto equo tra i vettori di caratteristiche di tutti i metodi.

Tuttavia, nella fase di verifica dell'efficacia della classificazione delle matrici si è evidenziato come il metodo PA fosse inadeguato nella discriminazione degli stati mentali di MI. Per questo motivo, confrontando i risultati ottenuti nel metodo Fusion concatenando la matrice di covarianza PA e non concatenandola, si è valutato di escluderla dal metodo Fusion in quanto questo consentiva di ottenere valori di accuratezze nettamente superiori.

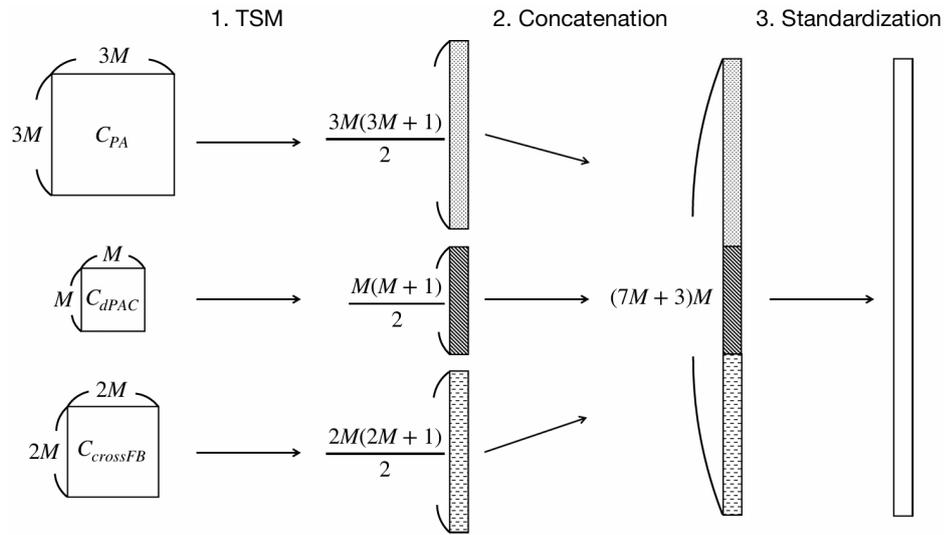


Figure 3.5 Processo di fusione di tre diverse rappresentazioni SPD

3.6 Classificazione

Le features estratte sono state utilizzate per addestrare un classificatore basato sulla Ridge Regression.

3.6.1 Ridge Regression

Questo approccio è stato scelto per la sua capacità di gestire la multicollinearità tra le caratteristiche e di prevenire l'overfitting, fornendo al contempo una soluzione robusta per la classificazione.

La Ridge Regression modifica la funzione di costo della regressione lineare standard aggiungendo un termine di penalità. La funzione di costo diventa:

$$J(\beta) = \sum_{i=1}^n (y_i - \mathbf{x}_i \cdot \beta)^2 + \lambda \sum_{j=1}^p \beta_j^2$$

dove λ è il parametro di penalizzazione che controlla l'importanza della penalizzazione e β rappresenta il vettore dei coefficienti del modello di re-

gressione. Un valore più grande di λ porta a una maggiore penalizzazione dei coefficienti, riducendo così la varianza ma aumentando il bias.

3.6.2 Processo di Classificazione

L'implementazione della Ridge Regression è stata effettuata utilizzando la funzione `ridge` di MATLAB, che risolve il problema di minimizzazione sopra descritto.

Il processo di classificazione è stato suddiviso in tre fasi principali: *training*, *validation* e *test*. Durante la fase di *training*, il modello è stato addestrato utilizzando il 70% dei dati di *calibration*. Questi dati di calibrazione contengono esempi noti di segnali EEG associati a specifici stati cognitivi, e vengono utilizzati per addestrare il modello di Ridge Regression a riconoscere i pattern caratteristici di ciascuno stato. Una volta addestrato il modello, si passa alla fase di *validation*, in cui il modello viene validato utilizzando il restante 30% dei dati di *calibration* non utilizzati durante l'addestramento. Il modello che ottiene le migliori prestazioni durante la fase di *validation* viene poi applicato ai dati di *evaluation* durante la fase di *test*. I dati di *evaluation* sono nuovi campioni di segnali EEG che non sono stati utilizzati durante la fase di training. L'obiettivo della fase di *test* è valutare l'accuratezza del modello su questi nuovi campioni.

Il processo di classificazione inizia con la preparazione delle label, le quali rappresentano le due classi dell'immaginazione motoria che vengono concatenate per formare un unico vettore di label. Successivamente, si procede con l'addestramento del modello utilizzando la Ridge Regression. Questo modello viene addestrato sui dati di *calibration*, dove la matrice delle features precedentemente calcolata serve come input e il vettore delle label come target. Tra i vari modelli addestrati, viene selezionato quello con l'accuratezza

più elevata durante la fase di *validation*.

Per il modello addestrato selezionato, si effettuano predizioni sui dati di input di *evaluation*. Queste predizioni, inizialmente continue, vengono poi convertite in etichette binarie (0 e 1) utilizzando una soglia. Le predizioni vengono quindi confrontate con le label originali per determinare il numero di coincidenze corrette, ossia il numero di predizioni accurate.

L'accuratezza viene calcolata dividendo il numero di predizioni corrette per il numero totale di campioni, come mostrato nella seguente formula:

$$\text{accuracy} = \frac{\text{numero di predizioni corrette}}{\text{numero totale di predizioni}}$$

valutando così le sue prestazioni finali.

4 | Risultati

Lo scopo di questo studio è stato valutare l'efficacia di diversi approcci di estrazione delle caratteristiche nel contesto di compiti di MI, utilizzando segnali EEG raccolti da sei soggetti durante più sessioni. I risultati vengono esposti attraverso tabelle e grafici che mostrano le accuratezze dei vari metodi di estrazione delle caratteristiche. Queste accuratezze rappresentano la capacità dei modelli di classificare correttamente gli stati cognitivi dei soggetti basati sui segnali EEG raccolti.

La Tabella 4.1 fornisce una panoramica dettagliata delle accuratezze medie e delle relative deviazioni standard, calcolate considerando tutti i soggetti, per i sei diversi metodi di estrazione delle features utilizzati durante le cinque sessioni sperimentali. Ciascuna riga della tabella rappresenta una sessione sperimentale, mentre le colonne riportano i risultati per ciascun metodo di estrazione delle caratteristiche.

Il metodo $C[\theta, \alpha]$ ha mostrato accuratezze medie variabili da un minimo di 0.601 nella prima sessione a un massimo di 0.637 nella quinta sessione. Il metodo $C[\beta, \gamma]$ ha evidenziato accuratezze medie tra 0.553 nella prima sessione e 0.610 nella quinta sessione. Il metodo PA ha ottenuto le performance peggiori, con accuratezze medie che variano tra 0.491 e 0.501, suggerendo che i risultati sono inefficaci, quindi non adeguati per i dati analizzati in questo studio. Al contrario, il metodo dPAC ha mostrato accuratezze medie com-

Table 4.1 Accuratezze medie e deviazioni standard per i diversi metodi di estrazione delle caratteristiche

Metodo	Sessione 1	Sessione 2	Sessione 3	Sessione 4	Sessione 5
C$[\theta, \alpha]$	60.1 \pm 11.9	62.3 \pm 9.5	61.1 \pm 10.4	62.6 \pm 9.5	63.7 \pm 7.9
C$[\beta, \gamma]$	55.3 \pm 2.7	56.6 \pm 2.9	61.6 \pm 4.7	57.5 \pm 1.5	61.0 \pm 3.7
PA	49.8 \pm 0.73	50.1 \pm 0.6	50.1 \pm 1.2	49.2 \pm 0.9	49.1 \pm 0.7
dPAC	61.4 \pm 4.7	63.2 \pm 4.1	65.2 \pm 4.2	63.0 \pm 3.5	66.0 \pm 2.2
crossFB	64.4 \pm 3.6	65.7 \pm 3.4	67.6 \pm 5.9	67.4 \pm 3.9	71.4 \pm 3.7
Fusion	68.4 \pm 3.8	70.0 \pm 4.7	66.2 \pm 7.8	70.0 \pm 3.1	73.6 \pm 2.3

prese tra 0.614 nella prima sessione e 0.652 nella terza sessione. Il metodo crossFB ha presentato accuratezze medie che variano tra 0.644 nella prima sessione e 0.714 nella quinta sessione, suggerendo una buona consistenza nei risultati. Infine, il metodo Fusion ha ottenuto le performance migliori, con accuratezze medie che vanno da 0.662 nella terza sessione a 0.736 nella quinta sessione.

Analizzando le diverse sessioni, emerge che la quinta sessione ha generalmente prodotto le migliori accuratezze per la maggior parte dei metodi; al contrario, la prima sessione ha generalmente prodotto le accuratezze più basse. Osservando l'andamento tra le varie sessioni, si nota una tendenza generale al miglioramento delle accuratezze man mano che si procede con le sessioni. Questa tendenza è particolarmente evidente nei metodi Fusion, crossFB e dPAC, che mostrano un incremento costante delle accuratezze dalle prime alle ultime sessioni. Nei metodi C $[\theta, \alpha]$ e C $[\beta, \gamma]$ si può osservare un andamento fluttuante con un iniziale aumento delle accuratezze, una lieve decrescita nella quarta sessione e un nuovo aumento nella quinta sessione. Questo miglioramento complessivo potrebbe essere attribuito all'adattamento progressivo dei soggetti all'interfaccia BMI e al

training ripetuto, che può aver contribuito a migliorare la loro capacità di generare segnali EEG più consistenti e distintivi.

Nel contesto della valutazione delle accurattezze ottenute dai vari metodi di estrazione delle caratteristiche per la BMI, è stato creato un grafico a barre (Figura 4.1) per rappresentare in modo visivo e comparativo le prestazioni di ciascun metodo. Questo grafico riassume i dati raccolti durante cinque diverse sessioni per ogni soggetto e permette di confrontare direttamente le performance medie dei metodi su un insieme di sessioni evidenziando le differenze in termini di accuratezza.

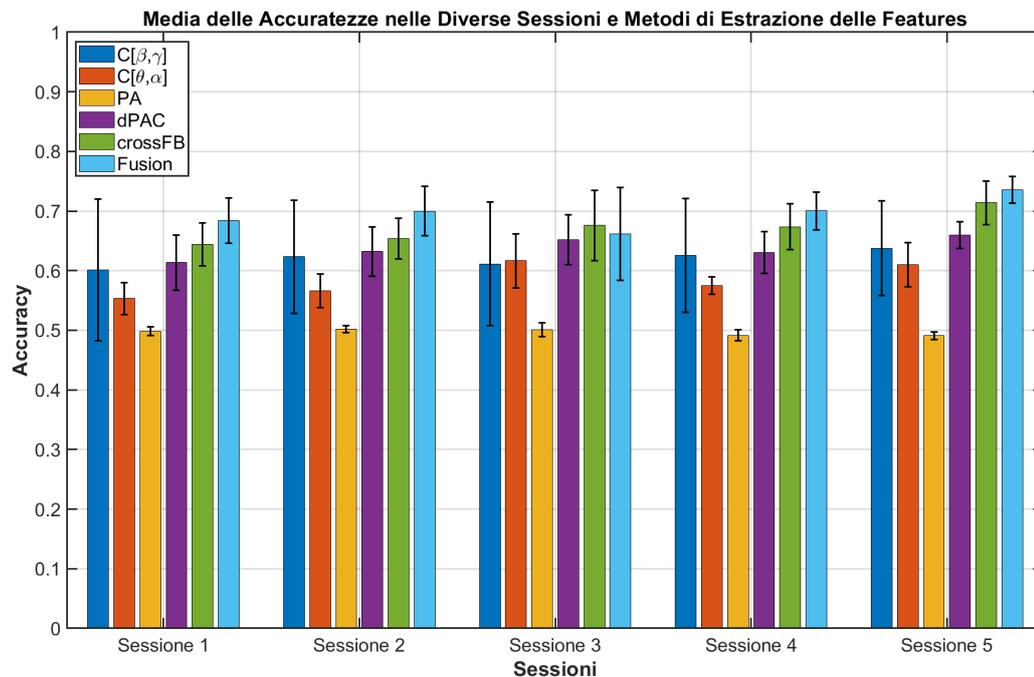


Figure 4.1 Accuratezze medie dei soggetti nelle diverse sessioni e tra i diversi metodi utilizzati nella fase di estrazione delle features

Per fornire un'analisi dettagliata della distribuzione delle accurattezze ottenute dai vari metodi di estrazione delle caratteristiche, è stato utilizzato il grafico 4.2. Questo tipo di grafico è particolarmente utile per visualizzare la dispersione dei dati e identificare eventuali outliers, ma anche per compren-

dere la consistenza delle performance dei metodi su più sessioni.

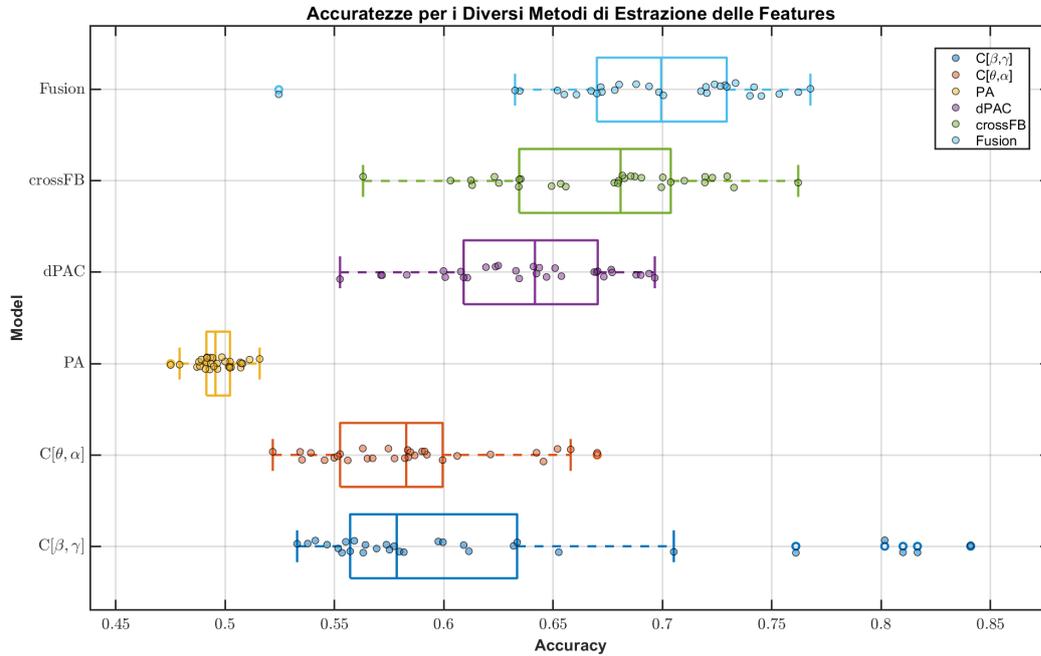


Figure 4.2 Rappresentazione grafica della distribuzione delle accuratze

Si può osservare che i metodi $C[\theta, \alpha]$ e $C[\beta, \gamma]$ mostrano una variabilità significativa. Il metodo dPAC, con punti concentrati principalmente tra 0.6 e 0.65 e metodo crossFB con punti distribuiti tra 0.65 e 0.7, mostrano una variabilità intermedia. Questo suggerisce che questi metodi è relativamente stabili, sebbene presentino una certa fluttuazione tra le sessioni. Il metodo Fusion mostra una variabilità più contenuta rispetto agli altri metodi, con punti distribuiti tra 0.7 e 0.75, probabilmente dovuta alla combinazione di più tecniche di estrazione delle caratteristiche.

5 | Discussione

I risultati delle accuratèzze sono stati confrontati con quelli riportati nello studio "Novel SPD matrix representations considering cross-frequency coupling for EEG classification using Riemannian geometry" [35].

Sebbene le performance ottenute in questo lavoro siano inferiori rispetto a quelle previste, è importante sottolineare alcuni aspetti chiave e miglioramenti rilevati. Innanzitutto, si può individuare la causa delle accuratèzze medie inferiori a quelle attese nel fatto che il task assegnato agli utenti durante l'acquisizione del segnale EEG, ovvero task di MI, sia completamente diverso e molto più complesso rispetto a quelli proposti nello studio sopra citato in cui i partecipanti hanno eseguito compiti di N-back in cui dovevano memorizzare l'ordine dei numeri e rispondere se il numero corrente corrispondeva a quello apparso n volte prima. Di conseguenza gli stati cognitivi risultano più difficili da classificare e questo potrebbe spiegare le prestazioni inferiori.

Per quanto riguarda invece lo scopo finale della sperimentazione, ovvero verificare che i metodi innovativi proposti esibissero effettivamente dei miglioramenti rispetto alle baselines tradizionali, è stato raggiunto con esito positivo, in quanto i metodi dPAC, crossFB e Fusion evidenziano delle accuratèzze superiori rispetto ai metodi $C[\theta, \alpha]$ e $C[\beta, \gamma]$, suggerendo che le caratteristiche estratte da queste tecniche sono più stabili e generalizzabili attraverso

diverse sessioni e soggetti. Nello specifico, il metodo dPAC ha mostrato accuratèzze variabili ma generalmente superiori alle baseline del 5-10% circa, con accuratèzze medie intorno al 60-65%. Questi risultati indicano che dPAC è in grado di cogliere informazioni rilevanti per la classificazione degli stati cognitivi, sebbene la sua efficacia possa essere influenzata dalla variabilità individuale. Il metodo crossFB ha mostrato accuratèzze medie intorno al 65-70%, superiori del 5% circa a quelle ottenute con dPAC e del 10-15% a quelle ottenute con $C[\theta, \alpha]$ e $C[\beta, \gamma]$. I risultati suggeriscono che crossFB riesce a catturare pattern di attività cerebrale che possono essere trascurati quando si analizzano le bande di frequenza in modo isolato, migliorando così la capacità di discriminare tra diversi stati cognitivi. Il metodo Fusion ha dimostrato di essere il più efficace, con accuratèzze del 70-75%, superiori rispetto ai singoli metodi $C[\theta, \alpha]$ e $C[\beta, \gamma]$ del 20% circa, del 10% al metodo PA e del 5% al metodo crossFB. Questo suggerisce che l'integrazione di caratteristiche neurofisiologiche multiple possa migliorare la discriminabilità delle classi cognitive. La maggiore accuratèzza nel metodo Fusion indica che questo approccio può fornire risultati più affidabili e consistenti rispetto ai singoli metodi.

I risultati del metodo PA sono stati invece particolarmente scadenti, mostrando un'accuratèzza intorno al 50% già nella fase di *training*. Un'accuratèzza di questo livello è equivalente a quella ottenuta tramite una classificazione casuale per un problema binario, indicando che il metodo PA non riesce a catturare efficacemente le caratteristiche distintive necessarie per una classificazione accurata degli stati cognitivi. Di conseguenza, si ritiene che questo approccio non sia utilizzabile con i task di MI.

A causa delle prestazioni insoddisfacenti del metodo PA, il metodo Fusion è stato modificato per escludere le features estratte tramite il metodo PA e includere solo dPAC e crossFB. Questa scelta è stata motivata da un

confronto tra i risultati ottenuti con e senza l'inclusione del metodo PA. Con PA, l'accuratezza risultava intorno al 50%, mentre senza PA si raggiungeva un'accuratezza del 70%. Pertanto, il metodo Fusion è stato costruito concatenando solo le features estratte tramite i metodi dPAC e crossFB, risultando nel metodo con le prestazioni migliori tra tutti quelli testati.

Eseguendo un confronto con lo studio di riferimento sui risultati ottenuti, si può osservare che questo ha riportato miglioramenti significativi utilizzando rappresentazioni di matrici SPD che considerano il CFC. In particolare, il modello Fusion di tre matrici di covarianza CFC ha mostrato un incremento dell'accuratezza media del 18% rispetto alla matrice di covarianza convenzionale nelle bande theta e alpha, e del 4% nelle bande beta e gamma. Nel presente lavoro, sebbene non siano stati raggiunti tali incrementi, il metodo Fusion ha comunque dimostrato un potenziale miglioramento rispetto ai metodi singoli, allineandosi parzialmente con i risultati dello studio di riferimento.

Infine, analizzando le accuratèzze ottenute nei singoli soggetti, si evidenzia una tendenza al miglioramento progressivo delle performance nel corso delle sessioni successive. Questo trend suggerisce che l'allenamento prolungato e l'adattamento del soggetto all'interfaccia possono contribuire a migliorare le performance della BMI nel tempo.

6 | Conclusioni

In questa tesi ho affrontato lo sviluppo e la validazione di metodi innovativi per il miglioramento delle Brain-machine interface (BMI) basate sull'analisi dei segnali EEG. Il lavoro si è concentrato sull'utilizzo di rappresentazioni matriciali delle componenti in frequenza dei segnali EEG, con l'obiettivo di migliorare la classificazione degli stati cognitivi dei soggetti.

Il progetto è iniziato con una revisione delle tecniche esistenti e delle sfide associate alle BMI, in particolare l'instabilità e la variabilità dei segnali EEG, nonché la necessità di metodi robusti per l'estrazione delle caratteristiche. È stato identificato che le rappresentazioni di covarianza nello spazio di Riemann possono offrire vantaggi significativi grazie alla loro capacità di catturare relazioni complesse tra diverse bande di frequenza.

La fase sperimentale ha coinvolto sei soggetti (C7, C8, C9, D7, G1, G2), con diverse sessioni di raccolta dati. I risultati ottenuti hanno mostrato che le accuratèzze medie dei metodi proposti sono state inferiori rispetto a quelle attese. Tuttavia, i metodi dPAC e crossFB hanno evidenziato una robustezza superiore rispetto a PA, che ha mostrato prestazioni equivalenti al caso (0.50). Questo ha portato all'esclusione di PA dal metodo Fusion.

L'analisi dei risultati ha rivelato che il metodo Fusion, nonostante le accuratèzze inferiori alle aspettative iniziali, ha dimostrato un miglioramento rispetto alle baseline tradizionali. La combinazione di dPAC e crossFB nel

metodo Fusion ha prodotto le migliori prestazioni, con accuratezze medie superiori rispetto ai singoli metodi. Questo suggerisce che l'integrazione di più approcci può catturare meglio le dinamiche complesse dei segnali EEG.

L'approccio proposto in questa tesi ha mostrato potenziali miglioramenti per le BMI, nonostante alcune limitazioni. Il metodo Fusion ha dimostrato che la combinazione di diverse tecniche di estrazione delle caratteristiche può fornire un vantaggio significativo e la sua bontà dipende fortemente dai metodi utilizzati. Tuttavia, le prestazioni inferiori alle aspettative indicano che c'è ancora spazio per miglioramenti.

Una delle principali criticità emerse riguarda la variabilità dei risultati tra i soggetti. Questo suggerisce la necessità di sviluppare metodi più personalizzati che possano adattarsi meglio alle caratteristiche individuali dei soggetti. Inoltre, l'esclusione del metodo PA, sebbene giustificata dai risultati sperimentali, indica che ulteriori ricerche sono necessarie per comprendere meglio come integrare efficacemente diverse fonti di informazione.

Per i lavori futuri, l'introduzione di un numero maggiore di soggetti coinvolti nello studio, includendo una popolazione più eterogenea con diverse condizioni neurologiche, potrebbe aiutare alla creazione di modelli più comprensivi. Questo permetterebbe di valutare la robustezza e la generalizzabilità dei metodi proposti su un ampio spettro di utenti, migliorando la validità dei risultati. Un'ulteriore aspetto che è necessario valutare è la sperimentazione del classificatore in un contesto online, attraverso esperimenti "live". Testare il sistema in tempo reale consentirebbe di valutare la sua efficacia e adattabilità in condizioni operative realistiche, fornendo un feedback immediato sull'interazione tra l'utente e la BMI. Un altro aspetto rilevante per i futuri sviluppi riguarda l'esplorazione di nuovi tipi di classificatori, ad esempio tramite l'integrazione di tecniche di machine learning più avanzate, come

reti neurali profonde (deep learning) o classificatori basati su support vector machines (SVM). In parallelo, è consigliabile investigare l'estrazione di caratteristiche più complesse dai segnali EEG, ad esempio calcolando la matrice di covarianza crossFB utilizzando più di due bande di frequenza distinte.

In conclusione, mentre questo lavoro ha proposto l'utilizzo di rappresentazioni matriciali delle componenti in frequenza nei segnali EEG per le BMI, i futuri sviluppi dovrebbero mirare a testare il sistema in condizioni reali, ampliare il numero di soggetti, esplorare nuovi classificatori e investigare l'estrazione di caratteristiche più complesse. Questi passi sono essenziali per realizzare BMI più affidabili, robuste e applicabili in scenari clinici e quotidiani.

Bibliography

- [1] J. R. Wolpaw and E. W. Wolpaw, “Brain-computer interfaces: something new under the sun,” *Brain-computer interfaces: principles and practice*, vol. 14, 2012.
- [2] J. N. Mak and J. R. Wolpaw, “Clinical applications of brain-computer interfaces: current state and future prospects,” *IEEE reviews in biomedical engineering*, vol. 2, pp. 187–199, 2009.
- [3] L. Tonin and J. d. R. Millán, “Noninvasive brain–machine interfaces for robotic devices,” *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 4, pp. 191–214, 2021.
- [4] R. Abiri, S. Borhani, E. W. Sellers, Y. Jiang, and X. Zhao, “A comprehensive review of eeg-based brain–computer interface paradigms,” *Journal of neural engineering*, vol. 16, no. 1, p. 011001, 2019.
- [5] M. Lotze and L. G. Cohen, “Volition and imagery in neurorehabilitation,” *Cognitive and behavioral neurology*, vol. 19, no. 3, pp. 135–140, 2006.
- [6] G. Pfurtscheller and C. Neuper, “Motor imagery and direct brain-computer communication,” *Proceedings of the IEEE*, vol. 89, no. 7, pp. 1123–1134, 2001.

-
- [7] G. Pfurtscheller, C. Brunner, A. Schlögl, and F. L. Da Silva, “Mu rhythm (de) synchronization and eeg single-trial classification of different motor imagery tasks,” *NeuroImage*, vol. 31, no. 1, pp. 153–159, 2006.
- [8] H. Altaheri, G. Muhammad, M. Alsulaiman, S. U. Amin, G. A. Altuwaijri, W. Abdul, M. A. Bencherif, and M. Faisal, “Deep learning techniques for classification of electroencephalogram (eeg) motor imagery (mi) signals: A review,” *Neural Computing and Applications*, vol. 35, no. 20, pp. 14681–14722, 2023.
- [9] Y. Wang, M. Nakanishi, and D. Zhang, “Eeg-based brain-computer interfaces,” *Neural Interface: Frontiers and Applications*, pp. 41–65, 2019.
- [10] O. Bai, P. Lin, S. Vorbach, M. K. Floeter, N. Hattori, and M. Hallett, “A high performance sensorimotor beta rhythm-based brain–computer interface associated with human natural motor behavior,” *Journal of neural engineering*, vol. 5, no. 1, p. 24, 2007.
- [11] J. Carmena and J. d. R. Millán, “Brain–machine interfaces,” *this journal is cited, in accordance with accepted academic*, 2013.
- [12] F. Lotte, L. Bougrain, and M. Clerc, “Electroencephalography (eeg)-based brain-computer interfaces,” *Wiley encyclopedia of electrical and electronics engineering*, p. 44, 2015.
- [13] F. Lotte, M. Congedo, A. Lécuyer, F. Lamarche, and B. Arnaldi, “A review of classification algorithms for eeg-based brain–computer interfaces,” *Journal of neural engineering*, vol. 4, no. 2, p. R1, 2007.
- [14] A. Ortiz-Rosario and H. Adeli, “Brain-computer interface technologies: from signal to action,” *Reviews in the Neurosciences*, vol. 24, no. 5, pp. 537–552, 2013.

-
- [15] L. F. Nicolas-Alonso and J. Gomez-Gil, “Brain computer interfaces, a review,” *sensors*, vol. 12, no. 2, pp. 1211–1279, 2012.
- [16] F. Lotte and M. Congedo, “Eeg feature extraction,” *Brain–Computer Interfaces 1: Foundations and Methods*, pp. 127–143, 2016.
- [17] J. R. Wolpaw, “Brain–computer interfaces,” in *Handbook of clinical neurology*, vol. 110, pp. 67–74, Elsevier, 2013.
- [18] B. Blankertz, C. Sannelli, S. Halder, E. M. Hammer, A. Kübler, K.-R. Müller, G. Curio, and T. Dickhaus, “Neurophysiological predictor of smr-based bci performance,” *Neuroimage*, vol. 51, no. 4, pp. 1303–1309, 2010.
- [19] C. Guger, B. Z. Allison, B. Großwindhager, R. Prückl, C. Hintermüller, C. Kapeller, M. Bruckner, G. Krausz, and G. Edlinger, “How many people could use an ssvep bci?,” *Frontiers in neuroscience*, vol. 6, p. 30623, 2012.
- [20] M. Fatourechi, A. Bashashati, R. K. Ward, and G. E. Birch, “Emg and eeg artifacts in brain computer interface systems: A survey,” *Clinical neurophysiology*, vol. 118, no. 3, pp. 480–494, 2007.
- [21] D. J. Krusienski, M. Grosse-Wentrup, F. Galán, D. Coyle, K. J. Miller, E. Forney, and C. W. Anderson, “Critical issues in state-of-the-art brain–computer interface signal processing,” *Journal of neural engineering*, vol. 8, no. 2, p. 025002, 2011.
- [22] F. Lotte, “Signal processing approaches to minimize or suppress calibration time in oscillatory activity-based brain–computer interfaces,” *Proceedings of the IEEE*, vol. 103, no. 6, pp. 871–890, 2015.

-
- [23] F. Yger, M. Berar, and F. Lotte, “Riemannian approaches in brain-computer interfaces: a review,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, no. 10, pp. 1753–1762, 2016.
- [24] M. F. Atiyah, V. K. Patodi, and I. M. Singer, “Spectral asymmetry and riemannian geometry. i,” in *Mathematical Proceedings of the Cambridge Philosophical Society*, vol. 77, pp. 43–69, Cambridge University Press, 1975.
- [25] A. A. Agrachev, D. Barilari, and U. Boscain, “Introduction to riemannian and sub-riemannian geometry,” 2012.
- [26] T. T. Munia and S. Aviyente, “Time-frequency based phase-amplitude coupling measure for neuronal oscillations,” *Scientific reports*, vol. 9, no. 1, p. 12441, 2019.
- [27] Y. Salimpour and W. S. Anderson, “Cross-frequency coupling based neuromodulation for treating neurological disorders,” *Frontiers in neuroscience*, vol. 13, p. 297308, 2019.
- [28] R. T. Canolty and R. T. Knight, “The functional role of cross-frequency coupling,” *Trends in cognitive sciences*, vol. 14, no. 11, pp. 506–515, 2010.
- [29] J. Sun, H. Wang, and J. Jiang, “Euler common spatial pattern modulated with cross-frequency coupling,” *Knowledge and Information Systems*, vol. 64, no. 12, pp. 3401–3418, 2022.
- [30] G. Pfurtscheller, C. Neuper, and G. Krausz, “Functional dissociation of lower and upper frequency mu rhythms in relation to voluntary limb movement,” *Clinical neurophysiology*, vol. 111, no. 10, pp. 1873–1879, 2000.

- [31] A. Palatella, P. Forin, S. Tortora, E. Menegatti, and L. Tonin, “An alternative training protocol for a motor imagery bmi based on a collaborative approach,” *Proceedings of the Graz Conference on Brain-Computer Interface 2024*, pp. 1–6, 2024.
- [32] V. Jirsa and V. Müller, “Cross-frequency coupling in real and virtual brain networks,” *Frontiers in computational neuroscience*, vol. 7, p. 78, 2013.
- [33] F. Dehais, A. Duprès, S. Blum, N. Drougard, S. Scannella, R. N. Roy, and F. Lotte, “Monitoring pilot’s mental workload using erps and spectral power with a six-dry-electrode eeg system in real flight conditions,” *Sensors*, vol. 19, no. 6, p. 1324, 2019.
- [34] M. X. Cohen, C. E. Elger, and J. Fell, “Oscillatory activity and phase–amplitude coupling in the human medial frontal cortex during decision making,” *Journal of cognitive neuroscience*, vol. 21, no. 2, pp. 390–402, 2008.
- [35] M. S. Yamamoto, A. Mellot, S. Chevallier, and F. Lotte, “Novel spd matrix representations considering cross-frequency coupling for eeg classification using riemannian geometry,” in *2023 31st European Signal Processing Conference (EUSIPCO)*, pp. 960–964, IEEE, 2023.
- [36] J. R. Wolpawa, N. Birbaumer, D. J. McFarlanda, G. Pfurtschellere, and T. M. Vaughan, “Brain-computer interfaces for communication and control,” *Clinical neurophysiology*, vol. 113, no. 6, pp. 767–791, 2002.
- [37] A. Barachant, S. Bonnet, M. Congedo, and C. Jutten, “Classification of covariance matrices using a riemannian-based kernel for bci applications,” *Neurocomputing*, vol. 112, pp. 172–178, 2013.

- [38] V. Arsigny, P. Fillard, X. Pennec, and N. Ayache, “Geometric means in a novel vector space structure on symmetric positive-definite matrices,” *SIAM journal on matrix analysis and applications*, vol. 29, no. 1, pp. 328–347, 2007.
- [39] M. T. Harandi, M. Salzmann, and R. Hartley, “From manifold to manifold: Geometry-aware dimensionality reduction for spd matrices,” in *Computer Vision–ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6–12, 2014, Proceedings, Part II 13*, pp. 17–32, Springer, 2014.