

POLITECNICO DI TORINO

**Laurea Magistrale in Ingegneria Biomedica
Strumentazione Biomedica**



Tesi di Laurea Magistrale

**Metanalisi delle metodologie di processing
del segnale EEG per l'ottimizzazione delle
Brain Computer Interfaces basate sul
Motor Imagery task**

Relatore

Prof.ssa Valentina AGOSTINI

Candidato

Roberta SURIANO

Correlatori

Dott. Marco GHISLIERI

Ing. Annalisa LETIZIA

Ing. Vincenza TUFANO

Marzo 2024

Memento Audere Semper

Abstract

Recentemente, il settore dello sviluppo delle Brain Computer Interface (BCI) ha visto una significativa espansione, influenzando diverse discipline tra cui psicologia, elettronica, neuroscienza, elaborazione dei segnali e riconoscimento di immagini. Le BCI sono impiegate per generare comandi o segnali di controllo a partire dai segnali EEG registrati dallo scalpo, offrendo il potenziale di migliorare la qualità della vita per diverse categorie di individui.

Al fine di migliorare le prestazioni di una BCI basata sul Motor Imagery (MI) task e ottimizzare i tempi computazionali, è stato condotto uno studio dello stato dell'arte che ha portato alla realizzazione di una metanalisi. La ricerca di articoli è stata condotta in conformità con le linee guida del "Preferred Reporting Items for Systematic Reviews and Meta-Analysis" (PRISMA), che ha portato all'individuazione di 22 studi pertinenti. Questi studi forniscono una panoramica delle diverse tecniche di elaborazione dei segnali EEG nell'intervallo temporale 2019-2023, comprese le metodologie di machine learning e di deep learning impiegate sia per la feature extraction che per la feature classification.

I dataset presi in considerazione in questi studi sono dataset pubblici ottenuti da individui sani, raccolti per vari scopi, tra cui competizioni internazionali, trial clinici ed esperimenti specificamente progettati per valutare le BCI basate su MI. Molti di questi approcci prendono in considerazione reti neurali convoluzionali (CNN), alcune delle quali sono di tipo più tradizionale, come EEGNet o AlexNet (note nell'ambito dell'ingegneria neurale da diversi anni), mentre altre migliorano queste architetture attraverso il fine-tuning dei parametri o l'introduzione di strati più profondi, come il Self Attention Layer. In alternativa, alcune proposte esplorano approcci di machine learning come la Support Vector Machine (SVM) o la Linear Discriminant Analysis (LDA).

Le prestazioni in termini di accuratezza, nel caso di task binari (ad esempio, movimento immaginario della mano destra o sinistra), variano dal 53.7% al 99.35%, mentre per task multi-classe (coinvolgendo non solo gli arti superiori ma anche la lingua ed entrambi i piedi) il range si estende dal 57.29% al 95.33%. Questa ampia variazione è influenzata dalle differenze nei dataset utilizzati nei diversi studi, ognuno con un numero diverso di partecipanti. Inoltre, un altro fattore che potrebbe contribuire all'ampia gamma di risultati è la diversità nelle tecniche di pre-processing applicate inizialmente ai segnali EEG grezzi, oltre alle metodologie di estrazione e classificazione delle caratteristiche considerate in questa review.

La presente metanalisi fornisce una guida chiara per lo sviluppo di BCI basate su MI e suggerisce per le future ricerche di estendere tali approcci a dataset più ampi, inclusi dati acquisiti da pazienti affetti da patologie come, ad esempio, gli stroke patients. Questo consentirebbe di testare le BCI direttamente su individui che potrebbero trarne i massimi benefici nell'ambito dell'ingegneria riabilitativa. Inoltre, viene proposto l'utilizzo di tecniche all'avanguardia di data augmentation al fine di aumentare ulteriormente le dimensioni dei dataset, evitando problemi di overfitting.

Indice

| | |
|--|-----------|
| Abstract | iv |
| 1 Introduzione | 1 |
| 1.1 Contesto, scopo e obiettivi della ricerca | 1 |
| 1.2 Rilevanza delle BCI | 2 |
| 1.3 Fondamenti sui segnali cerebrali e sul segnale EEG | 5 |
| 1.3.1 Sistema Internazionale 10/20 | 7 |
| 1.4 Applicazioni BCI | 8 |
| 1.4.1 Motor Imagery come paradigma di controllo delle BCI | 9 |
| 2 Materiali e metodi | 12 |
| 2.1 Protocollo PRISMA | 12 |
| 2.2 Criteri di inclusione ed esclusione | 17 |
| 2.2.1 Scelta delle keyword e altri criteri di ricerca | 18 |
| 2.2.2 Database interrogati | 20 |
| 2.2.3 Valutazione della qualità degli studi | 21 |
| 2.2.4 Bias di pubblicazione e altre limitazioni del protocollo | 22 |
| 2.3 Presentazione finale degli articoli | 23 |
| 2.4 Raccolta dei dati EEG | 27 |
| 2.4.1 Protocollo di acquisizione | 28 |
| 2.5 Pre-processing dei segnali EEG | 31 |
| 2.5.1 Filtraggio e riduzione del rumore | 33 |
| 2.5.2 Estrazione del MI task | 34 |
| 2.6 Tecniche di Data Augmentation | 35 |
| 2.7 Feature Extraction | 39 |

| | | |
|----------|---|-----------|
| 2.8 | Classificazione | 50 |
| 3 | Risultati | 58 |
| 3.1 | Task binario | 59 |
| 3.2 | Task multi-classe | 62 |
| 4 | Conclusioni | 65 |
| 4.1 | Limitazioni e Sviluppi futuri | 66 |
| A | Appendice | 69 |
| | Elenco delle tabelle | 77 |
| | Elenco delle figure | 79 |
| | Bibliografia | 82 |

Capitolo 1

Introduzione

Obiettivo di questo lavoro di tesi è condurre una metanalisi volta a fornire al lettore una comprensione approfondita delle tecniche di elaborazione del segnale elettroencefalografico (EEG) impiegate nei task di Motor Imagery (MI), nell'ambito delle Brain-Computer Interfaces (BCI).

1.1 Contesto, scopo e obiettivi della ricerca

La BCI è una straordinaria innovazione tecnologica che si è sviluppata in un contesto di crescente interazione tra il mondo della neuroscienza e quello dell'informatica [1]. Questa tecnologia ha visto la luce in risposta all'obiettivo di consentire una comunicazione diretta tra il cervello umano e i computer o altri dispositivi esterni, aprendo la strada a innumerevoli possibilità nelle applicazioni pratiche e nella ricerca scientifica.

La BCI è stata concepita inizialmente per affrontare le sfide legate a disabilità e disturbi neurologici, offrendo soluzioni innovative per migliorare la qualità della vita delle persone colpite da tali condizioni. Tuttavia, nel corso del tempo, il suo ambito di applicazione si è esteso a settori molto diversi, come la psicologia, la robotica, il gaming, la neuroscienza cognitiva e l'industria dell'intrattenimento [2]. Questa espansione ha dimostrato l'ampio potenziale della BCI e il suo ruolo cruciale nell'ottimizzare l'interazione tra il cervello umano e le macchine.

In questo contesto, l'obiettivo del lavoro che verrà presentato di seguito è quello di condurre una metanalisi specificamente incentrata sulle BCI basate su MI, ossia la capacità di immaginare movimenti fisici senza che questi vengano effettivamente eseguiti. Il fulcro di questa metanalisi è analizzare i processi di elaborazione dei segnali EEG coinvolti nel collegamento tra l'intenzione del soggetto e l'azione virtuale eseguita attraverso una BCI.

In particolare, si esamina come il segnale EEG associato all'immaginazione di movimenti possa essere interpretato attraverso l'impiego di reti di classificazione, realizzate mediante tecniche di machine learning o deep learning. Queste reti di classificazione svolgono un ruolo cruciale nella creazione delle BCI, poiché consentono di tradurre il segnale EEG in comandi utili per il controllo di dispositivi esterni, rendendo possibile l'interazione tra il cervello e la macchina.

Di conseguenza, si punta a identificare le metodologie più efficaci per sviluppare BCI altamente performanti, garantendo al contempo un utilizzo efficiente delle risorse computazionali. Esaminando le differenze nei risultati tra diversi studi e valutando la qualità delle tecniche di classificazione impiegate, si contribuisce a ottenere una comprensione più approfondita dei processi coinvolti nella creazione di tali interfacce avanzate.

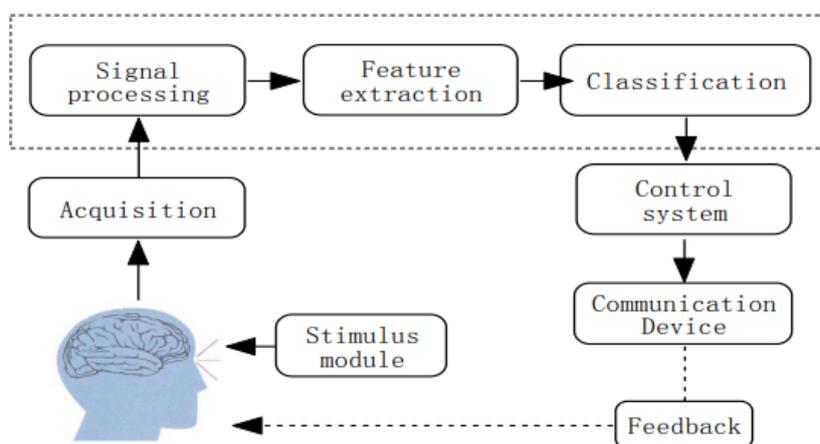


Figura 1.1: Schema BCI: fasi di elaborazione del segnale fisiologico dalla sua acquisizione fino al controllo di un dispositivo esterno [3]

Questo processo di analisi contribuirà ulteriormente a promuovere nuove scoperte nella comprensione del cervello umano e a stimolare lo sviluppo di sistemi BCI basati su MI, sfruttando al meglio le potenzialità del machine learning e del deep learning per migliorare significativamente la vita di coloro che ne traggono beneficio in una vasta gamma di applicazioni.

1.2 Rilevanza delle BCI

Le BCI rappresentano una tecnologia cruciale per ripristinare le capacità di comunicazione in individui gravemente disabili, come coloro affetti dalla sindrome locked-in, dalla sclerosi laterale amiotrofica, da ictus cerebrali o da danni alla corteccia motoria. Una BCI è un sistema di comunicazione composto da elementi hardware e software che consente all'attività cerebrale di controllare dispositivi esterni mediante l'interpretazione delle intenzioni dell'utente [1].

Il processo di raggiungere un'interfaccia di controllo inizia con l'acquisizione di un segnale, che può essere un segnale elettrico riflesso dall'attività cerebrale rilevato

dallo scalpo o, nei metodi invasivi, dal profondo del cervello. Altrimenti, il segnale può essere emodinamico. Successivamente, si procede con l'elaborazione e il miglioramento dei segnali, seguiti dall'estrazione e dalla classificazione delle informazioni rilevanti. Le caratteristiche estratte vengono quindi tradotte in comandi per consentire ai dispositivi esterni di ripristinare, potenziare, sostituire, aggiungere o migliorare le funzioni naturali del sistema nervoso centrale.

| Segnale | Fenomeno fisiologico | Numero di scelte | Training | Transfer rate |
|-------------------|--|--------------------------------|----------|-----------------|
| VEP | Modulazioni del segnale cerebrale nella corteccia visiva | Alto | No | 60-100 bits/min |
| SCP | Lente variazioni di potenziale nei segnali cerebrali | Basso (2 o 4, molto difficile) | Sì | 5-12 bits/min |
| P300 | Picchi positivi dovuti a stimoli insoliti | Alto | No | 20-25 bits/min |
| Ritmi sensomotori | Modulazioni nei ritmi sensomotori sincronizzate con l'attività motoria | Basso (2,3,4,5) | Sì | 3-35 bits/min |

Tabella 1.1: Caratteristiche tecniche delle BCI più diffuse [1]

Nella Tabella 1.1, sono presenti brevi spiegazioni per ciascuna tipologia di BCI elencata. Ogni spiegazione comprende informazioni sul fenomeno fisiologico osservabile attraverso la BCI, la percentuale di successo nell'utilizzo, la necessità o meno di allenamento preliminare prima dell'uso e la velocità di trasferimento dell'informazione.

| | |
|---------------------------|--|
| BCI invasive | utilizzate per il controllo di protesi con maggiori gradi di libertà |
| BCI non invasive | efficaci nel ripristinare i normali collegamenti comunicativi e controllare neuroprotesi e sedie a rotelle |
| BCI esogene | si basano sull'attività neurale in risposta a uno stimolo esterno |
| BCI endogene | si basano sull'autoregolazione dei ritmi cerebrali senza stimoli esterni, tramite il neurofeedback |
| BCI unidirezionali | comprendono tutte le BCI esogene, rispondendo a uno stimolo esterno con una reazione del dispositivo |
| BCI bidirezionali | includono tutte le BCI endogene, alternando fasi di registrazione e stimolazione per regolare la risposta del dispositivo in base al neurofeedback |

Tabella 1.2: Tecnologie BCI [1]

Le tecnologie BCI possono essere categorizzate in diverse tipologie, compresi approcci invasivi o non invasivi, esogeni o endogeni, e unidirezionali o bidirezionali [4]. Nella Tabella 1.2, sono riassunte le funzioni specifiche di ciascuna di queste categorie.

Nel contesto delle BCI esogene (Figura 1.2) e quindi unidirezionali, due tecnologie significative sono:

- *Steady-State Visual Evoked Potential (SSVEP)*: Sfrutta i potenziali evocati visivi nella corteccia visiva in risposta a stimoli visivi come flash di luce o immagini. Gli SSVEP sono sensibili alla frequenza dello stimolo, facilitando la classificazione.
- *P300*: Sfrutta potenziali evocati positivi in risposta a stimoli insoliti, senza richiedere una fase di addestramento.

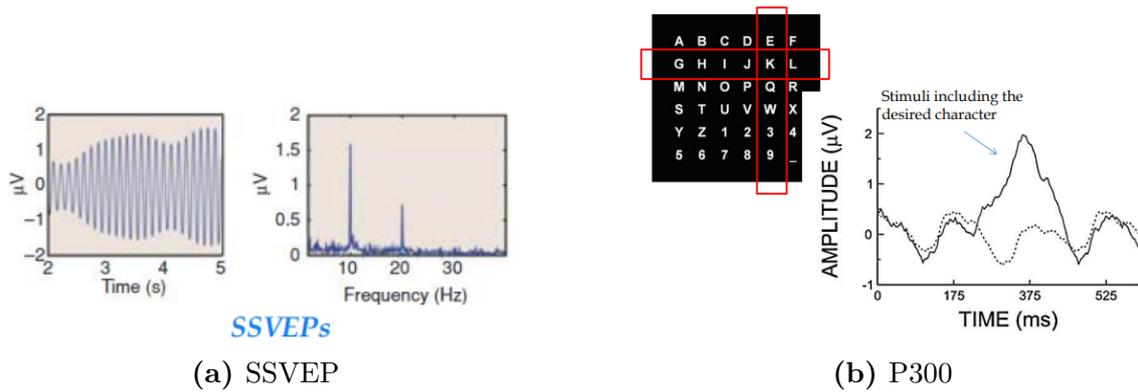


Figura 1.2: Modulazioni del segnale EEG per BCI esogene [5]

Queste tecnologie offrono opzioni flessibili per lo sviluppo di BCI adattabili alle specifiche esigenze degli utenti. Le due tecnologie in particolare consentono il controllo di dispositivi esterni utilizzando l'attività cerebrale in risposta a stimoli visivi o insoliti, fornendo soluzioni pratiche per le applicazioni BCI.

Nel contesto delle BCI endogene (Figura 1.3), che permettono un controllo bidirezionale più diretto, emergono due tecnologie distintive:

- *Slow Cortical Potential (SCP)*: Questa tecnologia si basa su variazioni lente nell'attività cerebrale rilevate tramite EEG, con variazioni che durano diversi secondi. Queste variazioni, con frequenze inferiori a 1 Hz, sono associate a cambiamenti nell'attività all'interno della corteccia cerebrale. Le variazioni negative sono correlate all'aumento dell'attività neurale, mentre quelle positive indicano una diminuzione dell'attività. La regolazione di questi segnali può essere autoregolata da pazienti sani o affetti da patologie, ma l'estrarre informazioni da tali potenziali è relativamente limitato, e richiede un periodo di allenamento prolungato.
- *Sensorimotor Rhythms (SMR)*: Questa tecnologia si basa sulle oscillazioni dell'attività cerebrale nella banda di frequenza tra 7 e 30 Hz, nota come onde mu e beta. L'ampiezza di questi ritmi varia in risposta all'attività cerebrale coinvolta in compiti motori. La capacità di apprendere a generare volontariamente queste variazioni ha reso questi ritmi ampiamente utilizzati nello sviluppo delle BCI. Due modulazioni importanti sono l'Event-Related Desynchronization (ERD),

che comporta una soppressione dell'ampiezza del ritmo, e l'Event-Related Synchronization (ERS), che implica un aumento dell'ampiezza.

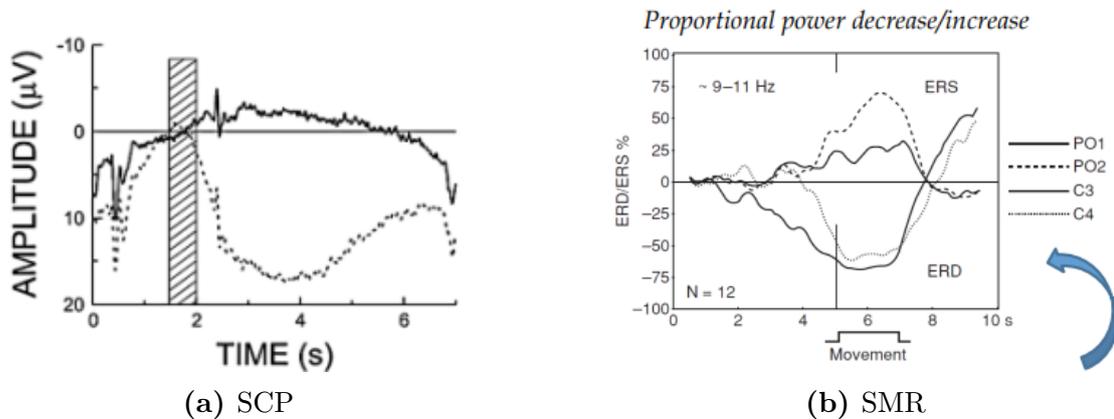


Figura 1.3: Modulazioni del segnale EEG per BCI endogene [5]

Le BCI endogene consentono un controllo bidirezionale più diretto regolando le attività cerebrali interne, offrendo una vasta gamma di applicazioni e coinvolgendo maggiormente l'utente.

Mentre alcune applicazioni basate su BCI sono ancora prevalentemente confinate all'ambito dei laboratori, alcune industrie specializzate hanno già sviluppato applicazioni iniziali accessibili alle persone. Tuttavia, per rendere le BCI pienamente accessibili in una varietà di contesti, è essenziale semplificarne l'uso attraverso la riduzione dei costi computazionali necessari per la preparazione, l'addestramento e la calibrazione di tali sistemi.

1.3 Fondamenti sui segnali cerebrali e sul segnale EEG

I segnali cerebrali presentano tipicamente variazioni non costanti e spesso si sovrappongono ad altri segnali derivanti da diverse attività cerebrali nel corso del tempo e nello spazio. Questi segnali possono essere soggetti a distorsioni provocate da artefatti come l'attività muscolare cranica, i movimenti degli occhi o l'attività cardiaca. I sistemi BCI richiedono l'elaborazione in tempo reale di tali segnali.

Come precedentemente menzionato, i segnali cerebrali acquisibili si suddividono principalmente in due categorie: quelli elettrofisiologici e quelli emodinamici. Tra i segnali elettrofisiologici, troviamo il segnale EEG, il magneto-elettroencefalografico (MEG), l'elettrocorticografico (ECoG) e l'elettroencefalografia intracranica (iEEG). D'altra parte, i segnali emodinamici includono principalmente la risonanza magnetica funzionale (fMRI) e il segnale NIRS (Near Infrared Spectroscopy) [6]. Questi segnali differiscono tra loro in termini di caratteristiche, come il tipo di attività misurata (elettrica, magnetica o metabolica), le modalità di acquisizione diretta o indiretta, risoluzione spaziale e temporale, grado di invasività e portabilità, nonché le esigenze di acquisizione in strutture appositamente attrezzate.

Tra i segnali menzionati, quelli che trovano un'applicazione significativa nel campo delle BCI sono soprattutto i segnali EEG, nonostante la loro elevata variabilità, suscettibilità ad artefatti da movimento e bassa risoluzione spaziale. Tuttavia, l'EEG possiede proprietà efficienti che lo rendono il segnale preferito per diverse applicazioni di BCI. Ecco alcune delle sue principali proprietà [7]:

1. Non invasività: L'EEG è una tecnologia non invasiva, eliminando la necessità di inserire elettrodi direttamente nel cervello. Questa caratteristica rende l'EEG più accettabile per gli utenti e riduce i rischi associati all'introduzione diretta di elettrodi nel tessuto cerebrale. Gli elettrodi comunemente utilizzati sono di solito in argento/cloruro d'argento (Ag/AgCl) per le loro proprietà conduttive e la capacità di ridurre l'impedenza elettrica tra la pelle e l'elettrodo, consentendo la registrazione di segnali complessi come l'EEG e riducendo al minimo le interferenze.
2. Alta risoluzione temporale: L'EEG offre una risoluzione temporale molto elevata, permettendo di rilevare cambiamenti nell'attività cerebrale con precisione di millisecondi. Questa caratteristica è fondamentale per le BCI, consentendo la rilevazione rapida delle variazioni e l'interpretazione in tempo reale dei segnali cerebrali.
3. Costo e portabilità: Rispetto ad altre tecnologie neurofisiologiche come l'ECOG o l'iEEG, l'EEG è generalmente più economico e portatile, semplificando l'accesso e l'applicazione in una varietà di contesti.
4. Facilità di applicazione: La collocazione degli elettrodi sulla superficie del cuoio capelluto è relativamente semplice e non richiede procedure chirurgiche complesse.
5. Rilevamento di diversi tipi di onde cerebrali: L'EEG può rilevare diverse tipologie di onde cerebrali, come delta, theta, alfa, beta e gamma (Figura 1.4). Questa diversità consente alle BCI di interpretare una vasta gamma di comandi cerebrali, apportando informazioni preziose sulla condizione mentale e l'attività cognitiva dell'utente.

In particolare:

- a. *Ritmo delta*: Con una frequenza inferiore a 4 Hz e una tensione media di circa 150 μV , il ritmo delta prevale nell'infanzia e compare durante l'anestesia generale e il sonno non profondo. La sua presenza durante la veglia può indicare malattie cerebrali.
- b. *Ritmo theta*: Presente nei neonati, il ritmo theta può rappresentare tensioni emotive. Si distingue in theta lento (4-6 Hz) e theta rapido (6-7,5 Hz), con una tensione media di 100 μV . Le onde theta si manifestano nelle regioni frontale, centrale e temporale durante il sonno profondo.
- c. *Ritmo alfa*: Distinto in alpha lento (con frequenza di 8-9 Hz), alpha intermedio (9-11,5 Hz) e alpha rapido (11,5-13 Hz), il ritmo alfa ha un'ampiezza di 40-50 μV . Registrato a occhi chiusi in un soggetto sveglio, è localizzato principalmente nei lobi occipitale e parietale. Quando al paziente viene

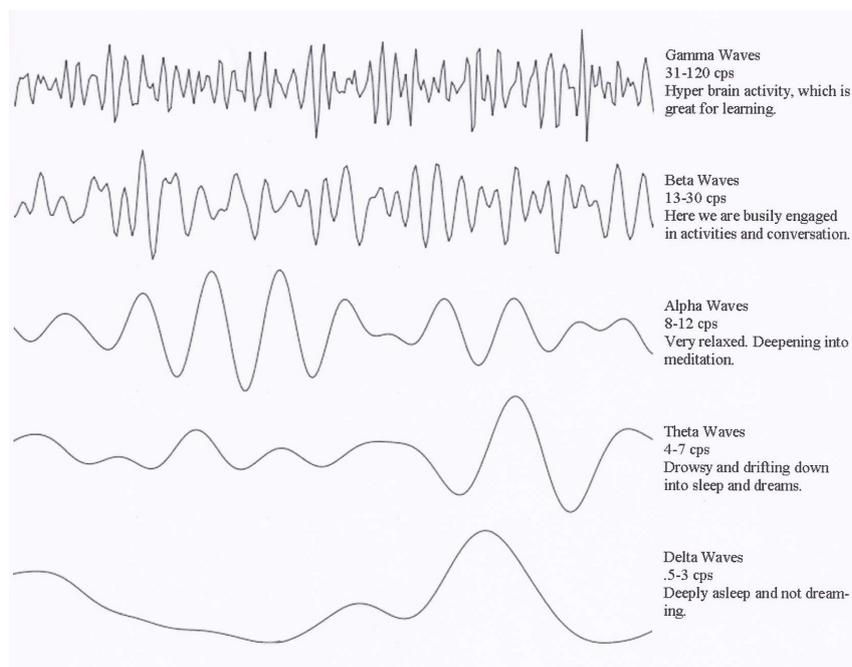


Figura 1.4: Andamento onde cerebrali e loro caratteristiche [8]

chiesto di aprire gli occhi, il ritmo alfa scompare, sostituito da un'attività di bassa tensione non più attribuibile all'alpha.

- d. *Ritmo beta:* Caratteristico di soggetti con intensa attività cerebrale, stati di allerta o sonno REM, il ritmo beta è distinto in beta lento (13,5-18 Hz) e beta rapido (18,5-30 Hz), con una tensione di circa 10-15 μV . Le onde beta sono prevalentemente evidenti nella zona centrale del cranio.
- e. *Ritmo gamma:* Con una frequenza di circa 40 Hz e un'ampiezza molto ridotta, il ritmo gamma è difficile da misurare. È associato a compiti con un'alta elaborazione cognitiva e riflette il nostro stile di apprendimento; infatti, individui con deficit mentali tendono ad avere un'attività delle onde gamma inferiore alla media. Anche gli stati di felicità e la fase REM del sonno mostrano picchi elevati in queste onde cerebrali [1].

In sintesi, l'EEG è una scelta popolare per le BCI grazie alla sua non invasività, alta risoluzione temporale, facilità di applicazione, costo relativamente basso e versatilità nelle applicazioni.

1.3.1 Sistema Internazionale 10/20

La registrazione del segnale EEG segue comunemente lo Standard Internazionale 10/20 (Figura 1.5), che determina il posizionamento degli elettrodi mediante il 10% o il 20% della distanza tra inion e nasion, variabile da persona a persona. La distanza tipica varia tra 30 e 36 cm, rappresentando la misura dalla protuberanza alla base dell'osso occipitale sulla linea mediana del cranio (inion) all'avvallamento tra naso e fronte a livello degli occhi (nasion).

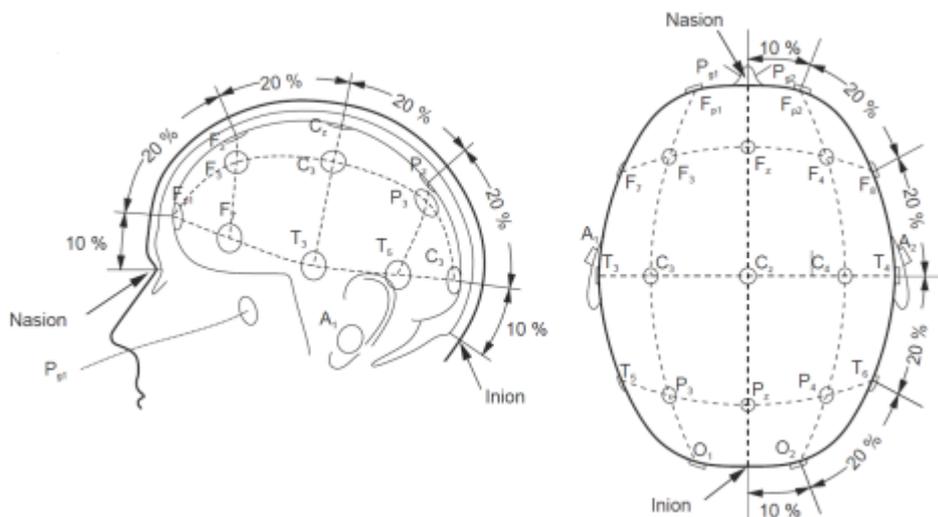


Figura 1.5: Schema di posizionamento degli elettrodi secondo lo Standard Internazionale 10/20 [1]

L'adozione del sistema 10/20 riveste importanza cruciale poiché facilita la creazione di un database per il confronto delle misure su scala globale. Per la registrazione del segnale EEG, vengono impiegati almeno 21 elettrodi sulla superficie dello scalpo, ciascuno caratterizzato dalla lettera dell'area cerebrale di appartenenza (F per frontale, O per occipitale, T per temporale, P per parietale, C per centrale) e da un numero pari se posizionato nell'emisfero destro, dispari se collocato nell'emisfero sinistro. Gli elettrodi lungo l'asse anteriore-posteriore nasion-inion sono contrassegnati dalla lettera dell'area cerebrale seguita dalla lettera "Z" [9].

È importante posizionare gli elettrodi di riferimento in prossimità della scatola cranica, poiché i segnali cerebrali sono notevolmente più piccoli rispetto a quelli provenienti da altre parti del corpo. Per evitare interferenze con questi ultimi, gli elettrodi di riferimento sono posizionati al di sopra delle orecchie e sono denominati A1 e A2.

1.4 Applicazioni BCI

Le applicazioni delle BCI sono ampie e in costante evoluzione. Come già menzionato, i loro ambiti di utilizzo sono molteplici, tra cui:

- **Neuroprotesi:** Le BCI consentono il controllo di protesi robotiche o dispositivi assistivi per persone con disabilità motorie, permettendo loro di compiere azioni come il movimento di un arto artificiale.
- **Comunicazione Assistita:** Le BCI forniscono un canale di comunicazione per persone con gravi disabilità fisiche o paralisi, permettendo loro di comunicare attraverso comandi inviati direttamente dal cervello.
- **Riabilitazione:** Nell'ambito della riabilitazione neurologica, le BCI aiutano i pazienti a recuperare funzionalità motorie dopo lesioni cerebrali o ictus.

- **Gaming:** Le BCI sono utilizzate nel mondo del gioco per creare esperienze interattive, consentendo ai giocatori di controllare personaggi o eseguire azioni nel gioco attraverso il pensiero.
- **Neurofeedback:** Le BCI forniscono un feedback in tempo reale sull'attività cerebrale, aiutando gli utenti a imparare a controllare o modificare specifici modelli di attività cerebrale per migliorare il benessere mentale.
- **Interfacce Uomo-Macchina avanzate:** Le BCI contribuiscono allo sviluppo di interfacce utente più intuitive, permettendo alle persone di interagire con dispositivi elettronici attraverso il pensiero anziché tramite input fisici come tastiere o mouse.
- **Ricerca scientifica:** Le BCI vengono utilizzate nella ricerca scientifica per studiare l'attività cerebrale e approfondire la comprensione dei meccanismi che regolano la mente umana, contribuendo agli studi sulla cognizione, sull'apprendimento e su altre funzioni cerebrali.
- **Controllo di veicoli e droni:** Le BCI possono essere integrate nei sistemi di controllo di veicoli o droni, consentendo agli operatori di guidare o pilotare attraverso comandi cerebrali.
- **Medicina personalizzata:** Le BCI potrebbero personalizzare i trattamenti medici basandosi sulle risposte cerebrali individuali, migliorando così l'efficacia e la sicurezza dei trattamenti [10].

Queste rappresentano solo alcune delle numerose applicazioni potenziali delle BCI, e la continua ricerca in questo campo promette ulteriori sviluppi e scoperte.

1.4.1 Motor Imagery come paradigma di controllo delle BCI

In questo lavoro di tesi ci si sofferma esclusivamente sull'acquisizione di segnali EEG durante il MI e si orienta lo studio verso le specifiche tecniche di elaborazione di questo tipo di segnale. Tutte le applicazioni precedentemente menzionate risultano infatti realizzabili attraverso l'analisi e l'elaborazione di tale segnale.

L'utilizzo dell'MI-EEG trova applicazioni nelle BCI endogene, caratterizzandosi come un tipo di segnale generato spontaneamente dal cervello quando il soggetto immagina un movimento senza eseguirlo fisicamente. Questo segnale, non provocato da stimoli esterni, si distingue per la sua semplicità, flessibilità e buona risoluzione temporale. Inoltre, l'impiego di dispositivi di elaborazione dal costo moderato contribuisce alla sua accessibilità.

Il paradigma di controllo basato su MI-EEG comporta l'acquisizione del segnale EEG nel momento in cui al soggetto viene chiesto di immaginare un movimento, seguito dalla trasformazione del segnale in un comando per controllare un dispositivo esterno [11]. Durante questa acquisizione, la frequenza e la banda di potenza dei segnali EEG variano in base al contenuto del movimento immaginato. Questa attività cerebrale è comunemente studiata nelle regioni della corteccia motoria coinvolte nel controllo dei movimenti volontari.

Durante l'intero compito di MI, emergono fenomeni di desincronizzazione (ERD) e sincronizzazione (ERS) nelle onde cerebrali (Figura 1.6), soprattutto nelle bande di frequenza associate all'attività motoria [12]. Questi fenomeni possono essere distinti

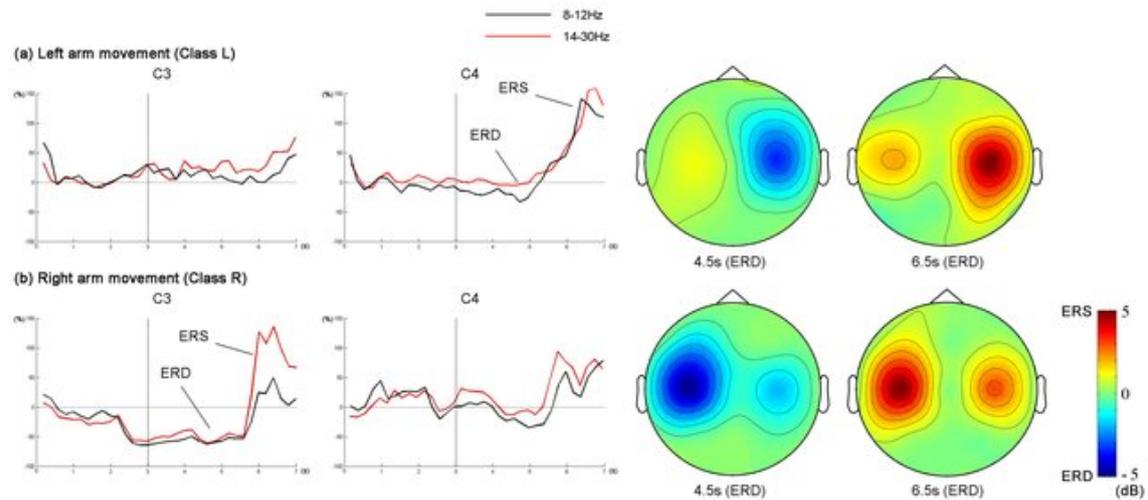


Figura 1.6: Andamento ERS/ERD con mappe topografiche attraverso cui è possibile visualizzare le attivazioni cerebrali per un semplice motor task [13]

nel seguente modo:

- *ERD*: durante l'immaginazione motoria, si osserva una temporanea diminuzione dell'attività delle onde cerebrali nella banda di frequenza mu (8-13 Hz) nella corteccia senso-motoria. Questa desincronizzazione è spesso correlata alla preparazione e all'immaginazione dei movimenti motori.
- *ERS*: dopo l'immaginazione motoria o durante periodi di inattività, si verifica un temporaneo aumento dell'attività nelle bande di frequenza delle onde beta. Questa sincronizzazione può riflettere il ripristino dell'attività neurale alla base dell'immaginazione motoria, poiché le onde beta sono coinvolte nei movimenti volontari e coordinano l'attività motoria.

L'analisi delle onde mu e beta durante il compito di MI risulta fondamentale per comprenderne le variazioni dell'attività cerebrale durante la preparazione e l'immaginazione dei movimenti [14]. Questi studi sono ampiamente impiegati nelle BCI basate sull'EEG, dove la capacità di rilevare e interpretare i modelli di attività cerebrale associati all'immaginazione motoria riveste un ruolo cruciale per abilitare il controllo di dispositivi esterni attraverso il pensiero. In aggiunta, è stato osservato che le aree con maggiore attivazione durante il MI acquisito tramite EEG sono spesso localizzate nella corteccia senso-motoria, comprendente l'area motoria primaria (M1) e l'area somatosensoriale (S1). Tali regioni (Figura 1.7) sono significativamente coinvolte nel controllo e nella percezione dei movimenti volontari.

È essenziale sottolineare che la specificità delle aree coinvolte può variare a seconda del tipo di movimento immaginato e delle caratteristiche individuali. In termini generali, l'analisi dell'EEG durante il MI fornisce informazioni sulle modulazioni dell'attività cerebrale associate all'anticipazione e all'immaginazione dei movimenti,

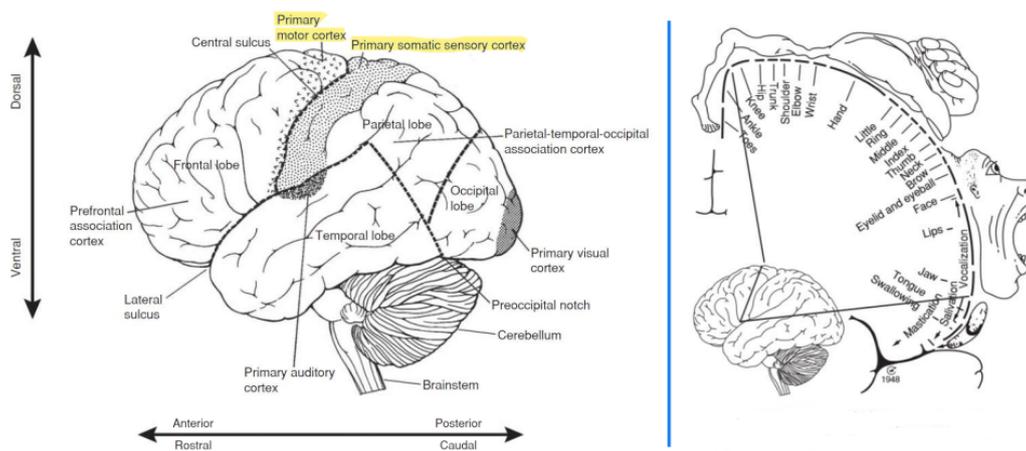


Figura 1.7: Corteccia primaria motoria e sensoriale [5]

offrendo una preziosa finestra sulla rappresentazione neurale del movimento nella corteccia senso-motoria.

Capitolo 2

Materiali e metodi

Questo capitolo inizia con la descrizione della metodologia impiegata per condurre la metanalisi. Successivamente, sono esaminati dettagliatamente diversi approcci utilizzati nell'elaborazione del segnale EEG. Ciò comprende non solo le fasi di pre-processing, ma anche aspetti relativi alla Data Augmentation, alla feature extraction e alla feature classification.

2.1 Protocollo PRISMA

Con l'obiettivo di fornire linee guida esaustive per la conduzione di revisioni sistematiche e metanalisi, nel 2009 è stata formulata una guida internazionale denominata PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) [15]. Il PRISMA Statement rappresenta un'evoluzione dell'originaria QUOROM Statement (QUality Of Reporting Of Meta-analyses), incorporando numerosi sviluppi concettuali e pratici nel contesto delle revisioni sistematiche. Questa guida mira a garantire uniformità nella chiarezza espositiva e nell'accessibilità delle informazioni.

Un punto cruciale che ha segnato una svolta fondamentale durante il passaggio dal QUOROM al PRISMA Statement è stato il chiaro intento di differenziare tra revisione sistematica e metanalisi. Questi due concetti sono spesso scambiati erroneamente, con la falsa convinzione che siano due modi distinti di indicare la stessa procedura.

Una revisione sistematica si caratterizza per una domanda iniziale chiaramente formulata e si propone di rispondere a questa domanda attraverso l'impiego di metodi sistematici ed espliciti. Tale processo coinvolge l'identificazione e la selezione meticolosa degli articoli di ricerca pertinenti. Nella revisione sistematica, l'applicazione di metodi statistici per analizzare e sintetizzare i risultati degli studi può essere una scelta, ma non è obbligatoria. Al contrario, una metanalisi si distingue da una revisione sistematica poiché impiega specificamente tecniche statistiche per integrare i risultati già presenti negli studi selezionati. In questo modo, la metanalisi mira a fornire una sintesi quantitativa e più approfondita delle evidenze raccolte.

Il PRISMA Statement si compone di una checklist di 27 punti e di un diagramma di flusso suddiviso in 4 parti. Questi strumenti forniscono agli utenti, che siano clinici, ricercatori o scrittori di riviste scientifiche, una guida dettagliata su tutti i passaggi da seguire in modo sequenziale per condurre una revisione sistematica o una metanalisi conformemente agli standard internazionali.

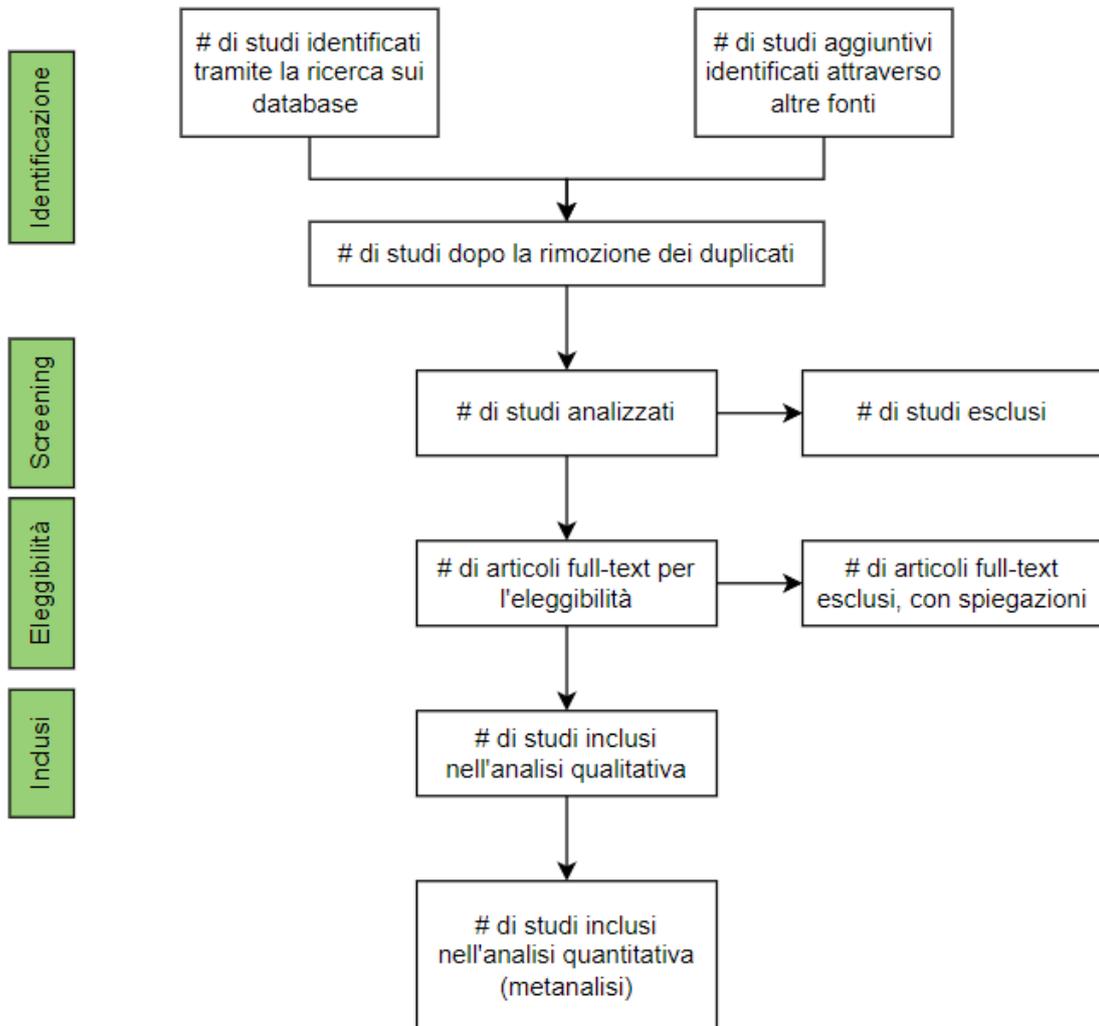


Figura 2.1: Flow-chart PRISMA Statement

Nella Figura 2.1, si evidenzia che la prima fase della preparazione di una metanalisi consiste nell'identificazione degli articoli attraverso diversi database di ricerca. Questa fase iniziale si conclude con l'eliminazione dei duplicati, realizzata mediante un controllo incrociato tra gli articoli rinvenuti in diversi database. La seconda fase è dedicata allo screening, durante il quale, sulla base dei criteri di inclusione ed esclusione definiti, vengono selezionati solo alcuni degli articoli inizialmente individuati, mentre gli altri vengono automaticamente esclusi. La terza fase, denominata fase di eleggibilità, comporta la verifica della disponibilità effettiva dei testi integrali degli articoli selezionati. Infine, la quarta e ultima fase fornisce il numero totale degli

articoli inclusi nello studio.

I 27 punti illustrati nella Tabella 2.1, delineano gli elementi chiave che devono essere inclusi in una revisione sistematica o metanalisi.

Tale struttura garantisce la presentazione chiara e completa delle informazioni essenziali, agevolando una comunicazione precisa e trasparente riguardo ai dettagli metodologici e ai risultati della ricerca.

| Sezione/Argomento | N°item | Item della checklist |
|----------------------------|--------|--|
| Titolo | 1 | Identificare l'articolo come revisione sistematica, metanalisi o entrambe |
| Abstract strutturato | 2 | Fornire un abstract strutturato che includa, a seconda del caso: background, obiettivi, fonti dei dati, criteri di eleggibilità degli studi, partecipanti, interventi, metodi per la valutazione e la sintesi degli studi, risultati, limiti, conclusioni e implicazioni dei risultati principali, numero di registrazione della revisione sistematica |
| Razionale | 3 | Descrivere il razionale della revisione nel contesto delle conoscenze già note |
| Obiettivi | 4 | Esplicitare i quesiti della revisione utilizzando lo schema PICOS: Partecipanti, Interventi, Confronti, Outcome e disegno di Studio |
| Protocollo e registrazione | 5 | Indicare se esiste un protocollo della revisione, dove può essere consultato e, se disponibili, fornire le informazioni relative alla registrazione incluso il numero di registrazione |
| Criteri di eleggibilità | 6 | Specificare le caratteristiche dello studio (es. PICOS, durata del follow-up) e riportare quelle utilizzate come criteri di eleggibilità (es. gli anni considerati, la lingua e lo status di pubblicazione), riportando le motivazioni |

| | | |
|-----------------------------------|----|---|
| Fonti di informazione | 7 | Descrivere tutte le fonti di informazione della ricerca (es. database con l'intervallo temporale coperto, contatto con gli autori per identificare ulteriori studi), riportando la data dell'ultima ricerca effettuata |
| Ricerca | 8 | Riportare la strategia di ricerca bibliografica completa per almeno un database, includendo tutti i filtri utilizzati, per garantire la riproducibilità |
| Selezione degli studi | 9 | Rendere esplicito il processo di selezione degli studi (es. screening, eleggibilità, inclusione nella revisione sistematica e, se applicabile, nella metanalisi) |
| Processo di raccolta dati | 10 | Descrivere il metodo per l'estrazione dei dati dai report (es. moduli guidati, indipendentemente, in doppio) e ogni processo per ottenere e confermare i dati dai ricercatori |
| Caratteristiche dei dati | 11 | Elencare e definire tutte le variabili per le quali i dati sono stati cercati (es. PICOS, fonti di finanziamento) e ogni assunzione e semplificazione effettuata |
| Rischio di bias nei singoli studi | 12 | Descrivere i metodi utilizzati per valutare il rischio di bias nei singoli studi (precisando se la valutazione è stata fatta a libello di studio o di outcome) e come questa informazione è utilizzata nella sintesi dei dati |
| Misure di sintesi | 13 | Indicare le principali misure di sintesi (es. rischio relativo, differenza tra medie) |
| Sintesi dei risultati | 14 | Descrivere i metodi per gestire i dati e combinare i risultati degli studi, se applicabile, includendo misure di consistenza per ciascuna metanalisi |
| Rischio di bias tra gli studi | 15 | Specificare qualsiasi valutazione del rischio di bias che può influire sulla stima cumulativa (es. bias di pubblicazione, reporting selettivo tra gli studi) |

| | | |
|-------------------------------|----|--|
| Analisi aggiuntive | 16 | Descrivere i metodi delle eventuali analisi aggiuntive (es. analisi di sensibilità o per sottogruppi, meta-regressioni), indicando quali erano predefinite |
| Selezione degli studi | 17 | Riportare, idealmente con un diagramma di flusso, il numero degli studi esaminati, valutati per l'eleggibilità e inclusi nella revisione, con le motivazioni per le esclusioni a ogni step |
| Caratteristiche degli studi | 18 | Riportare per ciascuno studio le caratteristiche per le quali i dati sono stati estratti (es. dimensione dello studio, PICOS, durata del follow-up) e fornire la citazione bibliografica |
| Rischio di bias negli studi | 19 | Presentare i dati relativi al rischio di bias di ogni studio e, se disponibile, qualunque valutazione effettuata a livello di outcome (item 12) |
| Risultati dei singoli studi | 20 | Per tutti gli outcome considerati (benefici o rischi), riportare per ogni studio: (a) un semplice riassunto dei dati per ciascun gruppo di intervento e (b) stime dell'effetto e limiti di confidenza, idealmente utilizzando un forest plot |
| Sintesi dei risultati | 21 | Riportare i risultati di ogni metanalisi effettuata, includendo limiti di confidenza e misure di consistenza |
| Rischio di bias tra gli studi | 22 | Presentare i risultati di qualsiasi valutazione del rischio di bias tra gli studi (item 15) |
| Analisi aggiuntive | 23 | Fornire i risultati di eventuali analisi aggiuntive se eseguite (es. analisi di sensibilità o per sottogruppi, meta-regressioni (item 16)) |
| Sintesi delle evidenze | 24 | Riassumere i principali risultati includendo la forza delle evidenze per ciascun outcome principale; considerare la loro rilevanza per categorie rilevanti di stakeholders (es. professionisti sanitari, pazienti, policy-makers) |

| | | |
|------------------------|----|--|
| Limiti | 25 | Discutere i limiti a livello di studio e di outcome (es. il rischio di bias) e a livello di revisione (es. reperimento parziale degli studi identificati, reporting bias) |
| Conclusioni | 26 | Fornire un'interpretazione generale dei risultati nel contesto delle evidenze, e riportare le implicazioni per la ricerca futura |
| Fonti di finanziamento | 27 | Elencare le fonti di finanziamento della revisione sistematica e altri eventuali supporti (es. la fornitura di dati) e ruolo dei finanziatori per la revisione sistematica |

Tabella 2.1: 27 items per redigere una revisione sistematica o una metanalisi secondo il PRISMA Statement

2.2 Criteri di inclusione ed esclusione

Per condurre la metanalisi mirata a identificare le tecniche più efficaci di elaborazione del segnale EEG per la classificazione di un compito di MI per una BCI, è stata seguita attentamente la Tabella 2.1. Questo approccio ha consentito la creazione di un lavoro ben strutturato e facilmente comprensibile per un lettore esterno.

Inizialmente, si sono identificati i criteri di inclusione ed esclusione al fine di stabilire su quali articoli e in quale misura concentrare l'attenzione per la metanalisi. I criteri scelti sono riassunti nella Tabella 2.2.

| | |
|-----------------------|---|
| Query | (bci AND eeg AND motor AND imagery AND public AND dataset AND deep AND learning) OR (bci AND eeg AND motor AND imagery AND public AND dataset AND machine AND learning) |
| Anni di pubblicazione | 2019-2023 |
| Lingua | Inglese |
| Tipo di documento | Articolo/Rivista |
| Disponibilità | Libero accesso |
| Database | Pubmed/Scopus |

Tabella 2.2: Criteri di inclusione per la metanalisi

2.2.1 Scelta delle keyword e altri criteri di ricerca

In un primo momento, è risultato cruciale identificare le parole chiave che potessero essere utili e contemporaneamente descrivere l'obiettivo della metanalisi. Ciò è stato fatto al fine di cercare esclusivamente gli articoli rilevanti all'interno della letteratura scientifica.

Sono state formulate due *query* di ricerca. Poiché entrambe le *query* sono in egual modo rilevanti, è stato utilizzato l'operatore logico OR tra di esse per rendere la ricerca equamente orientata in entrambe le direzioni.

È stata quindi inserita la seguente chiave di ricerca: (bci AND eeg AND motor AND imagery AND public AND dataset AND deep AND learning) OR (bci AND eeg AND motor AND imagery AND public AND dataset AND machine AND learning).

La selezione si è orientata verso articoli che affrontano le tecniche di elaborazione del segnale EEG, sia basate su machine learning che su deep learning. Inoltre, entrambe le query hanno posto l'accento sulla necessità che i dataset utilizzati negli studi fossero di natura pubblica e non privata, garantendo così la reperibilità dei dati online. Tale scelta è giustificata dalla volontà di offrire al lettore della metanalisi la possibilità di verificare autonomamente la riproducibilità dei risultati ottenuti. Non vi è modo migliore di farlo se non consentire al lettore di scaricare e elaborare i dati seguendo la pipeline suggerita come la più efficace dalla metanalisi stessa. Nella Figura 2.2 viene mostrata la distribuzione dell'utilizzo di dataset pubblici. In particolare, numerosi di essi sono stati resi disponibili per consentire a vari ricercatori del settore di partecipare a competizioni internazionali, come ad esempio BCI Competition III e IV.

In seguito, sono stati specificati ulteriori criteri di ricerca, tra cui l'intervallo di anni di pubblicazione, la lingua, la tipologia di documento, la disponibilità dell'articolo e i database da cui condurre effettivamente la ricerca degli articoli.

In particolare, l'intervallo di anni di pubblicazione selezionato va dal 2019 al 2023, inclusi. Tale scelta è motivata dal desiderio di offrire una metanalisi aggiornata che fornisca al lettore una prospettiva moderna sulle tecnologie di elaborazione dei segnali, escludendo quelle considerate ormai obsolete o eccessivamente onerose in termini di tempo e costi computazionali.

Come illustrato nella Figura 2.3, gli studi inclusi nell'analisi sono distribuiti in modo più o meno equo tra il 2019 e il 2023, con una maggior presenza di pubblicazioni nel 2023 (7 studi).

Si è optato per l'adozione dell'inglese come lingua principale, considerando che è la lingua più universalmente diffusa e compresa a livello globale nella maggior parte

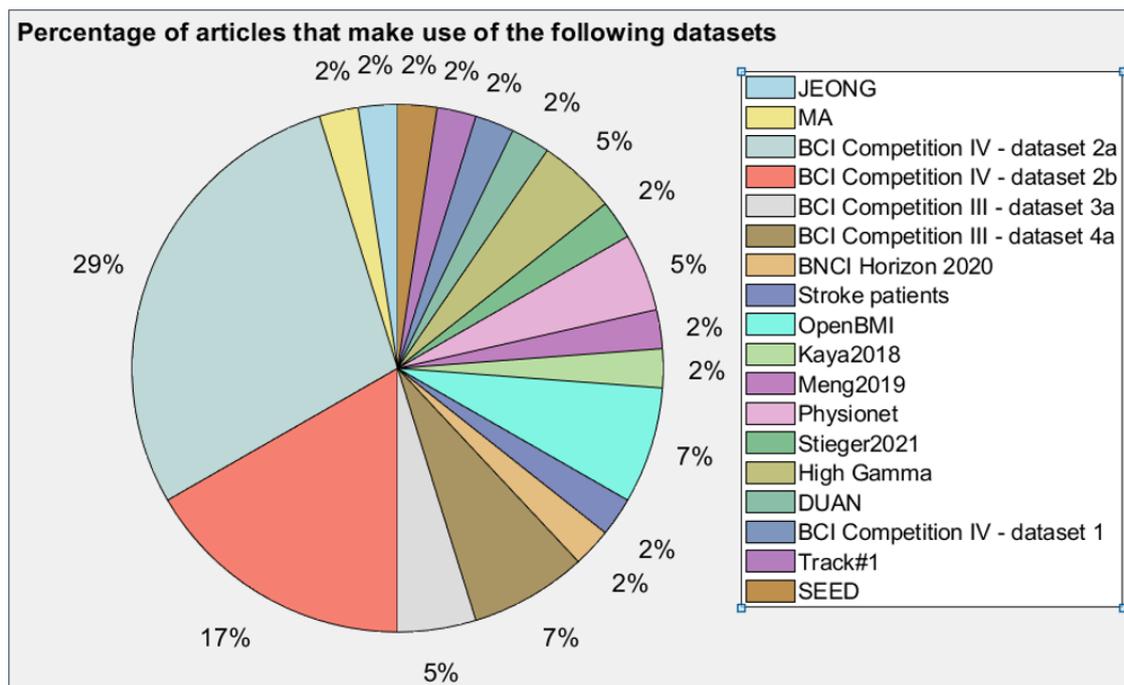


Figura 2.2: Distribuzione dei dataset pubblici utilizzati

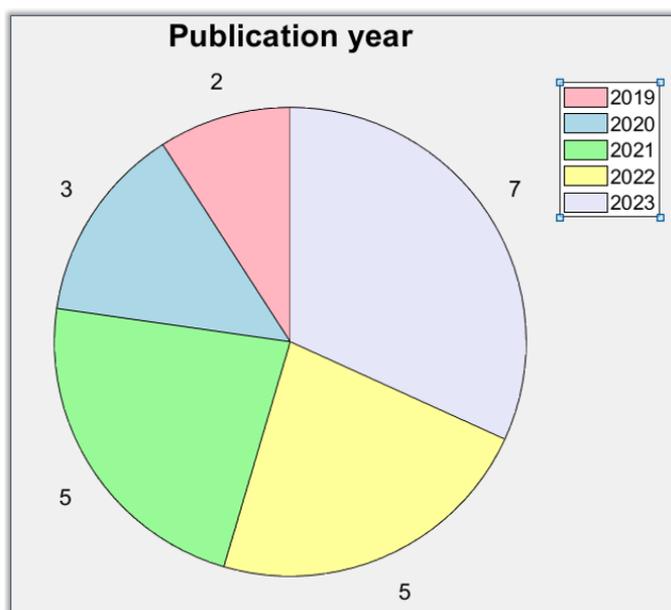


Figura 2.3: Range anni di pubblicazione degli articoli

degli articoli scientifici. Questa scelta amplifica significativamente l'accessibilità della ricerca, raggiungendo un pubblico più vasto e conferendo un valore aggiunto alla metanalisi grazie all'incremento delle fonti di ricerca inizialmente selezionate.

In fase iniziale della ricerca, si sono focalizzate le attenzioni su due categorie di documenti: *Articoli* e *Revisioni*. Contestualmente, sono stati automaticamente esclusi

gli articoli derivanti da conferenze, riunioni e lavori di tesi. Tale esclusione è giustificata dalla considerazione che tali fonti potrebbero essere ritenute meno affidabili rispetto a un articolo scientifico o a una revisione sistematica. Come evidenziato nel capitolo precedente, questi ultimi devono necessariamente rispettare criteri universalmente accettati e considerati standard. Pertanto, le fonti risultanti sono considerate altrettanto valide e idonee per essere oggetto di studio nell'ambito della seguente metanalisi.

Per quanto concerne la disponibilità degli articoli, sono stati selezionati esclusivamente quelli a libero accesso, ossia quelli che possono essere scaricati autonomamente senza necessità di richiedere il permesso di lettura agli autori o alla pubblicazione giornalistica/rivista di provenienza.

2.2.2 Database interrogati

L'ultima decisione ha riguardato la selezione dei database di ricerca in cui inserire le chiavi di ricerca precedentemente elencate. Di conseguenza, i database esplorati per le ricerche correlate a questo lavoro di tesi sono stati *PubMed* [16] e *Scopus* [17]. PubMed costituisce una base di dati dedicata alla ricerca di articoli scientifici e revisioni prevalentemente nell'ambito della medicina e della biologia.

Diversamente, Scopus rappresenta una piattaforma di ricerca più ampia, inclusiva di articoli scientifici, conferenze, libri e brevetti. La sua portata non si limita esclusivamente all'ambito medico, ma si estende a tutte le discipline scientifiche.

Durante la fase di scelta dei database di ricerca, sono stati esclusi alcuni più generici, come ad esempio *Google Scholar* [18].

Le indicazioni fornite dal protocollo PRISMA e l'enumerazione dei criteri di inclusione ed esclusione nei paragrafi precedenti hanno condotto alla individuazione di 22 articoli, che sono esaminati in questa metanalisi.

In dettaglio, la Figura 2.4 presenta il flow-chart conforme al protocollo PRISMA, evidenziando le quattro fasi analitiche che hanno portato alla selezione dei 22 articoli finali.

Nel corso della *fase di identificazione*, è stato rintracciato un totale di 175 articoli nei database di ricerca, di cui 94 su Scopus e i restanti 91 su PubMed.

Nel corso della *fase di screening*, è stato inizialmente eseguito un controllo incrociato per individuare e eliminare i duplicati tra i diversi database. Sono stati eliminati 31 articoli duplicati, riducendo così il numero a 144 articoli destinati all'analisi. La seconda parte della fase di screening ha coinvolto un controllo più approfondito, concentrato sulla verifica dell'utilizzo di dataset pubblici da parte degli autori degli articoli. Questo aspetto è stato esaminato con particolare attenzione poiché, come precedentemente menzionato, si desidera offrire al lettore la possibilità di verificare

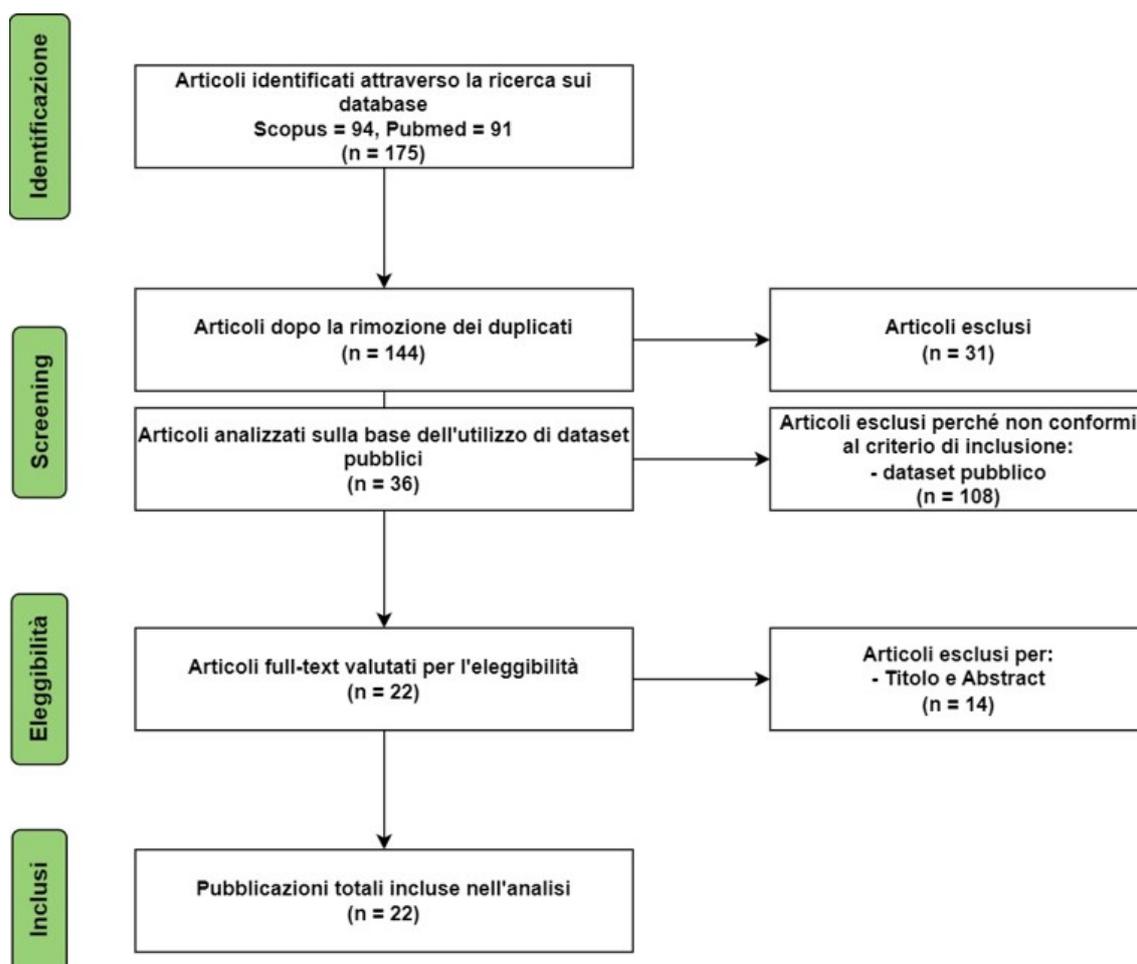


Figura 2.4: Flow-chart PRISMA Statement

la riproducibilità dei risultati attraverso l'implementazione personale della pipeline di elaborazione dei segnali. Di conseguenza, sono stati esclusi 108 articoli, portando il numero di articoli avanzati alla successiva fase di eleggibilità a 36.

Durante la *fase di eleggibilità*, i 36 articoli sono stati attentamente esaminati, valutando singolarmente titoli e abstract per assicurare la rilevanza rispetto agli obiettivi di questa tesi. Di questi, ne sono stati esclusi 14 dopo un'approfondita analisi.

Per concludere, nella *fase di inclusione* sono state confermate le 22 pubblicazioni, le quali sono state successivamente integrate nell'analisi.

2.2.3 Valutazione della qualità degli studi

Al fine di garantire la provenienza da fonti affidabili, è stato valutato per ciascun articolo il suo Impact Factor (IF), un indice che misura il numero medio di citazioni ricevute in un particolare anno da articoli pubblicati su un articolo scientifico nei due anni precedenti.

Le caratteristiche principali che rendono un articolo scientifico idoneo alla misura dell'IF includono:

- Puntualità nella pubblicazione dei fascicoli.
- Applicazione di un processo di valutazione editoriale basato sulla revisione tra pari (peer review).
- Presenza di un abstract e di informazioni bibliografiche in inglese, oltre a liste di riferimenti in caratteri latini conformi alle convenzioni editoriali internazionali (nonostante molte riviste siano pubblicate integralmente in lingua inglese).
- Internazionalità degli autori.
- Interesse per il contenuto scientifico, considerando la copertura attuale della specifica categoria tematica o la trattazione di argomenti emergenti.
- Presenza di citazioni nel database bibliografico Web of Science.

Questi criteri di valutazione [19] mirano a garantire la qualità e l'affidabilità delle fonti selezionate, assicurando che siano in linea con gli standard accettati nella comunità scientifica.

Di conseguenza, sono stati considerati esclusivamente articoli con un IF significativo. Un secondo controllo finalizzato a garantire la qualità delle pubblicazioni selezionate è stato eseguito basandosi sui quartili. Questi quartili sono distinti come Q1, Q2, Q3 e Q4. L'inclusione di un articolo scientifico in un determinato quartile è strettamente legata al suo valore di IF. Ad esempio, se un articolo appartiene al Q1, significa che il suo IF è più elevato del 75% delle riviste scientifiche appartenenti alla stessa categoria. In linea con questo criterio, si è dato un peso maggiore alle pubblicazioni appartenenti a questo quartile, o al massimo al quartile Q2.

2.2.4 Bias di pubblicazione e altre limitazioni del protocollo

Al termine di questa metanalisi, è importante considerare che la selezione iniziale degli articoli inclusi nel lavoro ha avuto un impatto significativo sulle conclusioni finali e sulla definizione della pipeline che identifica le migliori tecniche di elaborazione del segnale EEG per lo sviluppo di una BCI basata su un compito di immaginazione motoria. Tale selezione, effettuata in accordo con le linee guida del protocollo internazionale PRISMA per la stesura di metanalisi, è stata influenzata notevolmente dalla scelta dei database di ricerca utilizzati per l'analisi.

Inizialmente, sono stati selezionati due database e, di conseguenza, sono stati esclusi molti altri, ritenuti meno ricchi di fonti affidabili nel contesto medico, sanitario

e scientifico. Come precedentemente menzionato, questa decisione iniziale ha plasmato l'intera metanalisi e ha contribuito a definire il quadro di riferimento per le migliori pratiche di elaborazione dei segnali EEG nel contesto specifico di un MI task per lo sviluppo di una BCI.

Va considerato anche il bias di pubblicazione [20], che si manifesta quando gli articoli disponibili nei database di ricerca sono spesso quelli con risultati di successo, espressi, ad esempio, in termini di performance, più elevati. Il bias di pubblicazione si riferisce alla tendenza di pubblicare principalmente i risultati positivi, ignorando o scartando molte prove che hanno prodotto risultati negativi. Questo fenomeno può influenzare la visibilità e l'accessibilità di risultati negativi, alterando la percezione complessiva della percentuale di successo di uno studio. La mancata pubblicazione di risultati negativi contribuisce a una visione distorta e incompleta della ricerca in un determinato campo.

2.3 Presentazione finale degli articoli

Considerando tutte le fasi che hanno condotto all'identificazione degli articoli oggetto di studio e consapevoli dei limiti che derivano dalla scelta di un percorso rispetto a un altro, la Tabella 2.3 presenta un elenco completo di tutti gli articoli selezionati, inclusi i rispettivi titoli e abstract.

| ID | Titolo | Abstract |
|-----------|--|---|
| 1 [21] | A Factorization Approach for Motor Imagery Classification | Metodo per fattorizzare i segnali EEG in due gruppi per classificare le immagini motorie anche se le caratteristiche spaziali sono scarse. Basato sull' <i>adversarial learning</i> , si concentra sull'estrazione di caratteristiche comuni dei segnali EEG in modo che siano robuste al rumore e sull'estrazione delle sole caratteristiche del segnale. Obiettivo: classificare le classi rappresentando le caratteristiche dei due gruppi come un unico spazio di incorporazione. |
| 2 [22] | A large EEG dataset for studying cross-session variability in motor imagery brain-computer interface | Obiettivo: fornire l'accuratezza della classificazione di benchmarking per tre condizioni, ovvero la classificazione all'interno della sessione (WS), la classificazione tra le sessioni (CS) e l'adattamento tra le sessioni (CSA), con modelli specifici per soggetto. |
| 3 [23] | Advanced TSGL-EEGNet for motor imagery EEG based brain-computer interfaces | Obiettivo: introduzione di un popolare modello di deep learning, EEGNet, e confronto con l'algoritmo tradizionale Filter-Bank Common Spatial Pattern (FBCSP). Miglioramento dell'EEGNet attraverso l'utilizzo dell'algoritmo Temporary Constrained Sparse Group Lasso (TCSGL) per aumentarne le prestazioni. |

| | | |
|-----------|---|--|
| 4 [24] | An unsupervised deep transfer learning based motor imagery EEG classification scheme for brain-computer interface | Metodo non supervisionato basato sul deep-transfer-learning per affrontare le attuali limitazioni dei sistemi BCI, applicando l'idea del transfer learning alla classificazione dei segnali EEG delle immagini motorie. |
| 5 [25] | Motor imagery EEG classification based on ensemble support vector learning | Obiettivo: migliorare le prestazioni della classificazione EEG basata sulle immagini motorie in una situazione con pochi canali, attraverso un approccio basato sull'Ensemble Support Vector Learning (ESVL) per combinare i vantaggi delle caratteristiche basate su ERD/ERS e le caratteristiche basate sul potenziale correlato agli eventi nella classificazione EEG basata sulle immagini motorie. |
| 6 [26] | A sliding window common spatial pattern for enhancing motor imagery classification in EEG-BCI | Due tecniche a finestre scorrevoli per migliorare la classificazione binaria della MI. La prima calcola la ripetizione consecutiva più lunga (LCR) della sequenza di previsione di tutte le finestre scorrevoli ed è denominata SW-LCR. La seconda calcola la modalità della sequenza di predizione di tutte le finestre scorrevoli e prende il nome di SW-Mode. |
| 7 [27] | Adaptive transfer learning for EEG motor imagery classification with deep convolutional neural network | 5 schemi per l'adattamento di una rete neurale convoluzionale profonda (CNN) basata su un sistema elettroencefalografico (EEG)-BCI per la decodifica delle immagini motorie della mano (MI). Ogni schema mette a punto un modello preaddestrato e addestrato in modo estensivo e lo adatta per migliorare le prestazioni di valutazione su un soggetto target. |
| 8 [28] | Convolutional neural network based approach towards motor imagery tasks EEG signals classification | Obiettivo: trasformare i segnali EEG in ingresso in immagini applicando gli approcci tempo-frequenza (T-F). Gli approcci T-F utilizzati sono la Short Time Fourier Transform (STFT) e la Continuous Wavelet Transform (CWT). Dopo la trasformazione T-F, le immagini dei segnali EEG dei compiti MI vengono applicate allo stadio DCNN. Il modello DCNN pre-addestrato, AlexNet, viene utilizzato per la classificazione. |
| 9 [29] | A temporal-spectral-based squeeze-and-excitation feature fusion network for motor imagery EEG decoding | Struttura di decodifica MI-EEG che utilizza un'innovativa rete di fusione di caratteristiche squeeze-and-excitation basata sul piano tempo-spazio. Il blocco di fusione delle caratteristiche proposto, squeeze-and-excitation, mappa le caratteristiche temporali profonde e multispettrali in mappe di caratteristiche fuse complete, che evidenziano le risposte delle caratteristiche a seconda del canale, costruendo interdipendenze tra le diverse caratteristiche del dominio. |

| | |
|--|---|
| <p>10 [30] Shallow convolutional network excel for classifying motor imagery EEG in BCI applications</p> | <p>Applicazione delle reti neurali convoluzionali (CNN) per la classificazione del MI, utilizzando un'architettura Shallow end-to-end che contiene due strati convoluzionali per l'estrazione di caratteristiche temporali e spaziali. Si ipotizza che una BCI progettata per catturare la desincronizzazione/sincronizzazione evento-correlata (ERD/ERS) all'ingresso della CNN, con un'adeguata progettazione della rete, possa migliorare la classificazione del MI con un minor numero di fasi di calibrazione.</p> |
| <p>11 [31] Zero-shot learning for EEG classification in motor imagery based BCI system</p> | <p>Lo Zero-shot learning (ZSL) riconosce oggetti le cui istanze potrebbero non essere state viste durante l'addestramento con riduzione del tempo di calibrazione. Modello di apprendimento zero-shot in grado di riconoscere sia le categorie note che quelle sconosciute di segnali EEG.</p> |
| <p>12 [32] Unsupervised feature extraction with autoencoders for EEG based multi-class motor imagery BCI</p> | <p>Obiettivo: trasformazione del segnale EEG in un nuovo dominio: vettore di pesi ottimizzato dell'autoencoder. Rete neurale non supervisionata con le seguenti caratteristiche: coefficienti autoregressivi (AR), entropia di Shannon (SE) e leader wavelet estratte dal vettore dei pesi. Implementazione di una tecnica di estrazione delle caratteristiche basata su finestre rettangolari per catturare le caratteristiche locali dei dati EEG. Utilizzo della Support Vector Machine (SVM) come rete classificatrice.</p> |
| <p>13 [33] Unsupervised Motor Imagery Saliency Detection Based on Self-Attention Mechanism</p> | <p>Metodo non supervisionato basato sul meccanismo dell'auto-attenzione per rilevare automaticamente gli intervalli salienti dei segnali MI-EEG.</p> |
| <p>14 [34] EEGSym: Overcoming inter-subject variability in motor imagery based BCIs with deep learning</p> | <p>Rete neurale convoluzionale che prevede l'uso di moduli di incipit, connessioni residue e un design che introduce nell'architettura della rete la simmetria del cervello attraverso il piano medio-sagittale.</p> |
| <p>15 [35] A deep transfer convolutional neural network framework for EEG signal classification</p> | <p>Struttura CNN di trasferimento profonda basata su VGG-16. Modello CNN VGG-16 pre-addestrato sul dataset ImageNet e modello CNN target che condivide la stessa struttura di VGG-16, tranne che per lo strato di uscita softmax.</p> |

| | |
|---|---|
| <p>16 Priming cross-session motor imagery classification with a universal deep domain adaptation framework [36]</p> | <p>Il framework Siamese deep domain adaptation (SDDA) per la classificazione cross-session MI costituito da tre componenti: un nuovo metodo di pre-elaborazione basato su caratteristiche invarianti rispetto al dominio, una perdita di discrepanza media massima per allineare le caratteristiche di incorporazione del dominio sorgente e del dominio target e una perdita centrale migliorata basata sul coseno, progettata per sopprimere l'influenza del rumore e degli outlier sulla rete neurale.</p> |
| <p>17 A novel deep learning scheme for motor imagery EEG decoding based on spatial representation fusion [37]</p> | <p>Obiettivo: costruire una CNN multistrato per un'accurata rappresentazione spaziale dei segnali MI-EEG raggruppati multicanale, per estrarre le informazioni utili presenti in un segnale MI multicanale. Le rappresentazioni spaziali invarianti vengono poi acquisite dall'addestramento tra i vari soggetti per migliorare la capacità di generalizzazione attraverso un quadro di stacked sparse autoencoder framework, che si ispira a modelli rappresentativi di deep learning.</p> |
| <p>18 EEG-Channel-Temporal-Spectral-Attention Correlation for Motor Imagery EEG Classification [38]</p> | <p>Metodo di discriminazione MI-EEG, attraverso il coefficiente di correlazione temporale-spettrale basato sull'attenzione (WTS-CC), per considerare simultaneamente le caratteristiche e la loro ponderazione nei domini spaziale, dei canali EEG, temporale e spettrale.</p> |
| <p>19 Enhancing Cross-Subject Motor Imagery Classification in EEG-Based Brain-Computer Interfaces by Using Multi-Branch CNN [39]</p> | <p>Rete neurale convoluzionale 2D multiramo (cinque rami) che impiega diversi <i>iperparametri</i> per ogni ramo. Tuttavia, il modello proposto ha un costo computazionale leggermente superiore.</p> |
| <p>20 Overlapping filter bank convolutional neural network for multi-subject multcategory motor imagery brain-computer interface [40]</p> | <p>CNN a banchi di filtri sovrapposti per incorporare informazioni discriminatorie da componenti di frequenza multiple nel riconoscimento di immagini motorie di più soggetti.</p> |
| <p>21 The ensemble machine learning-based classification of motor imagery tasks in brain-computer interface [41]</p> | <p>Metodo innovativo per l'identificazione automatica dei compiti di MI task. Efficace ibridazione dell'analisi multiscala delle componenti principali (MSPCA), della decomposizione dei pacchetti Wavelet (WPD), dell'estrazione di caratteristiche statistiche dalle sottobande e dei classificatori basati sull'apprendimento d'insieme per la categorizzazione dei compiti MI.</p> |

| | |
|---|---|
| 22 EEG conformer: Convolutional transformer for EEG decoding and visualization [42] | Trasformatore convoluzionale compatto, denominato EEG Conformer, per incapsulare le caratteristiche locali e globali in un quadro di classificazione EEG unificato. |
|---|---|

Tabella 2.3: Presentazione degli studi selezionati

2.4 Raccolta dei dati EEG

L’acquisizione dei dati EEG da parte di ciascun autore di ogni articolo è avvenuta mediante una scelta arbitraria che non costituisce oggetto di interesse in questa metanalisi.

Ogni autore ha utilizzato sistemi di acquisizione diversi, ciascuno con la propria motivazione per la scelta effettuata. A volte, si è preferito l’uso di caschetti di produzione propria, in altri casi si è optato per quelli ampiamente utilizzati in sistemi di elaborazione simili secondo la letteratura scientifica. Più raramente, ma comunque presente, la considerazione dell’acquisizione come un processo meno cruciale per il compito assegnato ha portato all’uso di caschetti più economici tra quelli disponibili sul mercato.

È degno di nota esaminare la decisione riguardante il numero di elettrodi impiegati per la registrazione dei segnali, una scelta variabile da uno studio all’altro, così come la loro disposizione sullo scalpo. Secondo la letteratura scientifica, per l’acquisizione di un task di immaginazione motoria, è consigliabile posizionare un numero maggiore di elettrodi in corrispondenza della corteccia primaria motoria e sensitiva [12].

La maggior parte degli studi impiega un numero di elettrodi che varia tra 60 e 64. Alcune ricerche esaminano un numero variabile di elettrodi posizionati sullo scalpo, a seconda del dataset utilizzato.

Nella Figura 2.5 è mostrato il posizionamento dei 64 canali comunemente acquisiti durante la registrazione del segnale EEG. In particolare, i canali che rappresentano la corteccia motoria e somato-sensoriale primaria sono evidenziati nella figura tramite elettrodi di colore blu e giallo, corrispondenti alle regioni frontali e parietali del cervello. In queste regioni si osserva un’attività più intensa e, soprattutto, più significativa per l’elaborazione di un compito motorio immaginario. I canali che mostrano maggiormente informazioni sono, infatti, F1, Fz, F2, Fp1, Fpz e Fp2 per il lobo frontale, e P1, Pz e P2 per il lobo parietale.

Per la registrazione, vengono impiegati elettrodi passivi in Ag/AgCl di tipo *wet*, i quali necessitano dell’applicazione di un gel elettrolitico per migliorare il contatto elettrodo-cute, riducendo così l’impedenza di contatto all’interfaccia. La scelta di

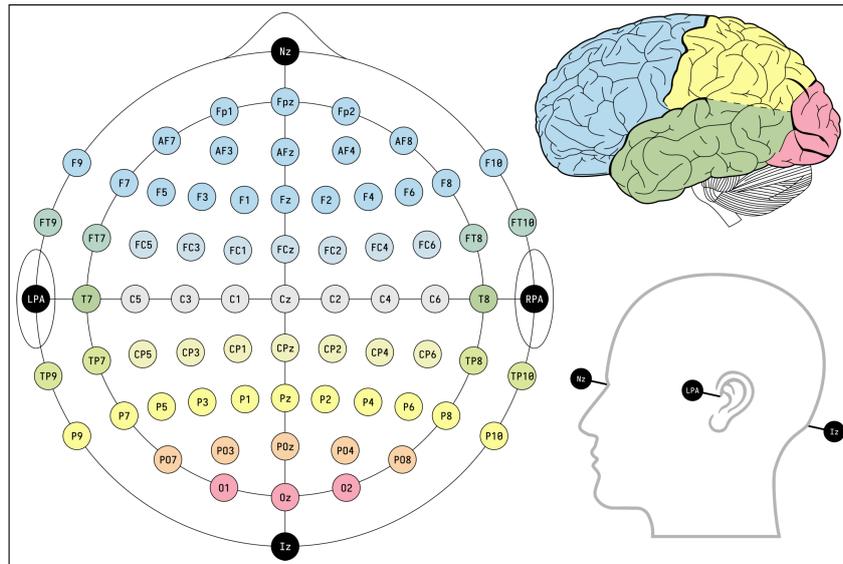


Figura 2.5: Acquisizione EEG a 64 canali [43]

tali elettrodi rispetto ai classici di tipo *dry* risulta preferibile, poiché la diminuzione dell'impedenza di contatto tra elettrodo e cute permette di ottenere segnali di qualità superiore [44]. Nonostante ciò, in alcuni studi non viene specificato il tipo di elettrodo utilizzato, lasciando libertà nella scelta durante l'acquisizione. Le moderne tecnologie che adottano elettrodi di tipo *dry* sono altrettanto valide, garantendo risultati in termini di precisione di acquisizione quasi paragonabili a quelli ottenuti con elettrodi *wet* [45]. Inoltre, il posizionamento di tali elettrodi segue il Sistema Internazionale 10/20, come descritto nel capitolo introduttivo.

2.4.1 Protocollo di acquisizione

Il procedimento di acquisizione per un compito di immaginazione motoria segue una sequenza di fasi alternate tra attività e riposo. Ogni protocollo inizia con una fase di *rest*, seguita dalla fase centrale in cui viene registrato il MI task, avviata da un segnale, spesso di natura acustica, che indica l'inizio del task. Subito dopo, si passa ad una fase aggiuntiva di riposo, durante la quale il soggetto è invitato a rilassarsi in attesa del successivo compito di MI. Di solito, l'intera registrazione per un singolo compito dura circa 13/14 secondi e comprende, quindi, due fasi di riposo oltre a quella dedicata al MI task.

Nella Figura 2.6, è rappresentato un possibile schema del protocollo di acquisizione. Questo protocollo prevede un periodo di 3 secondi in cui il paziente è invitato a fissare una croce sullo schermo di fronte a lui. Al termine di questi 3 secondi, viene emesso un segnale acustico (trigger) che avvia il MI task, e sullo schermo appare una freccia che indica la direzione (destra o sinistra) del movimento immaginato (mano

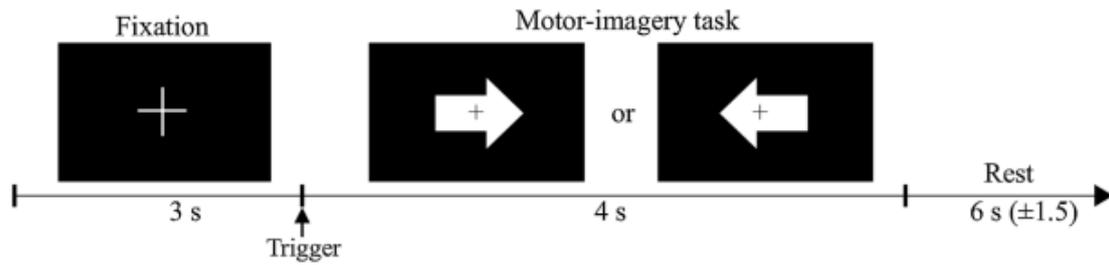


Figura 2.6: Protocollo di acquisizione del MI task [27]

destra o mano sinistra). Il compito dura circa 4 secondi, dopodiché segue un'altra fase di riposo in cui il paziente si rilassa e si prepara per il task successivo.

L'acquisizione del segnale è suddivisa in più trial o sessioni, e ogni sessione è separata da lunghi periodi di riposo. Questo approccio è adottato per assicurare che il segnale acquisito sia il più pulito possibile, privo di interferenze e soprattutto senza distrazioni da parte del paziente. La presenza di frequenti periodi di riposo garantisce, quindi, una maggiore affidabilità nell'acquisizione del compito, contribuendo a una registrazione corretta e accurata del segnale.

In presenza di più sessioni acquisite, una parte di queste viene utilizzata nella fase di training e la restante parte nella fase di evaluation/validation.

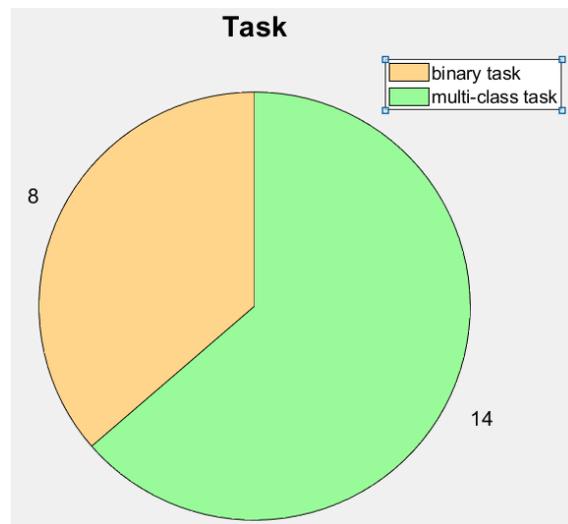


Figura 2.7: Task binario vs Task multi-classe

Nella Figura 2.7, tramite un grafico a torta viene riportata la suddivisione degli studi considerati nella presente metanalisi tra task binari e multi-classe. Più specificamente, su 22 studi inclusi nella metanalisi, 8 affrontano l'analisi del segnale EEG in un contesto di immaginazione motoria binaria come riportato in Tabella 2.4.

| ID | TASK | ID | TASK |
|--------|--------------|--------|--------------|
| 1[21] | multi-classe | 12[32] | multi-classe |
| 2[22] | binario | 13[33] | multi-classe |
| 3[23] | multi-classe | 14[34] | binario |
| 4[24] | binario | 15[35] | binario |
| 5[25] | multi-classe | 16[36] | multi-classe |
| 6[26] | multi-classe | 17[37] | binario |
| 7[27] | binario | 18[38] | multi-classe |
| 8[28] | binario | 19[39] | multi-classe |
| 9[29] | multi-classe | 20[40] | multi-classe |
| 10[30] | multi-classe | 21[41] | binario |
| 11[31] | multi-classe | 22[42] | multi-classe |

Tabella 2.4: Ripartizione degli studi tra task binario e task multi-classe

Vi è una distinzione tra task binario e task multi-classe. Il task binario coinvolge il movimento immaginario della mano destra o sinistra, mentre il task multi-classe comprende più di due movimenti immaginari, che possono coinvolgere non solo le mani, ma anche i piedi e la lingua.

Nella fase centrale del compito, in cui al paziente viene richiesto di immaginare il movimento, nei task multi-classe vengono mostrati simboli differenti sullo schermo. Questi simboli hanno lo scopo di guidare il paziente nell'immaginare il task specifico. Ad esempio, come è possibile vedere in Figura 2.8, potrebbero comparire frecce direzionali verso destra per indicare il movimento immaginario della mano destra, frecce verso sinistra per il movimento immaginario della mano sinistra, frecce verso il basso per il movimento immaginario dei piedi, e infine, un'icona stilizzata della lingua per il movimento immaginario della lingua.

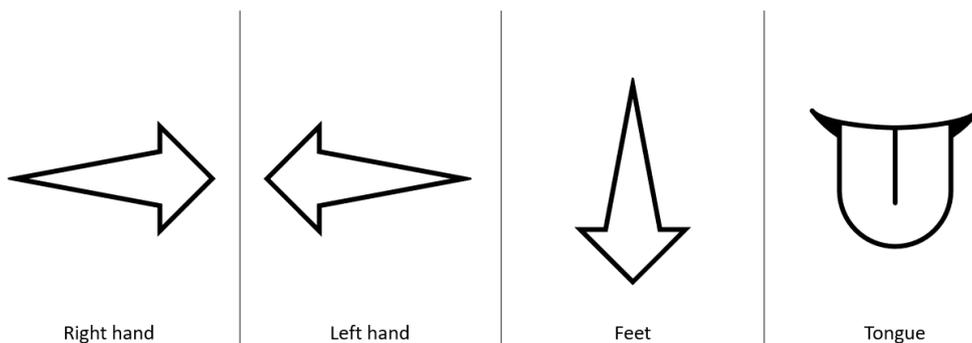


Figura 2.8: Task multi-classe

2.5 Pre-processing dei segnali EEG

Per quanto riguarda le tecniche di pre-processing utilizzate nei vari studi esaminati, è stato possibile individuare una tendenza comune che ha orientato la scelta verso una direzione univoca per l'elaborazione dei segnali grezzi, appena acquisiti.

Dato che il segnale EEG è ampiamente utilizzato per una varietà di compiti e analisi, la letteratura scientifica fornisce agli studiosi linee guida sull'approccio al segnale e sui primi passi da intraprendere per ottenere dati privi di rumore e artefatti, al fine di massimizzare l'informazione in base agli obiettivi di ricerca.

Inizialmente, si identificano le fasce di frequenza in cui concentrare il segnale EEG grezzo acquisito, al fine di ottenere un segnale privo di artefatti e di interferenze rumorose.

Come riportato da Al-Saegh *et al.*, 2021 [46], in alcuni casi, oltre alla semplice rimozione del rumore di fondo, può essere vantaggioso migliorare la qualità dei segnali per facilitare il successivo processo di elaborazione, in linea con gli obiettivi iniziali. Il segnale EEG risulta compromesso da diverse fonti esterne [47], tra cui il rumore ambientale proveniente dall'ambiente circostante, il rumore associato al segnale oculare EOG, il segnale elettromiografico EMG e il segnale cardiaco ECG, che costituisce un riferimento di base costante. Inoltre, durante l'acquisizione, si verificano interferenze di rete generate dagli apparecchi collegati alla rete elettrica, contribuendo ulteriormente alla corruzione del segnale EEG.

Per identificare le bande di frequenza cruciali per il compito di immaginazione motoria, la letteratura suggerisce che una risposta significativa si manifesti all'interno delle onde mu (8-13 Hz) e beta (14-35 Hz) [48]. In particolare, l'analisi delle onde beta riveste un'importanza fondamentale poiché evidenzia un significativo cambiamento nella morfologia del segnale quando si esegue un compito coinvolgente gli arti, sia superiori che inferiori [49]. Pertanto, si opta per l'utilizzo di un filtro passabanda al fine di concentrare esclusivamente le frequenze di interesse per l'analisi.

Dato che le bande di frequenza rilevanti per un MI task sono quelle comprese nelle onde mu e beta, si decide di adottare un filtro passabanda con frequenze di taglio comprese tra 4 e 40 Hz. Si opta per un margine di tolleranza non rigidamente limitato alle estremità delle onde mu e beta per garantire il mantenimento di tutto il contenuto informativo, anche se si trova leggermente al di sotto o al di sopra delle bande di frequenza comunemente indicate dalla letteratura scientifica.

Per la rimozione dell'interferenza di rete [50], si preferisce utilizzare un filtro Notch con una frequenza di taglio di 50 o 60 Hz, a seconda della regione geografica in cui avviene l'acquisizione del segnale elettrico e in cui è in uso l'apparecchiatura elettrica

(60 Hz negli Stati Uniti, 50 Hz in Europa).

| ID | Pre-processing | ID | Pre-processing |
|-------|--|--------|--|
| 1[21] | Passabanda [4-40 Hz], Notch [50 Hz] | 12[32] | Dataset 2a: Passabanda [0,5-100 Hz], Notch [50 Hz] Dataset 3a: Passabanda [1-50 Hz], Notch [50 Hz] |
| 2[22] | Eliminazione di segmenti di ampiezza inferiore a 100 μ m, Passabanda [0,5-40 Hz], Notch [50 Hz] | 13[33] | Passabanda Butterworth ordine 5 [4-40 Hz], Notch [50 Hz] |
| 3[23] | Dataset 2a: Passabanda [0,5-100 Hz], Notch [50 Hz] Dataset 3a: Passabanda [1-50 Hz], Notch [50 Hz] | 14[34] | Channel Extraction (8/16 electrodes), Notch [50/60 Hz], Common Average Reference filter, ricampionamento a 128 Hz, MI task Extraction |
| 4[24] | Wavelet denoising, Euclidean Space Data Alignment | 15[35] | Passabanda [4-32 Hz] |
| 5[25] | Dataset 2a: Passabanda [0,5-100 Hz], Notch [50 Hz] Dataset 2b: Passabanda [0,5-100 Hz], Notch [50 Hz] | 16[36] | Passabanda Blackman finestra [4-38 Hz] |
| 6[26] | Dataset 2a: Passabanda [0,5-100 Hz], Notch [50 Hz] Stroke patients: Passabanda [0,1-100 Hz], Notch [50 Hz] | 17[37] | Common Average Filter, Passabanda [7-35 Hz] |
| 7[27] | Estrazione MI task, ricampionamento a 4 Hz | 18[38] | Dataset 2a/2b: Passabanda [0.5-100 Hz], Notch [50 Hz] Track#1: Passabanda [8-30 Hz] |
| 8[28] | Hamming (120 unità), Overlap (100 unità), Zero-padding (200 unità) | 19[39] | Physionet: 8 sliding window senza overlap, Notch [60 Hz], Passabanda [2-60 Hz] Dataset 2a/2b: Passabanda [0.5-100 Hz] + Notch [50 Hz] |
| 9[29] | Dataset 2a: Passabanda Butterworth ordine 3 [0-38 Hz] HGD: Passabanda Butterworth ordine 3 [0-125 Hz], ricampionamento a 250 Hz | 20[40] | Dataset 2a: Passabanda [0.5-100 Hz], Notch [50 Hz] |

| | | | |
|--------|--|--------|---|
| 10[30] | Dataset 2a: Passabanda [0,5-100 Hz], Notch [50 Hz] Dataset 2b: Passabanda [0,5-100 Hz], Notch [50 Hz] Dataset 4a: ricampionamento a 250 Hz | 21[41] | Passabanda [0-50 Hz], ricampionamento a 100 Hz |
| 11[31] | Passabanda [8-30 Hz] | 22[42] | Dataset 2a/2b: passabanda [4-40 Hz] SEED: passabanda [4-47 Hz], Z-score standardization |

Tabella 2.5: Tecniche di pre-processing

2.5.1 Filtraggio e riduzione del rumore

Nella Tabella 2.5, si evidenzia che l'81.8% degli studi considerati in questa metanalisi ha impiegato un filtro passabanda (Figura 2.9) per eliminare le frequenze non rilevanti per l'analisi del MI task. Non tutti adottano margini stretti attorno alle onde mu e beta, come raccomandato dalla letteratura. Alcuni preferiscono invece un intervallo più ampio, giustificando tale scelta per preservare un maggiore contenuto frequenziale al fine di evitare l'eliminazione di parti significative dei segnali acquisiti.

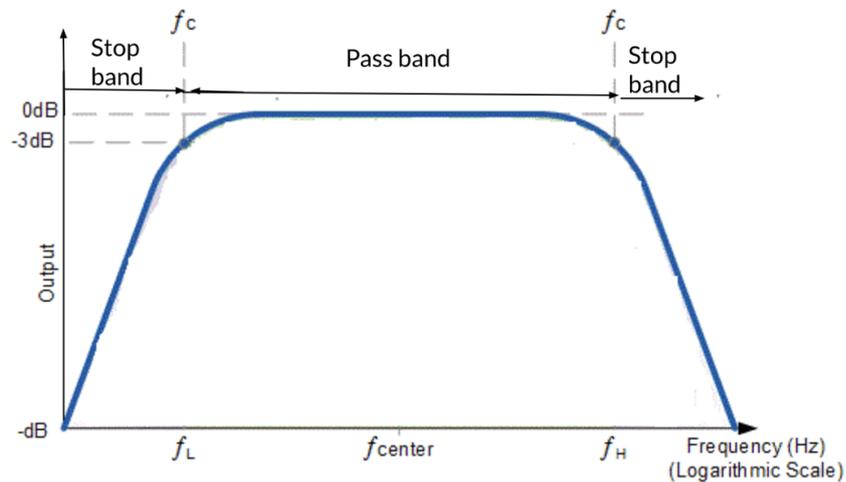


Figura 2.9: Filtro passabanda reale [51]

Alcuni di questi studi implementano tecniche di pre-processing aggiuntive, le quali indubbiamente contribuiscono al miglioramento del segnale. Tuttavia, risulterebbero quasi superflue e non essenziali in quanto aggiungono un ulteriore costo computazionale e richiedono risorse che potrebbero essere evitate. Ad esempio, Perez *et al.*,

2022 [34], utilizzano un filtro *Common Average Reference* (CAR), analogo a quello adoperato da Yang *et al.*, 2020 [37]. Il filtro CAR implica l'utilizzo di una media dei dati di registrazione provenienti dal segnale EEG come riferimento, consentendo così di isolare i potenziali corticali associati alle attività sensorimotorie. Questi potenziali sono soggetti a modulazione in risposta all'intenzione di movimento dell'utente [52].

Wang *et al.*, 2022 [24], presentano un approccio di pre-processing insolito che impiega un filtro di denoising e un allineamento dei dati nello spazio euclideo. Queste metodologie vengono adoperate per migliorare il rapporto segnale-rumore (SNR) inizialmente e per agevolare il processo successivo di Feature Extraction, consentendo la separazione delle informazioni rilevanti per ogni canale. Al momento della registrazione, l'SNR dei segnali EEG risulta tipicamente basso. Ciò è dovuto all'ampiezza del segnale, che si attesta sull'ordine dei microvolt, e alla sua suscettibilità alle interferenze elettromagnetiche provenienti dall'ambiente circostante. Un miglioramento del rapporto segnale-rumore è pertanto uno dei prerequisiti fondamentali per garantire un'analisi sicura e affidabile del segnale.

Ma *et al.*, 2022 [22], scelgono di escludere segmenti con un'ampiezza inferiore a 100 μm , sostenendo che tali segmenti non forniscono informazioni rilevanti, ma piuttosto derivano da fonti di rumore.

Indubbiamente, le tecniche citate precedentemente rivestono un'importanza scientifica significativa. Tuttavia, nel protocollo di elaborazione del segnale EEG per la presente metanalisi, si è scelto consapevolmente di non considerarle. Questo perché tali tecniche non sono considerate fondamentali e richiedono un costo computazionale elevato.

2.5.2 Estrazione del MI task

Si ritiene altresì essenziale isolare il MI task dalle fasi di riposo precedenti e successive al fine di non sovraccaricare l'intera rete di elaborazione con dati che, è noto a priori, non contengono informazioni rilevanti per l'analisi [34]. Come accennato in precedenza, le fasi di riposo che precedono e seguono il MI task sono cruciali durante l'acquisizione poiché consentono al soggetto di rilassarsi e di eseguire al meglio il compito richiesto. Questo approccio aiuta a evitare il rischio che le acquisizioni siano compromesse a causa di distrazioni del paziente.

Si è scelta l'estrazione del segnale a partire da 2-3 secondi dopo l'*onset time* fino a 0.5 secondi dopo la conclusione del MI task. Questo intervallo assicura che non vengano tralasciate informazioni importanti per l'analisi. Si preferisce avere un segnale più ampio, anche se meno informativo, rispetto a un segnale troncato che potrebbe perdere dati rilevanti. In questo modo si riduce significativamente il rumore nei dati

e si concentra l'attenzione unicamente sul task.

In aggiunta, questo approccio favorisce una maggiore percentuale di successo nelle prestazioni dell'algoritmo di classificazione, poiché si riduce la variabilità dei dati e si concentra l'attenzione sulle caratteristiche specifiche del MI task. Infine, ma non meno importante, questa procedura riduce notevolmente il carico computazionale, specialmente considerando che spesso si parte da un set di dati di dimensioni considerevoli.

Inoltre, si consiglia di eseguire il ricampionamento dei segnali nel caso in cui uno stesso studio desideri allineare i dati provenienti da acquisizioni diverse, campionati con frequenze di campionamento differenti. Il processo di ricampionamento consiste nel selezionare una frequenza di campionamento unica che sia valida per tutti i segnali inclusi nello studio e che corrisponda alla frequenza minima utilizzata tra i dati acquisiti.



Figura 2.10: Pre-processing

In sintesi, i passaggi per il pre-processing dei dati, al fine di prepararli per le analisi successive, sono riassunti nella Figura 2.10.

2.6 Tecniche di Data Augmentation

Prima di procedere con la definizione delle tecniche relative all'estrazione delle caratteristiche (Feature Extraction), è opportuno menzionare la possibilità di introdurre una fase intermedia nota come *Data Augmentation*.

La Data Augmentation ha lo scopo di prevenire l'overfitting dei modelli di reti neurali utilizzati per la classificazione generando artificialmente nuovi dati a partire dai dati di training acquisiti [53]. Questa tecnologia si basa su due strategie principali: manipolazioni di base dei dati e deep learning. Mentre il primo metodo opera direttamente nello spazio di input, il secondo si concentra sulla trasformazione dello spazio delle caratteristiche dei dataset [54].

La prima tecnica, che si basa sulle manipolazioni dei dati, coinvolge semplici trasformazioni geometriche che sono intuitive e hanno un costo computazionale basso.

Queste manipolazioni includono operazioni come il *flipping* (rotazione sul piano orizzontale o verticale), il *cropping* (ritaglio e unione delle parti rimanenti), e la *rotation* (rotazione su un'asse di coordinate prestabilite a priori), oltre alla semplice aggiunta di rumore ai dati iniziali. Utilizzando queste tecniche, si ottiene un set di dati aumentato che si basa sui dati originali.

La seconda tecnica, che si basa sul deep learning, applica le reti neurali profonde per mappare lo spazio dei dati e realizzare l'estrazione delle caratteristiche per ricostruire i dati artificiali (partendo da un'alta dimensionalità si arriva ad una bassa dimensionalità). Esistono due strategie tipiche di deep learning: autoencoder e reti generative avversarie (GAN).

Gli autoencoder (Figura 2.11) possono essere addestrati su un set di dati esistente e successivamente utilizzati per generare nuovi dati sintetici che sono simili ai dati originali. Questi nuovi dati possono essere utilizzati per aumentare il set di dati di addestramento e migliorare la generalizzazione del modello. Essi risultano anche fondamentali per la ricostruzione di dati danneggiati in fase di acquisizione o incompleti.

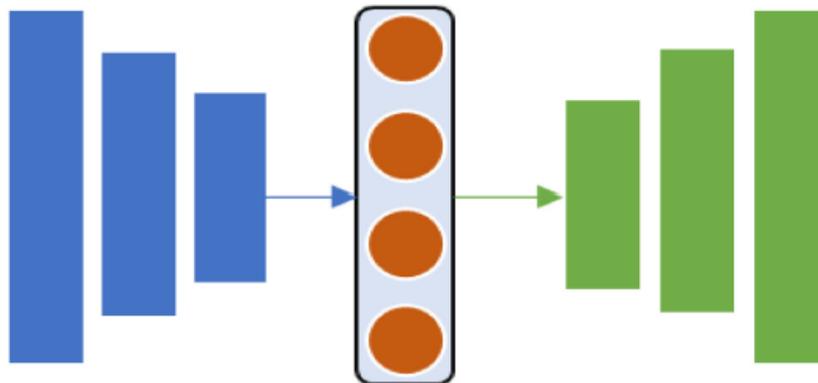


Figura 2.11: Autoencoder: in blu sono rappresentati gli input layers, in verde gli output layers [54]

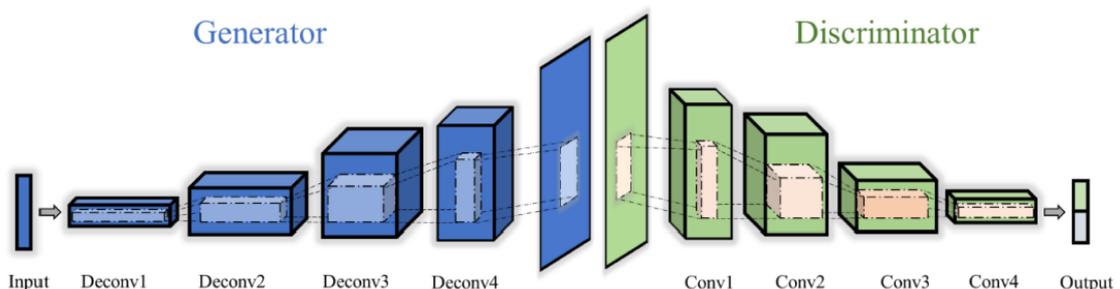


Figura 2.12: GAN [54]

Le GAN (Figura 2.12) funzionano attraverso due reti neurali, il generatore e il discriminatore, impegnate in un processo di apprendimento avversario. Durante l'addestramento, il generatore e il discriminatore si migliorano reciprocamente in un ciclo di feedback continuo:

- Il generatore cerca costantemente di produrre dati sintetici sempre più simili ai dati reali, con l'obiettivo di ingannare il discriminatore.
- Il discriminatore cerca di affinare la sua abilità nel distinguere tra dati reali e dati sintetici, al fine di identificare e rifiutare quelli sintetici.

Questo processo di competizione continua porta alla convergenza, dove il generatore produce dati sintetici difficilmente distinguibili da quelli reali, mentre il discriminatore ha difficoltà a distinguere tra i due tipi di dati.

Nella presente metanalisi, la Data Augmentation viene presa in considerazione unicamente da 3 studi su 22, come riporta il grafico a torta in Figura 2.13.

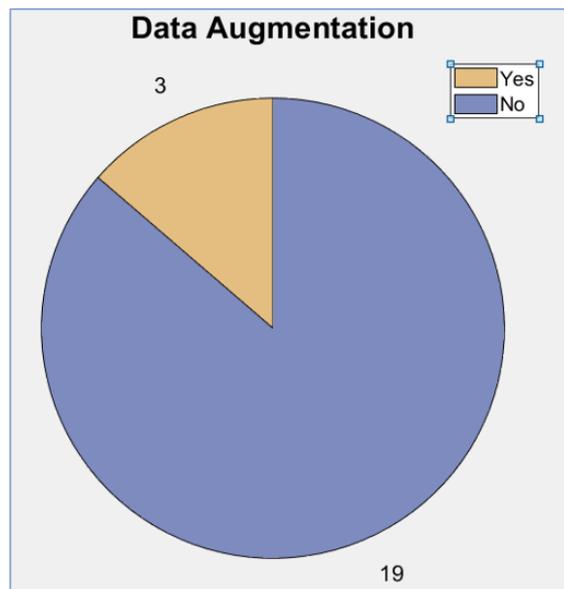


Figura 2.13: Data Augmentation

Le tecniche di Data Augmentation adoperate sono riassunte come segue:

- Hermosilla *et al.*, 2021 [30], adottano la *trial crops strategy* (Figura 2.14) per ampliare i dati nel training set. Tale tecnica consiste nell'estrarre brevi segmenti di segnale a partire dall'inizio dell'attivazione (onset time) per alcuni secondi. L'obiettivo di questa sequenza estratta è catturare più efficacemente le variazioni di ERD e ERS all'interno di ciascuna prova. Questo approccio di Data Augmentation mira a ottenere gli stessi benefici della tecnica di pre-processing utilizzata precedentemente, che consisteva nell'estrazione del MI task, tralasciando i periodi di riposo iniziali e finali.

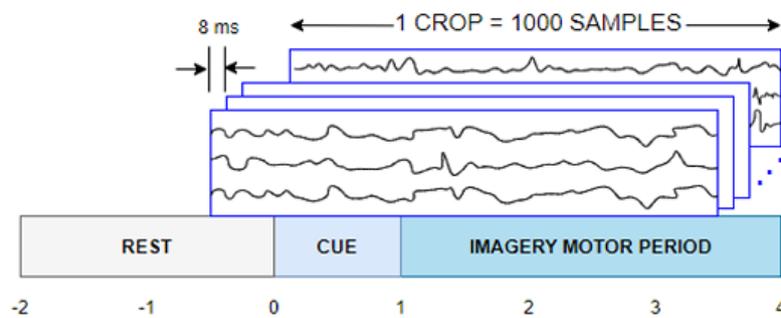


Figura 2.14: Trial crops strategy [30]

- Perez *et al.*, 2022 [34] utilizzano 3 tecniche di Data Augmentation:
 - *Patch perturbation*: Questa tecnica implica l'inserimento random di rumore gaussiano in alcune sequenze di segnali provenienti da canali selezionati casualmente. L'obiettivo è istruire il modello a generalizzare il più possibile, non permettendo che l'aggiunta di rumore influenzi significativamente il risultato. Naturalmente, questo risultato è ottenuto mantenendo almeno un canale o parti del segnale intatti e immutati.
 - *Hemisphere perturbation*: Si parte dall'ipotesi che la differenza tra un segnale durante il movimento immaginario della mano destra e quello della mano sinistra possa essere decodificata attraverso i cambiamenti dell'EEG in un emisfero. Pertanto, in questo contesto, gli elettrodi corrispondenti all'emisfero destro o sinistro vengono disturbati tramite l'aggiunta di rumore o cambiando la loro posizione in un ordine casuale. L'obiettivo di questa tecnica è insegnare al modello un metodo chiaro e preciso per identificare il MI task in ciascun emisfero.
 - *Random shift*: Questa tecnica parte dall'ipotesi che ogni utente possieda tempi di azione e reazione variabili, i quali possono cambiare in base al

livello di concentrazione/distrazione durante l'esecuzione della prova. Benché l'onset time di ciascuna prova sia noto con precisione, non si dispone di informazioni riguardanti il tempo di reazione specifico per ogni singola prova. Pertanto, questa tecnica prevede lo spostamento dell'onset time di mezzo secondo, che corrisponde al tempo medio per la scelta di un compito binario.

- Song *et al.*, 2022 [42] utilizzano un'altra tecnica chiamata *Segmentation and Reconstruction*. Come suggerisce il nome, questa tecnica consiste nel suddividere e successivamente ricostruire i segmenti concatenandoli nel dominio del tempo al fine di generare nuovi dati.

Nonostante le prove ottenute tramite l'utilizzo delle tecniche di Data Augmentation risultino più consistenti rispetto a quelle in cui tali tecniche non vengono adottate, il numero di studi che le impiegano risulta essere molto limitato rispetto all'insieme degli studi considerati nella metanalisi. La motivazione di questa scelta non è immediatamente chiara. Pur esistendo prove scientifiche che supportano l'efficacia delle tecniche di Data Augmentation nel contrastare il problema dell'overfitting e nell'incrementare la capacità di generalizzazione dei modelli di classificazione, portando a una maggiore accuratezza, l'inclusione di dati artificiali comporta notevoli costi computazionali e presenta sfide in termini di requisiti di memoria [55].

La ricerca scientifica sicuramente contribuirà significativamente ad avanzare nell'utilizzo delle tecniche di Data Augmentation e nei relativi benefici. Tuttavia, la questione principale sarà valutare se i vantaggi derivanti da tali tecniche superino i costi delle risorse computazionali impiegate.

2.7 Feature Extraction

L'estrazione delle caratteristiche (Feature Extraction) rappresenta il core centrale insieme ad un buon classificatore per ottenere una percentuale elevata di successo nella classificazione dei task di immaginazione motoria.

La Feature Extraction si riferisce al processo di trasformazione dei dati grezzi in caratteristiche numeriche che possono essere elaborate, preservando le informazioni provenienti dal set di dati originale [56]. Essa può essere effettuata manualmente o automaticamente:

- L'estrazione manuale delle caratteristiche richiede l'identificazione e la descrizione delle caratteristiche rilevanti per un dato problema e l'implementazione di un metodo per estrarle.

- L'estrazione automatica delle caratteristiche utilizza algoritmi specializzati o reti neurali profonde per estrarre automaticamente le caratteristiche da segnali o immagini senza bisogno di intervento umano. Questa tecnica può essere molto utile quando si desidera passare rapidamente dai dati grezzi allo sviluppo di algoritmi di Machine Learning (ML).

Con l'avvento del Deep Learning (DL), l'estrazione delle caratteristiche viene effettuata ad opera dei primi strati più profondi delle reti neurali.

Nella presente metanalisi, la ricerca iniziale degli articoli si è orientata, a partire dalla scelta dei criteri di inclusione, verso quelli che prendevano in considerazione esclusivamente tecniche di ML e DL. Questa selezione è stata determinata dalla considerazione che tali metodologie siano all'avanguardia rispetto ad altri approcci, come quelli basati su metodi statistici.

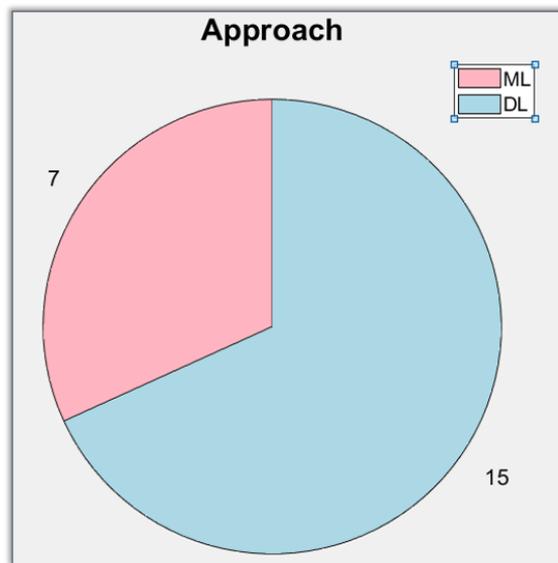


Figura 2.15: Machine Learning vs Deep Learning

La distribuzione dei 22 articoli considerati tra quelli che utilizzano un approccio basato su ML e quelli che, al contrario, impiegano il DL è illustrata nella Figura 2.15 attraverso un grafico a torta. Come evidente, 7 articoli impiegano approcci basati su ML, mentre 15 fanno uso di tecniche fondate sul DL.

Da questo momento in poi, si opta per trattare separatamente le tecniche di estrazione delle caratteristiche e di classificazione per un task binario e un task multi-classe. Questa scelta mira a fornire al lettore due pipeline distinte in base all'obiettivo di classificazione che desidera perseguire.

| TASK MULTI-CLASSE | | | |
|--------------------------|--|-----------|--|
| ID | Feature Extraction | ID | Feature Extraction |
| 1[21] | Common Feature Extraction + Class Specific Linear Extractor | 12[32] | Autoregressive coefficients + Wavelet Packet Entropy + Wavelet Fractal Estimates |
| 3[23] | FBCSP | 13[33] | CSP |
| 5[25] | FBCSP + STDF | 16[36] | EEGNet |
| 6[26] | CSP | 18[38] | Temporal FE module + Deep EEG channel attention module + Wavelet based temporal-spectral attention module |
| 9[29] | Deep temporal and Multi spectral convolution blocks + Squeeze and Excitation | 19[39] | EEGNet Fusion V2 |
| 10[30] | Temporal and Spatial convolution layers | 20[40] | Overlapping filter bank CNN |
| 11[31] | CSP | 22[42] | Convolution module + Self-Attention module |

Tabella 2.6: Feature Extraction task multi-classe

| TASK BINARIO | | | |
|---------------------|---------------------------|-----------|--|
| ID | Feature Extraction | ID | Feature Extraction |
| 2[22] | EEGNet | 14[34] | Temporal and spatial convolution layers |
| 4[24] | CSP | 15[35] | VGG-16 CNN |
| 7[27] | CNN | 17[37] | 2D-kernels-based-CNN |
| 8[28] | CNN (AlexNet) | 21[41] | Wavelet Packet Decomposition |

Tabella 2.7: Feature Extraction task binario

Nel prosieguo vengono esaminate approfonditamente le tecniche di estrazione delle caratteristiche adottate dagli studi inclusi nella metanalisi. Queste tecniche sono raggruppate in macro-categorie illustrate nella Tabella 2.8, ad eccezione di alcuni studi inclusi in "altri metodi" che impiegano tecniche al di fuori di qualsiasi macro-categoria e richiedono un'analisi separata.

| Feature Extraction | Numero di pubblicazioni | Percentuale |
|--------------------------------------|-------------------------|-------------|
| Common Spatial Pattern | 4 | 18.3% |
| Filter Bank CSP | 1 | 4.5% |
| FBCSP + Short Time Fourier Transform | 1 | 4.5% |
| Wavelet Packet Decomposition | 1 | 4.5% |
| Reti neurali convoluzionali | 12 | 54.6% |
| Altri metodi | 3 | 13.6% |

Tabella 2.8: Tecniche di Feature Extraction

Common Spatial Pattern

Una delle prime tecniche di Feature Extraction che meritano attenzione è la Common Spatial Pattern (CSP). Questa metodologia è impiegata nel 27,3% degli articoli inclusi nella metanalisi, sia singolarmente che in combinazione con altre tecniche per ottimizzare l'estrazione delle caratteristiche.

L'algoritmo CSP è adottato per migliorare la risoluzione spaziale dei segnali EEG. È in grado di individuare attività anomale nei segnali registrati, le quali sono cruciali per identificare pattern discriminanti utili nella classificazione dei MI task nel contesto delle BCI. Inoltre, contribuisce significativamente a migliorare il rapporto segnale-rumore dei segnali EEG.

Il metodo matematico in questione mira a ottenere un filtraggio spaziale ottimale tramite la decomposizione del segnale EEG. Tale approccio massimizza la varianza (la potenza del segnale) di una condizione e contemporaneamente minimizza la varianza della condizione opposta [57]. Il metodo CSP usa i filtri spaziali x ottimizzando la funzione:

$$Q(x) = \frac{x^T P_1^T P_1 x}{x^T P_2^T P_2 x} = \frac{x^T C_1 x}{x^T C_2 x} \quad (2.1)$$

dove T indica la trasposizione della matrice e P_i restituisce la matrice *training data* con i campioni sulle righe e i canali sulle colonne. La matrice di covarianza spaziale per una classe particolare i è C_i . Ci sono molti modi per risolvere questo problema di ottimizzazione, ma la tecnica funziona visualizzando inizialmente che la funzione $Q(x)$ rimane invariata se il filtro x viene ridimensionato. Infatti, $Q(kx) = Q(x)$, dove k indica una costante reale che indica che il ridimensionamento del filtro x è

arbitrario. Pertanto, la minimizzazione di $Q(x)$ è paragonabile alla minimizzazione di $x^T C_1 x$ soggetto al vincolo $x^T C_2 x = 1$, poiché esiste sempre un modo possibile per trovare un fattore di ridimensionamento di x tale da far sì che $x^T C_2 x = 1$.

Questo problema di ottimizzazione vincolata equivale a minimizzare la seguente funzione utilizzando il metodo del moltiplicatore di Lagrange:

$$L(\beta, x) = x^T C_1 x - \beta(x^T C_2 x - 1) \quad (2.2)$$

La derivata di L rispetto a x è 0, dove β è il moltiplicatore di Lagrange, e i filtri x che minimizzano L sono tali che:

$$\frac{\delta L}{\delta x} = 2x^T C_1 - 2\beta x^T C_2 = 0 \iff C_1 x = \beta C_2 x \iff C_2^{-1} C_1 x = \beta x \quad (2.3)$$

Si tratta di un problema standard di autovalori. Quindi, gli autovettori di $Z = C_2^{-1} C_1$ sono usati per ottenere la minimizzazione 2.1 corrispondente agli autovalori più grandi e più bassi. Le caratteristiche sono estratte come logaritmo della varianza del segnale EEG nella banda selezionata dopo la proiezione dei filtri x utilizzando la matrice CSP.

Se la varianza del segnale cerebrale correlato riflette l'intenzione di movimento del soggetto, il CSP risulta un algoritmo valido per l'estrazione delle caratteristiche. Tuttavia, il CSP è noto per la sua suscettibilità al rumore e all'overfitting. Per mitigare questo problema, talvolta vengono impiegate varianti avanzate come il Filter Bank CSP (FBCSP) [23] o il CSP associato alla tecnica Spatio-Temporal Discrepancy Feature (STDF) [25].

Deng *et al.*, 2021 [23] utilizzano la tecnica FBCSP che differisce dal tradizionale CSP per l'aggiunta di feature estratte all'interno di più bande di frequenza. L'algoritmo FBCSP prevede una fase aggiuntiva prima dell'applicazione della tecnica CSP. In particolare, viene impiegato un banco di filtri che opera un filtraggio di tipo passa-banda sulle acquisizioni del segnale EEG su diverse bande di frequenza.

Nella Figura 2.16, si osserva che il segnale EEG viene inizialmente filtrato utilizzando una serie di filtri passabanda con frequenze di taglio a blocchi adiacenti e contigui (ad esempio, 4-8 Hz, 8-12 Hz, ..., 36-40 Hz). Successivamente, viene applicato l'algoritmo CSP su ciascuna delle bande di frequenza esaminate nella prima fase. Quindi, ogni coppia di filtro passabanda e filtro spaziale produce caratteristiche specifiche per l'intervallo di frequenza del filtro passabanda [58]. In seguito a questi primi due passaggi, si procede con una selezione delle caratteristiche per determinare quelle più discriminanti dal banco di filtri. Infine, l'ultima fase comprende la classificazione delle caratteristiche mediante un algoritmo di classificazione.

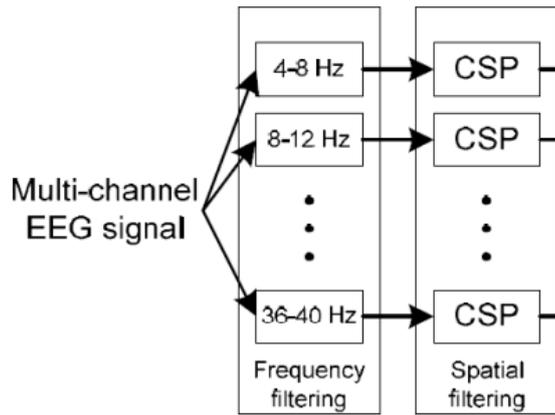


Figura 2.16: FBCSP [58]

Luo *et al.* (2020) [25] integrano la tecnica STDF con la CSP per l'estrazione delle caratteristiche. La tecnica STDF si focalizza sul rilevamento delle discrepanze spaziali e temporali nei dati dell'EEG. Pertanto, oltre alla convenzionale tecnica CSP, che estrae le caratteristiche nello spazio, la combinazione con la tecnica STDF consente di individuare feature tra il dominio spaziale e temporale dei dati.

Wavelet Packet Decomposition

Subasi *et al.* (2021) [41] utilizzano la tecnica *Wavelet Packet Decomposition* (WPD) nel processo di estrazione delle caratteristiche. Tuttavia, la selezione della WPD è stata esclusiva in uno studio su 22 inclusi nella metanalisi. Nonostante presenti numerosi vantaggi, questa tecnica non è ampiamente utilizzata nell'analisi dei segnali a causa dei suoi svantaggi. Tra i vantaggi, la WPD è in grado di individuare caratteristiche non stazionarie, un aspetto non comune nelle tecniche di estrazione delle caratteristiche attualmente disponibili, e offre una rappresentazione multirisoluzione dei segnali. D'altra parte, gli svantaggi includono un elevato costo computazionale e una forte dipendenza della performance dalla scelta della *mother wavelet* e dei parametri di decomposizione. Una selezione errata della *mother wavelet* o dei parametri potrebbe compromettere l'efficacia della rappresentazione del segnale.

Le *wavelet* possono essere descritte attraverso l'equazione 2.4, dove il parametro di dilatazione è rappresentato da s e il parametro di traduzione è rappresentato da u . I parametri possono essere generati nello stesso tempo con frequenze differenti.

$$\Psi(t) = \frac{1}{\sqrt{S}} \Psi\left(\frac{t-u}{s}\right) \quad (2.4)$$

Il processo di decomposizione di un segnale $x(t)$, utilizzando la trasformata *wavelet*,

è dato da:

$$W_X(u, s) = \frac{1}{\sqrt{S}} \int_{-\infty}^{+\infty} x(t) \Psi^* \frac{(t-u)}{s} dt \quad (2.5)$$

In questo studio viene selezionata la Discrete Wavelet Transform (DWT) come *mother wavelet* il che comporta un ulteriore svantaggio noto come "comportamento di varianza di spostamento". Esso varia l'energia del risultato della DWT e non riesce a rilevare un punto di cambiamento anche quando un segnale originale si sposta solo di un campione [59].

Reti Neurali Convoluzionali

Dodici degli studi su ventidue sembrano preferire l'utilizzo delle reti neurali convoluzionali (CNN) durante il processo di Feature Extraction.

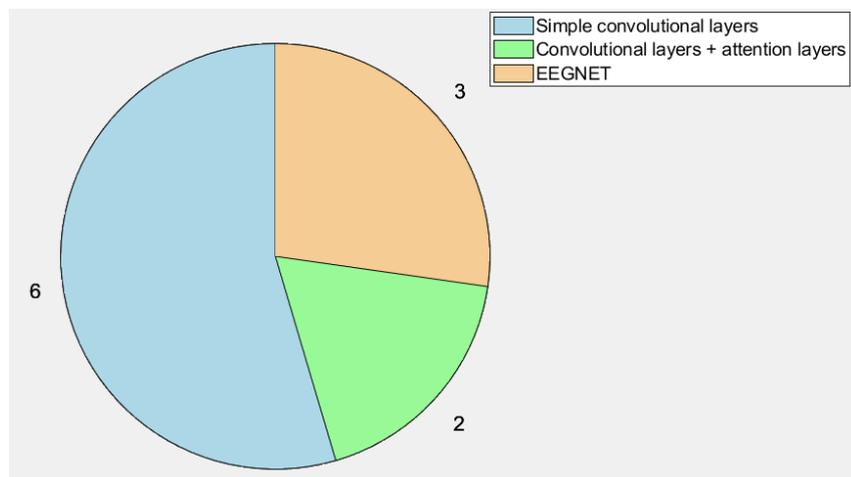


Figura 2.17: Tipologia reti convoluzionali CNN

Il grafico mostrato nella Figura 2.17 suddivide le reti convoluzionali in tre categorie: reti convoluzionali semplici, reti convoluzionali con attention layers e EEGNet.

Le reti convoluzionali semplici effettuano convoluzioni temporali e/o spaziali, mentre le reti convoluzionali con attention layers includono strati aggiuntivi per focalizzare l'attenzione su parti specifiche del segnale durante l'elaborazione. L'EEGNet è una particolare architettura di rete neurale convoluzionale progettata specificamente per l'analisi di segnali EEG.

La Figura 2.18 mostra una generica rete neurale convoluzionale profonda costituita da più layer in successione tra loro. In input alla rete viene fornita la matrice contenente i segnali EEG già sottoposti alla fase di preprocessing, in output la rete restituisce la matrice contenente le classi di appartenenza dei segnali di input.

I layer interposti tra input e output sono utili per processare il segnale sia durante la

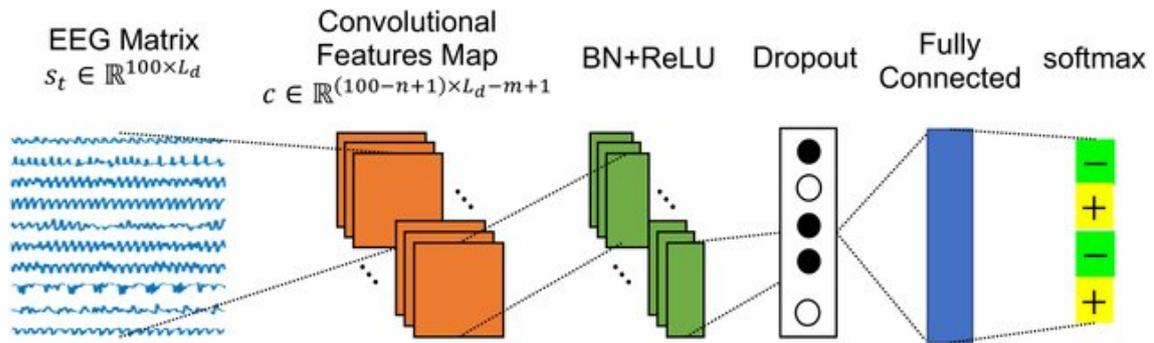


Figura 2.18: Esempio di rete neurale convoluzionale CNN [60]

fase di estrazione delle caratteristiche sia nella fase di classificazione. In particolare, si trovano [60]:

1. **Layer di Convoluzione:** eseguono operazioni di convoluzione, applicando filtri ai segnali di input per estrarre caratteristiche rilevanti. Ogni filtro identifica specifici pattern sia spaziali che temporali (feature map).
2. **Layer di Pooling:** riducono la dimensione spaziale delle feature map, riducendo così il numero di parametri e rendendo la rappresentazione più gestibile. I tipi comuni di pooling sono il max pooling e il mean pooling.
3. **Layer di Attivazione:** dopo la convoluzione, applicano una funzione di attivazione non lineare (come ReLU - Rectified Linear Unit) per introdurre non linearità nell'output dei layer convoluzionali.
4. **Layer di Normalizzazione Batch:** normalizzano l'input di ciascun batch, accelerando la convergenza del modello e migliorando la generalizzazione.
5. **Layer di Dropout:** il dropout è una tecnica di regolarizzazione che viene applicata durante l'addestramento per ridurre l'overfitting. I neuroni vengono disattivati casualmente durante l'addestramento per evitare che il modello dipenda troppo da specifiche caratteristiche dei dati di addestramento.
6. **Layer Fully Connected:** costituiti da neuroni interconnessi, utilizzati per combinare le feature estratte dalle fasi precedenti della CNN e produrre l'output finale. In questo livello, viene impiegata la *softmax function*, la quale restituisce un vettore di probabilità di appartenenza a una delle classi possibili per ciascuna delle feature estratte.

I primi tre strati della rete neurale convoluzionale lavorano insieme nel processo di Feature Extraction. Questi strati, combinandosi, iterando e scambiandosi, contribuiscono all'estrazione di caratteristiche sia nel dominio temporale che in quello

spaziale.

Tuttavia, va tenuto presente che questi rappresentano solo alcuni dei layer comuni presenti nelle reti neurali convoluzionali. A seconda della configurazione specifica dell'architettura della CNN, potrebbero esserci altri layer specializzati o varianti di questi layer di base.

Ad esempio, Hsu *et al.*,2023 [38] e Song *et al.*,2022 [42] utilizzano reti CNN dotate di *attention layer*. Quello che differenzia una rete convoluzionale semplice da una dotata di uno o più *attention layer* [61] è il ruolo cruciale svolto da questi ultimi nell'estrazione delle caratteristiche. Si parte dal presupposto che le reti neurali, composte da strati interconnessi, riflettano la struttura del cervello umano, in cui i neuroni sono collegati tramite sinapsi. Fondate su questo concetto fondamentale, le reti neurali dotate di *attention layer* imitano il modo in cui i sistemi biologici umani concentrano l'attenzione su parti specifiche quando elaborano un flusso di informazioni considerevole. Di conseguenza, l'obiettivo di una rete neurale convoluzionale che possiede *attention layer* è focalizzare e dare maggiore enfasi a determinate regioni del segnale.

Infine, tra le reti neurali convoluzionali esaminate negli studi inclusi nella metanalisi, ci sono quelle che adottano una struttura di rete specifica chiamata EEGNet, altamente specializzata per l'analisi dei segnali EEG. Questo tipo di rete [62] presenta una struttura ottimizzata per catturare le caratteristiche uniche dei segnali EEG, come la bassa frequenza e l'alta variabilità tra soggetti diversi. Inoltre, la dimensione del kernel e lo stride (passo di avanzamento) possono essere configurati in modo diverso rispetto alle CNN tradizionali per catturare meglio le caratteristiche temporali e spaziali dei segnali EEG.

Altri metodi

Lee *et al.*,2022 [21] operano l'estrazione delle caratteristiche utilizzando due tecniche distinte (Figura 2.19): *Common Feature Extractor* e *Class-Specific Feature Extractor*.

Il Common Feature Extractor è costituito da un generatore basato su layer convoluzionali e un discriminatore. Il generatore genera caratteristiche attraverso filtri convoluzionali 2D e average pooling layer. Il risultato finale sono caratteristiche 1D, e il compito del discriminatore è distinguere se le caratteristiche sono false o meno. Il discriminatore è progettato utilizzando layer di regressione lineare e la funzione di attivazione ELU. Per l'apprendimento avversario, vengono assegnate etichette "vero" e "falso" ai segnali EEG e al rumore casuale artificialmente creato, rispettivamente. Quindi, il generatore utilizza segnali EEG per l'addestramento indipendentemente

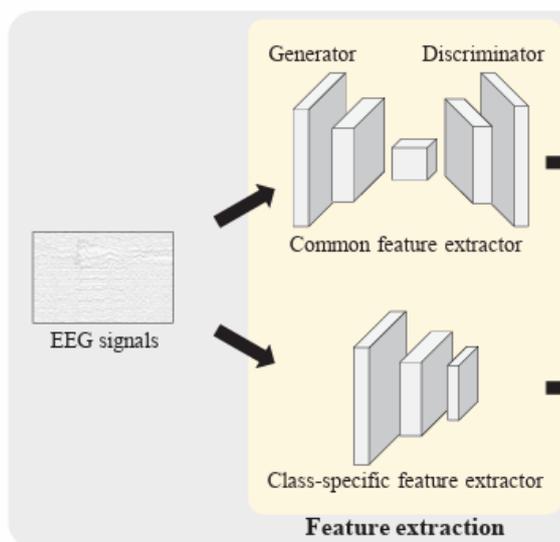


Figura 2.19: Common Feature Extractor e Class-Specific Feature Extractor [21]

dalla classe. Con il progredire dell'addestramento, il generatore estrae le caratteristiche comuni dei segnali EEG nel dataset di addestramento. Di conseguenza, il generatore impara a concentrarsi sulle caratteristiche dei segnali EEG, riducendo l'effetto del rumore sull'estrazione delle caratteristiche.

Il Class-Specific Feature Extractor, contrariamente, è progettato per estrarre le caratteristiche al fine della classificazione. Esso presenta una struttura identica a quella del generatore della tecnica precedente. Le etichette vengono utilizzate per l'addestramento, e i pesi vengono aggiornati in base ai gradienti generati dagli errori di classificazione. Gli output sono caratteristiche 1D che hanno la stessa dimensione delle caratteristiche estratte dal Common Feature Extractor.

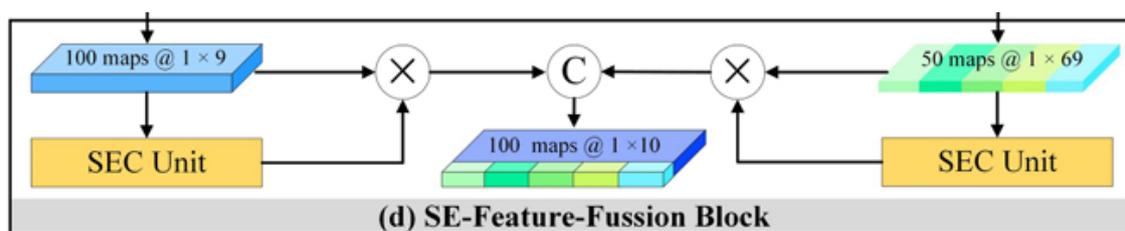


Figura 2.20: Squeeze-and-Excitation Feature Fusion Block [29]

Li *et al.*, 2021 [29] utilizzano due tecniche di estrazione delle caratteristiche usate comunemente, che agiscono sia nel dominio temporale che nel dominio spaziale. Tuttavia, l'innovazione di questa tecnica risiede nel blocco immediatamente successivo a quello dedicato alla Feature Extraction. Per ridurre la ridondanza e rimuovere le feature non rilevanti per l'analisi, viene introdotto un blocco chiamato "*Squeeze-and-Excitation Feature Fusion*" (Figura 2.20), il cui scopo è enfatizzare le feature

più discriminative.

In particolare, per utilizzare le informazioni sulle dipendenze dei canali, l'operazione di "squeeze" esegue prima il pooling medio globale sulle feature map di input per comprimere le informazioni, in modo da generare caratteristiche statistiche per canale. Successivamente, l'operazione di "excitation" associa un vettore di pesi per attribuire più o meno importanza alle feature estratte per ciascun canale.

Phadikar *et al.*,2023 [32] utilizzano un metodo innovativo (Figura 2.21) per effettuare Feature Extraction.

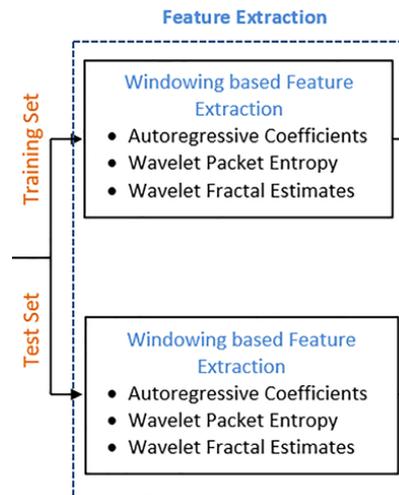


Figura 2.21: Phadikar *et al.*,2022 [32] Feature Extraction

dove

- **Autoregressive (AR) coefficients:** il modello autoregressivo viene utilizzato per caratterizzare processi tempo-varianti. Si tratta di un metodo parametrico per stimare la densità spettrale di potenza del segnale EEG.
- **Wavelet packet entropy:** le trasformate wavelet sono adoperate nell'estrazione delle caratteristiche per acquisire le feature locali del segnale EEG. Tuttavia, il loro impiego risulta difficile a causa della loro considerevole lunghezza. Di conseguenza, questo approccio considera l'entropia di Shannon come mezzo per catturare l'incertezza di un sistema specifico, utilizzandola come feature per il classificatore.
- **Wavelet fractal estimates:** vengono stimati due parametri frattali dai coefficienti DWT e impiegati come feature.

2.8 Classificazione

Per quanto riguarda le tecniche di classificazione impiegate nei 22 articoli analizzati nella presente metanalisi, alcune appartengono a macro-categorie già note, come le reti CNN, mentre altre sono del tutto innovative. Queste ultime sono dettagliatamente illustrate nel corso della metanalisi.

Così come avviene per l'estrazione delle caratteristiche, anche la fase di classificazione è suddivisa in task binari e multi-classe. Ciò consente di mostrare al lettore due pipeline distinte per l'analisi del segnale EEG, mirando a ottenere una BCI ottimizzata sia per i task binari che per quelli multi-classe. Nelle Tabelle 2.9, 2.10 sono elencate nel dettaglio le tecniche di classificazione utilizzate.

| TASK BINARIO | | | |
|---------------------|------------------------|-----------|--|
| ID | Classificazione | ID | Classificazione |
| 2[22] | EEGNet | 14[34] | CNN |
| 4[24] | CNN | 15[35] | Target CNN fine tuned |
| 7[27] | CNN | 17[37] | Stacked sparse autoencoder + Softmax layer |
| 8[28] | CNN (AlexNet) | 21[41] | k-Nearest Neighbor (k-NN), C4.5 Decision Tree, REP Tree, Support Vector Machine (SVM), Random Tree (RT) and RF |

Tabella 2.9: Classificazione task binario

| TASK MULTI-CLASSE | | | |
|--------------------------|---|-----------|---|
| ID | Classificazione | ID | Classificazione |
| 1[21] | Multi Layer Perceptron | 12[32] | SVM |
| 3[23] | TSGL-EEGNet | 13[33] | LDA Classifier |
| 5[25] | Ensemble Support Vector Learning Classifier | 16[36] | EEGNet |
| 6[26] | LDA Classifier | 18[38] | CNN |
| 9[29] | CNN | 19[39] | EEGNet Fusion V2 |
| 10[30] | CNN | 20[40] | Overlapping filter bank CNN |
| 11[31] | CNN | 22[42] | Classifier Module: two fully connected layers |

Tabella 2.10: Classificazione task multi-classe

Precedentemente, è stato suggerito di distinguere le tecniche di classificazione in DL e ML, risultando in 15 studi che adottano tecniche di DL e i rimanenti 7 che adoperano tecniche di ML. Tuttavia, all'interno di questa categorizzazione, è possibile effettuare un'ulteriore suddivisione per analizzare più approfonditamente i 15 articoli che adottano tecniche di DL.

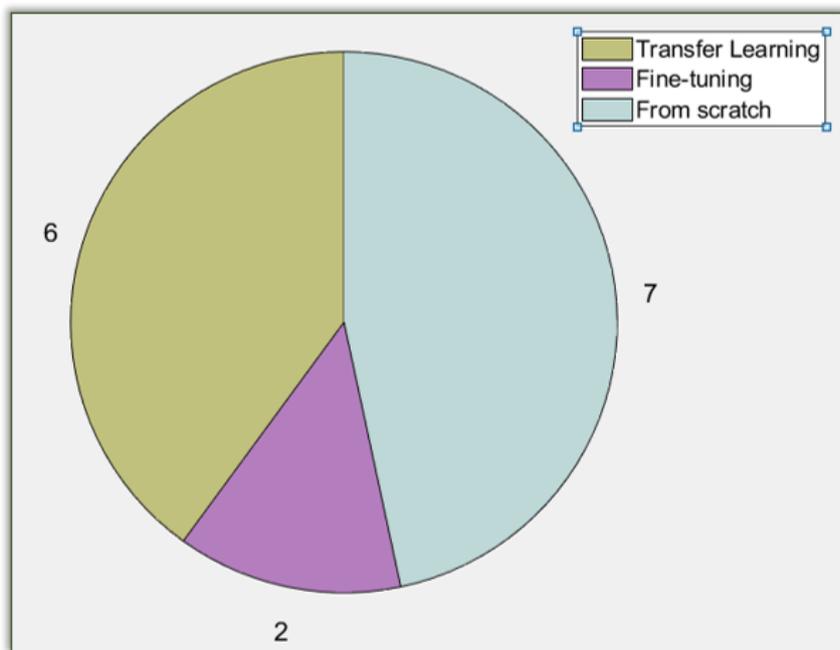


Figura 2.22: Distribuzione DL

In particolare, è opportuno esaminare le tecniche implementate da zero (from scratch), quelle basate sul transfer learning e quelle che eseguono un fine-tuning dei parametri. Il grafico mostrato nella Figura 2.22 rappresenta la distribuzione dei 15 articoli in base all'appartenenza a una delle tre categorie elencate precedentemente.

Di seguito sono riportate le caratteristiche di un algoritmo basato su transfer learning, di uno che si basa sul fine tuning dei parametri e di un altro ancora ideato da zero (from scratch):

- *Transfer Learning* [63]: si basa su un modello pre-addestrato su un compito affine a quello richiesto dalla rete in uso. I pesi e i parametri vengono trasferiti e adattati per il nuovo compito. Questo approccio si dimostra vantaggioso quando si desidera ridurre il tempo e le risorse computazionali richieste per l'addestramento.
- *From scratch*: il modello viene creato completamente ex novo, senza fare affidamento su reti preesistenti e già addestrate. Richiede un vasto insieme di dati e risorse computazionali significative.

- *Fine tuning* [64]: utilizza un modello pre-addestrato come punto di partenza e adatta con precisione i suoi parametri a un nuovo dataset. È estremamente sensibile alla selezione dei parametri.

Successivamente, sono illustrate e descritte le tecniche utilizzate, sia in termini generali per le macro-categorie di appartenenza, sia in dettaglio per le tecniche di classificazione più innovative. La Tabella 2.11 mostra le tecniche utilizzate e fornisce una percentuale del loro impiego all'interno della metanalisi.

| Classificazione | Numero di pubblicazioni | Percentuale |
|------------------------------|-------------------------|-------------|
| Multi Layer Perceptron | 1 | 4.5% |
| Linear Discriminant Analysis | 2 | 9.1% |
| Support Vector Machine | 2 | 9.1% |
| Reti neurali convoluzionali | 14 | 63.7% |
| Altri metodi | 3 | 13.6% |

Tabella 2.11: Tecniche di classificazione

Multi Layer Perceptron

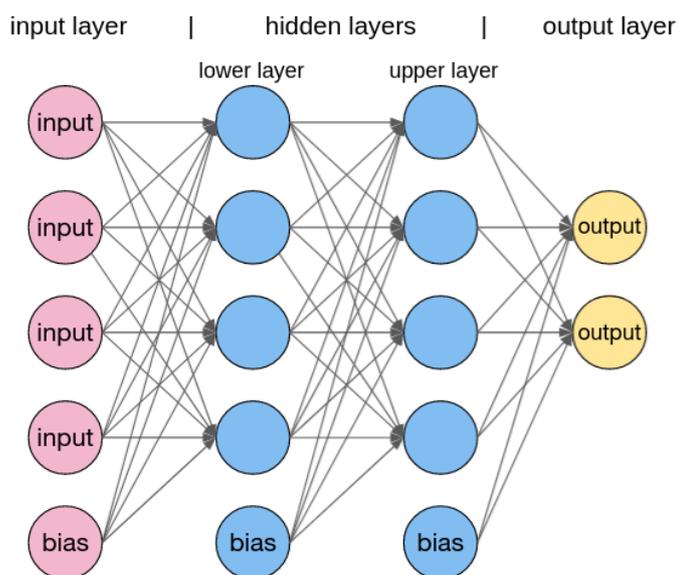


Figura 2.23: Multi Layer Perceptron [65]

Ai fini della classificazione delle feature, Lee *et al.*,2022 [21] utilizzano il classificatore Multi Layer Perceptron (MLP). Esso è composto da tre tipi di layer (Figura 2.23): l'input layer, l'output layer e gli hidden layer. L'input layer riceve il segnale di input da elaborare. Il compito richiesto, come la previsione e la classificazione, viene eseguito dall'output layer. Un numero arbitrario di hidden layer posizionati tra l'input layer e l'output layer costituisce il vero motore computazionale del MLP. Esso si presenta simile ad una rete feed forward, in quanto i dati fluiscono in avanti dall'input allo strato di output. I neuroni nel MLP vengono addestrati con l'algoritmo di apprendimento back propagation [66].

Linear Discriminant Analysis

Gaur *et al.*,2021 [26] e Ayoobi *et al.*,2022 [33] utilizzano il classificatore Linear Discriminant Analysis (LDA). La caratteristica distintiva di questo classificatore è la sua capacità di ridurre la dimensionalità mentre preserva le informazioni più discriminanti tra le classi. Inizialmente, l'obiettivo è selezionare la combinazione ottimale di caratteristiche per migliorare la discriminazione.

Per esempio, considerando un task binario con classi x_1 e x_2 , la classificazione coinvolge campioni n -dimensionali $x = x_1, x_2, x_3, \dots, x_n$, in cui n_1 appartiene alla classe w_1 e n_2 appartiene alla classe w_2 . L'obiettivo è individuare la retta $y = w^t x$ che massimizza la separazione tra le due classi all'interno di un insieme di possibili rette (vedi Figura 2.24).

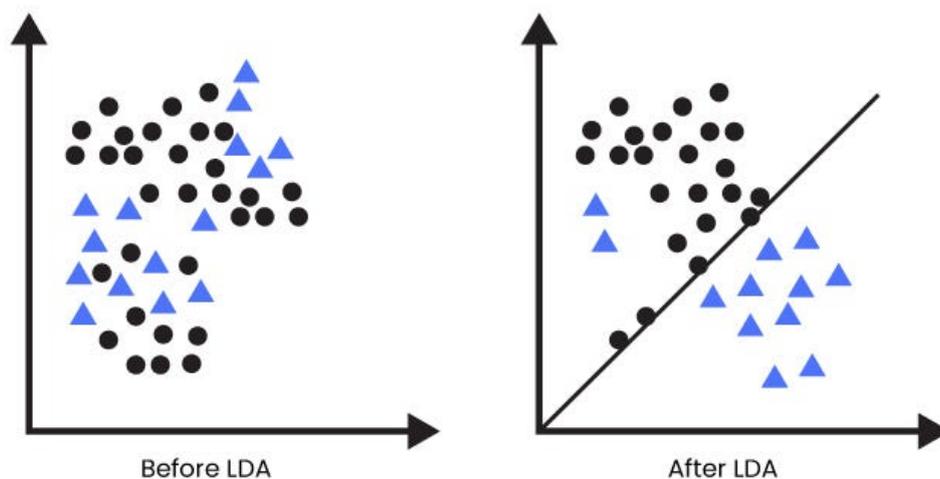


Figura 2.24: Linear Discriminant Analysis [67]

Support Vector Machine

Luo *et al.*,2020 [25] e Phadikar *et al.*,2023 [32] utilizzano il classificatore Support Vector Machine (SVM). Si tratta di un algoritmo di machine learning basato su apprendimento supervisionato molto utilizzato per compiti di classificazione binaria. Il classificatore SVM cerca di trovare l'iperpiano ottimale in grado di dividere due o più classi:

$$f(x) = x'\beta + b = 0 \quad (2.6)$$

dove x' è la trasposta delle feature di input e β e b sono i parametri dell'iperpiano. Questo iperpiano ottimale (Figura 2.25) dovrebbe massimizzare il margine tra le due classi o più classi di dati.

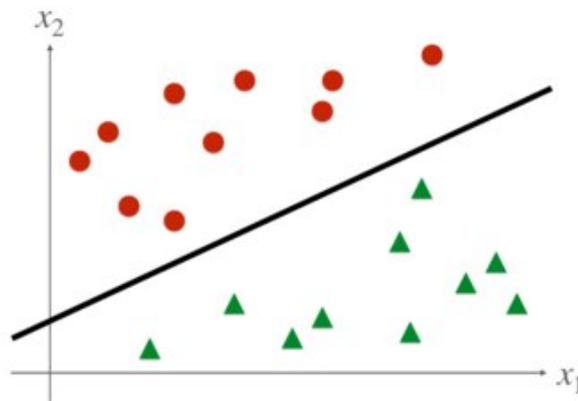


Figura 2.25: Support Vector Machine [68]

Reti Neurali Convoluzionali

Nel capitolo dedicato alla Feature Extraction 2.7, sono state esaminate approfonditamente le reti neurali convoluzionali (CNN) e il loro ruolo fondamentale nell'estrarre caratteristiche rilevanti grazie alla loro notevole versatilità. Sono stati analizzati gli strati che compongono una CNN e si è evidenziato il contributo significativo degli strati più profondi nel processo di estrazione delle caratteristiche.

Per quanto riguarda la classificazione, le reti CNN si dimostrano eccellenti classificatori, principalmente grazie alla presenza di uno o più strati "fully connected" posizionati all'uscita della rete. Questi strati, attivati dalla funzione "softmax", hanno il compito di fornire un vettore di probabilità che indica l'appartenenza alle varie classi coinvolte nello studio in esame (Figura 2.26).

Quattordici dei ventidue studi utilizzano le reti CNN per classificare il MI task. Si tratta di una percentuale considerevole che riflette il progresso del deep learning nell'aprire nuove strade per affrontare una vasta gamma di compiti nell'intelligenza artificiale.

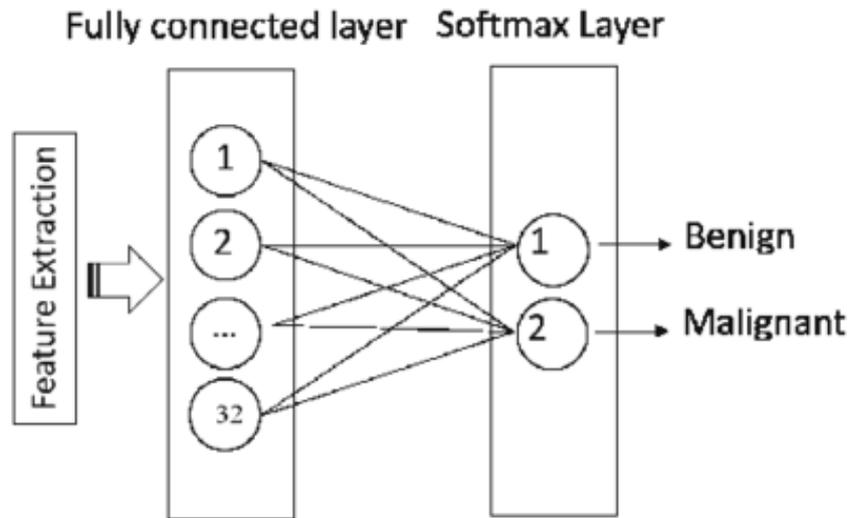


Figura 2.26: Fully Connected Layer [69]

Altri metodi

Duan et al. (2020) [31] adottano una metodologia innovativa per la classificazione delle caratteristiche: il *Zero-Shot Learning*. Il loro approccio si basa sull'assunto che un classificatore standard non possa prevedere una classe per la quale non esistano esempi nel training set. A questo scopo, Duan introduce una variabile binaria B che indica se un vettore di feature appartiene a una classe conosciuta o sconosciuta dopo l'applicazione di una soglia T . Questo metodo risulta efficace anche nel trattamento dei campioni "outlier", nonostante richieda una considerevole potenza computazionale.

Attraverso l'individuazione degli outlier e l'applicazione di una specifica soglia, è possibile determinare se i dati di test appartengono a una classe conosciuta o meno. Nel caso in cui i dati del test set siano considerati appartenenti a una classe conosciuta, viene impiegato un classificatore *softmax*.

Yang et al., 2020 [37] hanno adottato lo *stacked autoencoder* (SAE) come parte del processo di classificazione. Questa architettura rappresenta una rete profonda gerarchica che non solo estrae feature robuste e latenti, ma le classifica anche. Ciò che rende innovativa questa tecnica è l'unione di più autoencoder per formare lo *stacked sparse autoencoder* (SSAE). L'incorporazione degli hidden layer permette alla rete di catturare informazioni dai dati di input attraverso ogni autoencoder collegato in serie l'uno con l'altro. Alla fine della sequenza di autoencoder, si ottiene un'informazione consolidata che viene elaborata attraverso un classificatore *softmax* (Figura 2.27).

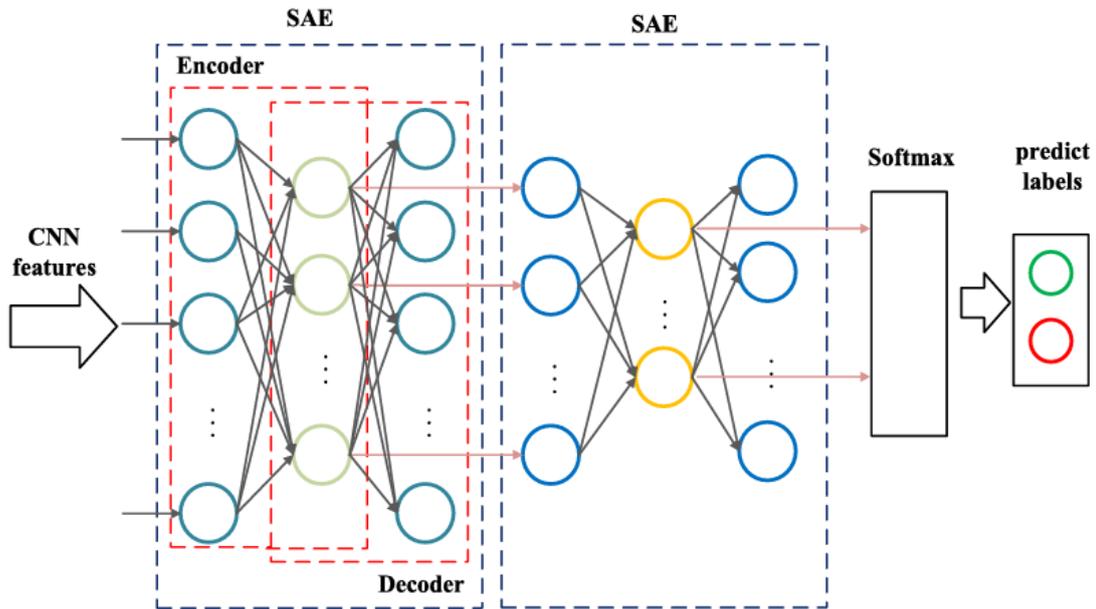


Figura 2.27: Stacked Sparse Autoencoder [37]

Tecniche di Machine Learning

Subasi *et al.*, 2021 [41] utilizzano una varietà di tecniche di ML per la classificazione, e alla fine le integrano insieme attraverso l'approccio *ensemble* (Figura 2.28). L'*ensemble* rappresenta una strategia che unisce le previsioni provenienti da diversi modelli al fine di migliorare complessivamente l'accuratezza delle predizioni. Questo approccio si basa sull'idea che combinando le previsioni di vari modelli, ciascuno con le proprie peculiarità e limitazioni, si possa ottenere una previsione più precisa rispetto a quella offerta da un singolo modello.

Gli algoritmi di classificazione da loro impiegati sono:

1. **k-Nearest Neighbor (k-NN)**: Il k-NN è un metodo di classificazione di tipo supervisionato molto semplice che si basa sul concetto di "vicinato". Si tratta di un algoritmo che classifica un nuovo elemento sulla base degli elementi del training set che fanno parte del suo vicinato. Si ha un insieme di elementi a cui è associata la classe e una misura di similarità per capire quanto sono vicini due elementi, in particolare quanto vicino è un elemento da classificare agli elementi del training set [70].
2. **C4.5 Decision Tree**: Il C4.5 è un algoritmo per la costruzione di alberi decisionali. Funziona selezionando l'attributo che meglio separa i dati di addestramento, dividendo i dati in base ai valori dell'attributo scelto e ripetendo il processo in modo ricorsivo. Dopo la costruzione, l'albero può essere potato per migliorare la generalizzazione. Infine, l'albero viene valutato usando un insieme

di dati di convalida per assicurare la sua capacità di predizione su nuovi dati [71].

3. **REP Tree:** Il REP Tree è un algoritmo per la costruzione di alberi decisionali che punta a ridurre l'errore di classificazione. Costruisce l'albero iniziale utilizzando suddivisioni ricorsive dei dati di addestramento e poi esegue una *potatura* iterativa per rimuovere nodi non significativi. Valuta l'errore di classificazione durante la *potatura* e ripete il processo fino a soddisfare i criteri di arresto [70].
4. **SVM:** menzionato sopra 2.8.
5. **Random Tree (RT):** Il RT è un algoritmo che utilizza un singolo albero decisionale costruito in modo casuale. Durante la creazione del singolo albero viene selezionato casualmente un sottoinsieme delle feature (variabili) disponibili. Esso può essere utilizzato per fare previsioni su nuovi dati, seguendo i percorsi decisionali dall'inizio alla fine dell'albero. Questo approccio riduce l'overfitting e migliora la robustezza del modello rispetto al rumore nei dati [70].
6. **Random Forest (RF):** RF è un algoritmo che unisce diversi alberi decisionali casuali. Durante il processo, crea numerosi alberi decisionali utilizzando un campionamento casuale dei dati di addestramento e delle caratteristiche disponibili. Le previsioni di ciascun albero vengono poi combinate attraverso votazione per la classificazione o media per la regressione [70].

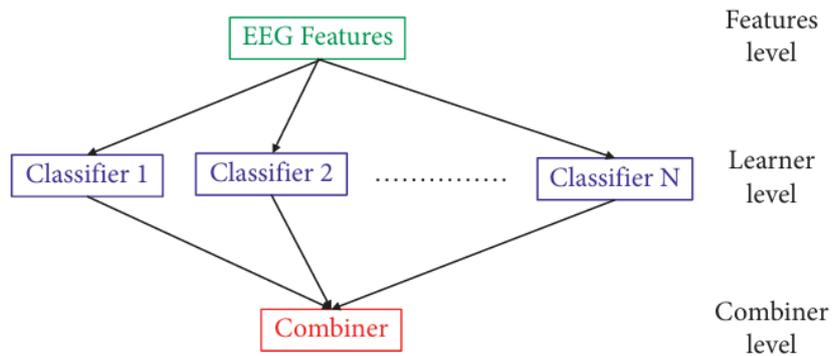


Figura 2.28: Ensemble-based approach [41]

Capitolo 3

Risultati

Alla conclusione dell'analisi delle tecniche di elaborazione del segnale EEG, che comprendono il pre-processing, la data augmentation, l'estrazione delle caratteristiche e la classificazione, l'obiettivo è presentare al lettore due pipeline separate per ottimizzare una BCI basata su un compito di immaginazione motoria sia binario che multi-classe.

Le performance di classificazione vengono valutate considerando l'accuratezza media di classificazione ottenuta sui dataset presi in esame da ciascuno dei 22 studi.

L'accuratezza è una misura parametrica che indica quante volte il modello di classificazione ha correttamente classificato un item all'interno del dataset rispetto al totale. Essa viene calcolata come:

$$acc = \frac{VP + VN}{VP + FP + VN + FN} \quad (3.1)$$

dove VP sono i Veri Positivi che rappresentano i casi in cui il modello classifica correttamente un'istanza come positiva, VN sono i Veri Negativi che rappresentano i casi in cui il modello classifica correttamente un'istanza come negativa, FP sono i Falsi positivi che rappresentano i casi in cui il modello classifica erroneamente un'istanza come positiva quando in realtà è negativa, FN sono i Fasi Negativi che rappresentano i casi in cui il modello classifica erroneamente un'istanza come negativa quando in realtà è positiva.

Attraverso la matrice di confusione in Figura 3.1 è possibile visualizzare il grado di errore o meglio di "confusione" del modello di classificazione.

In seguito, l'analisi eseguita viene elaborata utilizzando una metodologia condivisa sia per il task binario che per quello multi-classe, al fine di individuare le operazioni di processing del segnale EEG richieste.

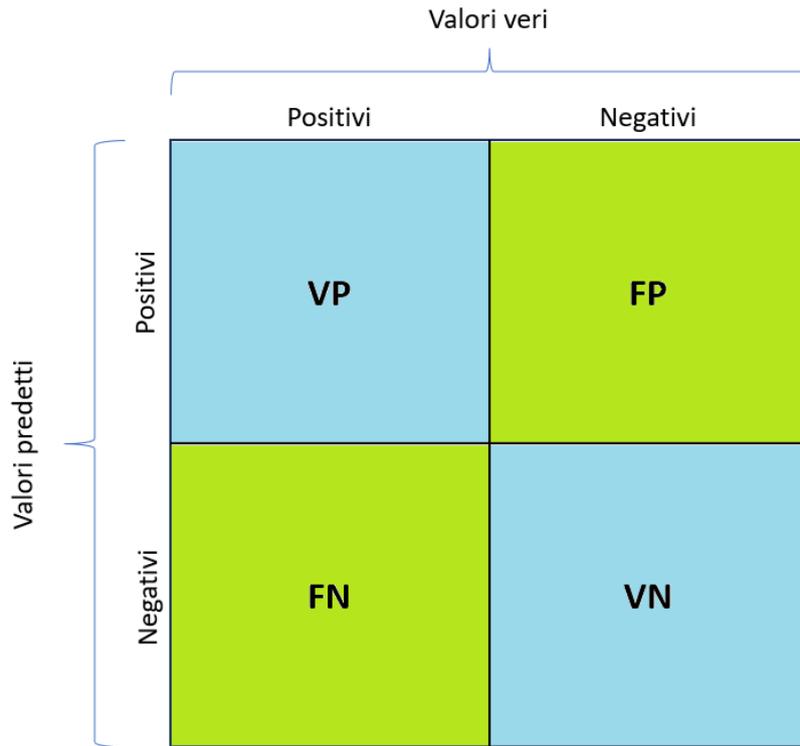


Figura 3.1: Matrice di confusione

3.1 Task binario

Nella Figura 3.2 sono rappresentati i risultati ottenuti da 8 studi relativi a un task binario di immaginazione motoria (mano destra/mano sinistra), espressi in termini di accuratezza.

È essenziale precisare che, per generare il grafico a torta, l'accuratezza degli studi che valutano il modello su più dataset viene calcolata come la media dell'accuratezza dei singoli dataset utilizzati nello studio.

Nella Tabella A.1 dell'Appendice A, vengono presentati i risultati in termini di accuratezza ottenuti per ciascuno degli 8 studi che riguardano un task binario. Per ogni studio sono riportate eventuali tecniche di data augmentation se presenti più le metodologie di feature extraction e classificazione utilizzate. Inoltre, vengono fornite informazioni sul numero di dataset impiegati da ciascuno studio e sul numero di soggetti considerati in ciascuno di essi.

Per identificare quali e quanti metodi includere per la creazione di una pipeline comune nell'elaborazione di un task di immaginazione motoria binaria, sono stati valutati parametri oggettivi come il numero di soggetti esaminati in ciascuno studio e l'accuratezza raggiunta.

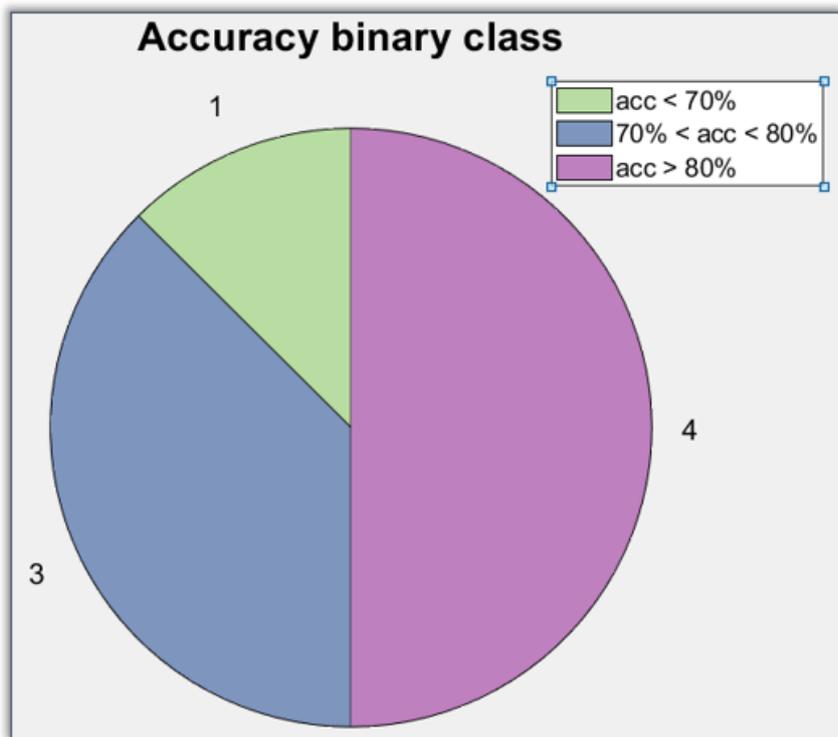


Figura 3.2: Accuratezza task binario

Non è stata effettuata una selezione basata sulle tecniche metodologiche stesse; al contrario, tutte sono state considerate allo stesso modo valide, in quanto trovano riscontri di validità nella letteratura scientifica.

Ad eccezione della fase di pre-processing dei dati e della loro organizzazione, per la quale è stata adottata una procedura comune sia per il task binario che per quello multi-classe, come specificato nel capitolo dedicato al pre-processing (vedi Sezione 2.5), le restanti fasi di elaborazione dei segnali EEG fino alla fase di classificazione vengono selezionate in base ai due parametri oggettivi precedentemente identificati.

Per identificare le metodologie di elaborazione del segnale EEG estratte dagli articoli che trattano un task binario, è stata seguita la seguente procedura:

- Si sono considerati solo gli studi che hanno ottenuto un'accuratezza superiore all'80%.
- Si è effettuato un controllo sulla numerosità dei dataset e un confronto tra il numero di soggetti considerati nello studio e l'accuratezza ottenuta.
- Gli articoli che utilizzano dataset di piccole dimensioni, composti da meno di 54 soggetti, sono stati scartati.

Si è giunti a una situazione che è stata rappresentata graficamente nella Tabella A.2. Gli studi con un'accuratezza superiore all'80% sono evidenziati in **rosa**. Tra questi, sono stati esclusi [28] e [37] in quanto considerano dataset composti da 5 e 7 soggetti, rispettivamente. L'elevata accuratezza ottenuta da questi due studi (99.35% e 86.40%), considerando la limitata numerosità dei dataset su cui sono stati testati, potrebbe essere poco precisa e il modello potrebbe non essere generalizzabile per dataset più ampi.

Date le considerazioni oggettive fatte, si è ora in grado di determinare le tecniche di elaborazione da adottare in ciascuna fase al fine di ottenere un'accuratezza soddisfacente e, di conseguenza, ottimizzare una BCI.

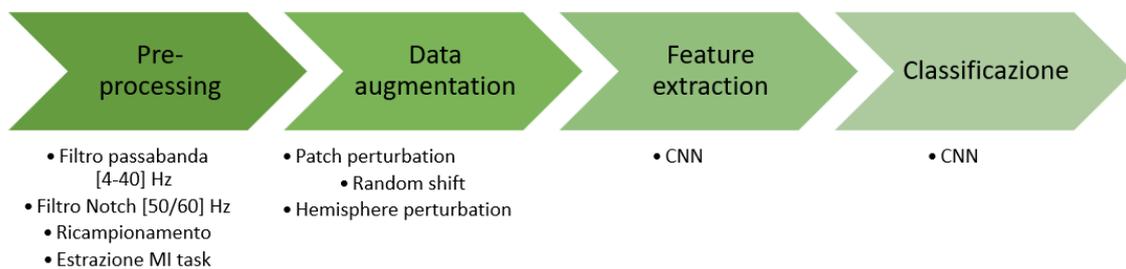


Figura 3.3: Pipeline MI task binario

Nella Figura 3.3 sono elencati i passi da seguire per una corretta classificazione dei segnali EEG nel caso di acquisizione durante un movimento immaginario di tipo binario.

Nel caso del task binario, dopo aver escluso gli studi con un numero limitato di soggetti e quelli che non hanno raggiunto un'accuratezza sufficientemente elevata, l'analisi finale è stata condotta sui lavori di Zhang *et al.*, 2021 [27] e Perez *et al.*, 2022 [34]. Entrambi gli studi utilizzano il medesimo dataset, OpenBMI, composto da 54 soggetti, consentendo un confronto diretto in termini di accuratezza. L'accuratezza riportata da Zhang [27] è leggermente superiore dello 0.89% quando testata sul dataset OpenBMI. Tuttavia, tale variazione percentuale risulta trascurabile, considerando che Perez [34] ha testato il proprio algoritmo su 5 dataset distinti, per un totale di 280 soggetti. Di conseguenza, lo studio di Perez risulta essere più robusto se comparato al primo. Poiché entrambi gli studi hanno impiegato reti CNN sia nella fase di Feature Extraction che nella fase di Classificazione, non vi sono dubbi su quale approccio utilizzare per tali fasi. La differenza principale riguarda l'utilizzo o meno di tecniche di Data Augmentation.

Poiché alla conclusione di questa metanalisi viene offerta al lettore una proposta di approfondimento sull'utilizzo delle tecniche di Data Augmentation per migliorare le

prestazioni di classificazione delle reti BCI nel riconoscimento di un task di movimento immaginario, si è scelto di integrare, nella pipeline relativa al task binario di immaginazione motoria, le tecniche di Data Augmentation adoperate da Perez [34].

3.2 Task multi-classe

Per quanto riguarda la definizione della pipeline da seguire nell'elaborazione del segnale EEG contenente informazioni relative a un task di immaginazione motoria di tipo multi-classe, la selezione dei parametri oggettivi è stata analoga a quella del caso binario.

In particolare, la scelta delle tecniche che assicurano le prestazioni più elevate è determinata attraverso un controllo incrociato tra la numerosità dei dataset utilizzati per il test degli algoritmi e l'accuratezza percentuale ottenuta da essi.

Le Tabelle A.3 e A.4 presentano un elenco di tutte le tecniche di elaborazione del segnale EEG impiegate nei 15 studi che analizzano i task di immaginazione motoria multi-classe.

Successivamente, la selezione degli studi è stata orientata verso quelli che soddisfano i seguenti criteri:

- Si sono considerati solo gli studi che hanno ottenuto un'accuratezza superiore all'80%.
- Si è effettuato un controllo sulla numerosità dei dataset e un confronto tra il numero di soggetti considerati nello studio e l'accuratezza ottenuta.
- Gli articoli che utilizzano dataset di piccole dimensioni, composti da meno di 3 soggetti, sono stati scartati.

Le Tabelle A.5 e A.6 riportano evidenziati in **rosa** gli studi che raggiungono un'accuratezza superiore all'80%. Viene subito scartato lo studio condotto da Phadikar *et al.*, 2023 [32] in quanto testato unicamente su 3 pazienti, potrebbe non essere generalizzabile su un campione più ampio di soggetti.

Per quanto riguarda la selezione della migliore metodologia sia per la Feature Extraction che per la Classificazione, si sono considerate complessivamente le tecniche più comunemente utilizzate nei 6 studi rimanenti ([23], [25], [26], [31], [33], [38]).

In particolare:

- **Feature Extraction:** 5 studi su 6 utilizzano l'algoritmo Common Spatial Pattern (CSP) o la sua variante Filter Bank CSP.

- **Classificazione:** 2 studi utilizzano l'algoritmo Linear Discriminant Analysis (LDA), 3 studi utilizzano le reti CNN per una classificazione lineare tramite i fully connected layer attivati dalla funzione softmax, 1 studio utilizza l'algoritmo Support Vector Machine (SVM).

Per quanto riguarda l'estrazione delle caratteristiche, non vi è stata alcuna incertezza sulla tecnica da impiegare nel caso di task multi-classe. Tuttavia, la scelta dell'algoritmo di classificazione non è stata altrettanto evidente.

Si è quindi proceduto con un'ultima valutazione delle informazioni reperibili nella letteratura scientifica riguardo alla complessità in termini di costi e tempi computazionali per l'applicazione di tali algoritmi.

| | |
|------------|--|
| LDA | moderati tempi e costi computazionali ma dipendenti dalla numerosità dei dataset e dal numero di feature da classificare |
| CNN | tempo computazionale elevato per l'addestramento della rete soprattutto se profonda |
| SVM | tempi e costi computazionali onerosi, specialmente quando vengono utilizzati kernel complessi e dataset ampi. Se usato in modalità <i>ensemble</i> i costi aumentano ulteriormente |

Tabella 3.1: Criticità degli algoritmi di classificazione per un task multi-classe

Dopo aver esaminato le criticità computazionali associate all'uso di tali algoritmi, si procede con la definizione della pipeline da seguire per l'elaborazione del task multi-classe di immaginazione motoria al fine di ottimizzare una BCI.

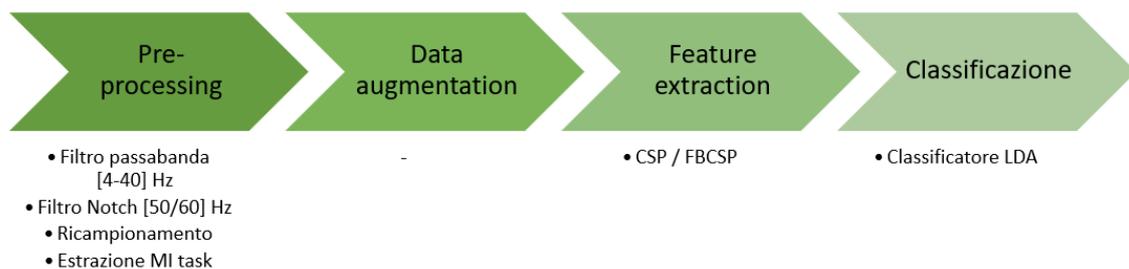


Figura 3.4: Pipeline MI task multi-classe

La Figura 3.4 illustra i passaggi necessari per raggiungere gli obiettivi della presente analisi nel contesto del task multi-classe.

Fin dall'inizio, c'è stata una chiara inclinazione verso l'impiego del CSP e della sua variante (FBCSP) per l'estrazione delle caratteristiche, mentre la selezione della tecnica di classificazione non è stata altrettanto immediata. È stato necessario valutare

i costi e i tempi computazionali associati a ciascuna delle tre tecniche considerate per la classificazione. Solo dopo un'attenta analisi computazionale è stata presa la decisione di adottare l'approccio LDA per la classificazione. Il classificatore LDA è noto per essere una metodologia semplice, efficiente e accurata per affrontare problemi di classificazione multi-classe.

La precisione dell'approccio LDA si avvicina a quella di altri metodi come il SVM, ma richiede notevolmente meno tempo per l'elaborazione, come dimostrato da studi precedenti [72].

Capitolo 4

Conclusioni

Alla conclusione di questa metanalisi, dopo aver esaminato attentamente i 22 articoli inclusi, sono state identificate le migliori tecniche di elaborazione del segnale EEG per ottimizzare una BCI nel contesto del compito di immaginazione motoria (sia per un caso binario che multi-classe).

Nello specifico, si è optato per l'adozione di un approccio uniforme per la fase di pre-processing dei segnali, poiché in questa fase i segnali risultano essere confrontabili (entrambi affetti da rumore e con un basso rapporto segnale-rumore), indipendentemente dal loro contenuto informativo.

Di conseguenza, si è privilegiato un pre-processing lineare che include l'applicazione di un filtro passa-banda con frequenze di taglio comprese tra 4 e 40 Hz per focalizzare le bande di frequenza più informative per un MI task (ritmo sensorimotorio), l'uso di un filtro Notch con frequenza di taglio di 50/60 Hz per eliminare le interferenze di rete, il ricampionamento quando si desidera unificare più dataset diversi in uno studio unico, e infine l'estrazione delle porzioni relative esclusivamente al MI task per ottimizzare tempi e costi computazionali.

Per quanto riguarda gli step successivi, ci si trova di fronte a una divisione in cui da un lato si affronta la classificazione di un task binario e dall'altro si delineano le tecniche di elaborazione da impiegare per la classificazione di un task multi-classe (Tabella 4.1).

| | Task binario | Task multi-classe |
|--------------------|---|-------------------|
| Data Augmentation | <ul style="list-style-type: none"> • Patch Perturbation • Random Shift • Hemisphere Perturbation | |
| Feature Extraction | CNN | CSP / FBCSP |
| Classificazione | CNN | LDA |

Tabella 4.1: Risultati

Nel dettaglio, si registra un'accuratezza dell'83.33% per un task binario e dell'81.37% per un task multi-classe.

4.1 Limitazioni e Sviluppi futuri

Le limitazioni di questa analisi derivano dalla complessità del task richiesto durante l'acquisizione del segnale. A volte, i soggetti trovano difficile concentrarsi sul compito richiesto e eseguire il movimento immaginario secondo le modalità e i tempi prescritti. Anche ipotizzando che l'acquisizione dei segnali vada a buon fine e che il soggetto esegua perfettamente il compito, l'alta variabilità del segnale EEG potrebbe influenzare i risultati e la loro interpretazione.

Potrebbe essere vantaggioso considerare l'acquisizione di un tipo diverso di segnale, come il Functional Near-InfraRed Spectroscopy (fNIRS). Il segnale fNIRS offre un compromesso unico tra risoluzione temporale e spaziale ed è immune dalla maggior parte degli artefatti, come l'attività muscolare e i battiti delle palpebre. Inoltre, può essere agevolmente integrato con altre tecniche di misurazione come i segnali fisiologici, l'EEG e la neurostimolazione [73].

Considerando i costi computazionali associati all'utilizzo di entrambe le tecniche di acquisizione, fNIRS e EEG, potrebbe essere vantaggioso sfruttare entrambe per sviluppare una BCI altamente ottimizzata.

Si consiglia, inoltre, al lettore di approfondire le tecniche di Data Augmentation e il loro utilizzo in compiti di questo tipo, poiché si ritiene che possano garantire risultati ottimali in termini di prestazioni e generalizzazione dei modelli.

L'obiettivo è contrastare gli aspetti negativi associati alla teoria sulla Data Augmentation e sfruttare esclusivamente i suoi vantaggi. Non esistono prove scientifiche

che confermino l'idea che l'aumento artificiale dei dati possa compromettere l'affidabilità dei risultati.

Analizzando in modo critico i risultati ottenuti attraverso tecniche che confrontano l'utilizzo della Data Augmentation con la sua assenza, e monitorando la ricerca nel campo della Data Augmentation per individuare nuove tecniche o approcci che possano mitigare o eliminare gli svantaggi associati, si prospetta un futuro in cui le BCI saranno altamente ottimizzate e accessibili a tutti.

Inoltre, si consiglia di acquisire i dati tramite trial clinici direttamente da soggetti che potrebbero beneficiare in futuro di queste tecnologie, per favorire lo sviluppo delle BCI soprattutto nel settore dell'ingegneria riabilitativa.

Appendice A

Appendice

Nelle pagine seguenti saranno mostrate le tabelle a cui si fa riferimento nel presente documento.

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|----------------|--|---|---|--|---|
| 2[22] 4[24] | Ma: 25 soggetti BNCI Horizon 2020: 14 soggetti | - - | EEGNet CSP | EEGNet CNN | 78.90% 79.00% |
| 7[27] 8[28] | OpenBMI: 54 soggetti BCI Competition III - dataset 4a: 5 soggetti | - - | CNN CNN AlexNet | CNN CNN AlexNet | 84.19% 99.35% |
| 14[34] | Physionet: 109 sog OpenBMI: 54 sog Kaya2018: 13 sog Meng2019: 42 sog Stieger2021: 62 sog | <ul style="list-style-type: none"> • Patch perturbation • Hemisphere perturbation • Random shift | Temporal and Spatial convolution layer | CNN | 88,60% 83,30% 85,10% 87,40% 90,20% |
| 15[35] | BCI Competition IV - dataset 2b: 9 soggetti | - | Pre-trained VGG-16 CNN | Target CNN fine tuned | 74.20% |
| 17[37] | BCI Competition IV - dataset 1: 7 soggetti | - | 2D-kernels-based-CNN | Stacked sparse autoencoder Softmax layer | 86.40% |
| 21[41] | BCI Competition III - dataset 4a: 5 soggetti | - | Wavelet Packet Decomposition | k-NN, C4.5 Decision Tree, REP Tree, SVM, RT, RF | SVM: 90,12% k-NN: 94,83% RF: 81,83% C4.5: 73,00% REP tree: 69,02% RT: 72,40% |

Tabella A.1: Tecniche di elaborazione per un task binario

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|--------------------------|---|---|---|--|---|
| 2[22] 4[24] | Ma: 25 soggetti BNCI Horizon 2020: 14 soggetti | - - | EEGNet CSP | EEGNet CNN | 78.90% 79.00% |
| 7[27] 8[28] 14[34] | OpenBMI: 54 soggetti BCI Competition III - dataset 4a: 5 soggetti Physionet: 109 sog OpenBMI: 54 sog Kaya2018: 13 sog Meng2019: 42 sog Stieger2021: 62 sog | - - <ul style="list-style-type: none"> Patch perturbation Hemisphere perturbation Random shift | CNN CNN AlexNet Temporal and Spatial convolution layer | CNN CNN AlexNet CNN | 84.19% 99.35% 88,60% 83,30% 85,10% 87,40% 90,20% |
| 15[35] | BCI Competition IV - dataset 2b: 9 soggetti | - | Pre-trained VGG-16 CNN | Target CNN fine tuned | 74.20% |
| 17[37] | BCI Competition IV - dataset 1: 7 soggetti | - | 2D-kernels-based-CNN | Stacked sparse autoencoder Softmax layer | 86.40% |
| 21[41] | BCI Competition III - dataset 4a: 5 soggetti | - | Wavelet Packet Decomposition | k-NN, C4.5 Decision Tree, REP Tree, SVM, RT, RF | SVM: 90,12% k-NN: 94,83% RF: 81,83% C4.5: 73,00% REP tree: 69,02% RT: 72,40% |

Tabella A.2: Tecniche di elaborazione per un task binario post valutazione

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|--------|--|----------------------|---|---|--|
| 1[21] | Jeong: 25 soggetti | - | <ul style="list-style-type: none"> • Common feature extractor • Class specific linear extractor • Concatenazione | Multi Layer Perceptron | 57.29% |
| 3[23] | BCI Competition IV - dataset 2a: 9 soggetti BCI Competition III - dataset 3a: 3 soggetti | - | FBCSP | TSGE-EEGNet | dataset 2a: 81.34% dataset 3a: 88.89% |
| 5[25] | Competition IV - dataset 2a: 9 soggetti Competition IV - dataset 2b: 9 soggetti | - | FBCSP + STDF | Ensemble Support Vector Learning Classifier | dataset 2a/2b: 82.50% |
| 6[26] | BCI Competition IV - dataset 2a: 9 soggetti Stroke patients: 10 soggetti | - | CSP | LDA | dataset 2a: 80.02% stroke patients: 80.00% |
| 9[29] | BCI Competition IV - dataset 2a: 9 soggetti High Gamma Dataset - 14 soggetti | - | <ul style="list-style-type: none"> • Deep temporal and Multi spectral Convolution blocks • Squeeze and Excitation • Feature fusion | CNN | dataset 2a: 74.71% HGD: 93.25% |
| 10[30] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 spgetti BCI Competition III - dataset 4a: 5 soggetti | Trial crops strategy | Temporal and spatial convolution layer | CNN | dataset 2a: 65.37% dataset 2b: 75.33% dataset 4a: 90.52% |
| 11[31] | 9 soggetti | - | CSP | CNN | 91.81% |

Tabella A.3: Tecniche di elaborazione per un task multi-classe pt.1

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|--------|---|---------------------------------|--|---|---|
| 12[32] | BCI Competition IV - dataset 2a: 9 soggetti BCI Competition III - dataset 3a: 3 soggetti | - | <ul style="list-style-type: none"> Autoregressive coefficients Wavelet packet entropy Wavelet fractal estimates | SVM | dataset 2a: 97.00% dataset 3a: 95.33% |
| 13[33] | BCI Competition IV - dataset 2a: 9 soggetti | - | CSP | LDA | 81.37% |
| 16[36] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti | - | EEGNet | EEGNet | dataset 2a: 79.43% dataset 2b: 87.52% |
| 18[38] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti Track#1: 20 soggetti | - | Initial temporal FE module Deep EEG-channel-attention module Wavelet-based temporal-spectral-attention module | CNN | dataset 2a: 81.45% dataset 2b: 81.78% Track#1: 83.31% |
| 19[39] | Physionet: 109 soggetti BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti | - | EEGNet Fusion V2 | EEGNet Fusion V2 | Physionet: 87.80% dataset 2a: 74.30% dataset 2b: 84.10% |
| 20[40] | OpenBMI: 54 soggetti BCI Competition IV - dataset 2a: 9 soggetti HGD: 14 soggetti BCI Competition III - dataset 4a: 5 soggetti | - | Overlapping filter bank CNN | Overlapping filter bank CNN | dataset 2a: 79.63% HGD: 93.25% OpenBMI: 87.60% |
| 22[42] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti SEED: 15 soggetti | Segmentation and Reconstruction | Convolution Module + Self-Attention Module | Classifier Module: two fully connected layers | dataset 2a: 78.66% dataset 2b: 84.63% SEED: 95.30% |

Tabella A.4: Tecniche di elaborazione per un task multi-classe pt.2

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|--------|--|----------------------|---|---|--|
| 1[21] | Jeong: 25 soggetti | - | <ul style="list-style-type: none"> Common feature extractor Class specific linear extractor Concatenazione | Multi Layer Perceptron | 57.29% |
| 3[23] | BCI Competition IV - dataset 2a: 9 soggetti BCI Competition III - dataset 3a: 3 soggetti | - | FBCSP | TSSL-EEGNet | dataset 2a: 81.34% dataset 3a: 88.89% |
| 5[25] | Competition IV - dataset 2a: 9 soggetti Competition IV - dataset 2b: 9 soggetti | - | FBCSP + STDF | Ensemble Support Vector Learning Classifier | dataset 2a/2b: 82.50% |
| 6[26] | BCI Competition IV - dataset 2a: 9 soggetti Stroke patients: 10 soggetti | - | CSP | LDA | dataset 2a: 80.02% stroke patients: 80.00% |
| 9[29] | BCI Competition IV - dataset 2a: 9 soggetti High Gamma Dataset - 14 soggetti | - | <ul style="list-style-type: none"> Deep temporal and Multi spectral Convolution blocks Squeeze and Excitation Feature fusion | CNN | dataset 2a: 74.71% HGD: 93.25% |
| 10[30] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 spgetti BCI Competition III - dataset 4a: 5 soggetti | Trial crops strategy | Temporal and spatial convolution layer | CNN | dataset 2a: 65.37% dataset 2b: 75.33% dataset 4a: 90.52% |
| 11[31] | 9 soggetti | - | CSP | CNN | 91.81% |

Tabella A.5: Tecniche di elaborazione per un task multi-classe post valutazione pt.1

| ID | DATASET | DATA AUGMENTATION | FEATURE EXTRACTION | CLASSIFICAZIONE | ACC. |
|--------|---|---------------------------------|--|---|--|
| 12[32] | BCI Competition IV - dataset 2a: 9 soggetti BCI Competition III - dataset 3a: 3 soggetti | - | <ul style="list-style-type: none"> Autoregressive coefficients Wavelet packet entropy Wavelet fractal estimates | SVM | dataset 2a: 97.00% dataset 3a: 95.33% |
| 13[33] | BCI Competition IV - dataset 2a: 9 soggetti | - | CSP | LDA | 81.37% |
| 16[36] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti | - | EEGNet | EEGNet | dataset 2a: 79.43% dataset 2b: 87.52% |
| 18[38] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti Track#1: 20 soggetti | - | Initial temporal FE module Deep EEG-channel-attention module Wavelet-based temporal-spectral-attention module | CNN | dataset 2a: 81.45% dataset 2b: 81.78% Track#1: 83.31% |
| 19[39] | Physionet: 109 soggetti BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti | - | EEGNet Fusion V2 | EEGNet Fusion V2 | Physionet: 87.80% dataset 2a: 74.30% dataset 2b: 84.10% |
| 20[40] | OpenBMI: 54 soggetti BCI Competition IV - dataset 2a: 9 soggetti HGD: 14 soggetti BCI Competition III - dataset 4a: 5 soggetti | - | Overlapping filter bank CNN | Overlapping filter bank CNN | dataset 2a: 79.63% HGD: 93.25% OpenBMI: 87.60% |
| 22[42] | BCI Competition IV - dataset 2a: 9 soggetti dataset 2b: 9 soggetti SEED: 15 soggetti | Segmentation and Reconstruction | Convolution Module + Self-Attention Module | Classifier Module: two fully connected layers | dataset 2a: 78.66% dataset 2b: 84.63% SEED: 95.30% |

Tabella A.6: Tecniche di elaborazione per un task multi-classe post valutazione pt.2

Elenco delle tabelle

| | | |
|------|--|----|
| 1.1 | Caratteristiche tecniche delle BCI più diffuse [1] | 3 |
| 1.2 | Tecnologie BCI [1] | 3 |
| 2.1 | 27 items per redigere una revisione sistematica o una metanalisi secondo il PRISMA Statement | 17 |
| 2.2 | Criteri di inclusione per la metanalisi | 17 |
| 2.3 | Presentazione degli studi selezionati | 27 |
| 2.4 | Ripartizione degli studi tra task binario e task multi-classe | 30 |
| 2.5 | Tecniche di pre-processing | 33 |
| 2.6 | Feature Extraction task multi-classe | 41 |
| 2.7 | Feature Extraction task binario | 41 |
| 2.8 | Tecniche di Feature Extraction | 42 |
| 2.9 | Classificazione task binario | 50 |
| 2.10 | Classificazione task multi-classe | 50 |
| 2.11 | Tecniche di classificazione | 52 |
| 3.1 | Criticità degli algoritmi di classificazione per un task multi-classe | 63 |
| 4.1 | Risultati | 66 |
| A.1 | Tecniche di elaborazione per un task binario | 70 |
| A.2 | Tecniche di elaborazione per un task binario post valutazione | 71 |
| A.3 | Tecniche di elaborazione per un task multi-classe pt.1 | 72 |

| | | |
|-----|---|----|
| A.4 | Tecniche di elaborazione per un task multi-classe pt.2 | 73 |
| A.5 | Tecniche di elaborazione per un task multi-classe post valutazione pt.1 | 74 |
| A.6 | Tecniche di elaborazione per un task multi-classe post valutazione pt.2 | 75 |

Elenco delle figure

| | | |
|------|---|----|
| 1.1 | Schema BCI: fasi di elaborazione del segnale fisiologico dalla sua acquisizione fino al controllo di un dispositivo esterno [3] | 2 |
| 1.2 | Modulazioni del segnale EEG per BCI esogene [5] | 4 |
| 1.3 | Modulazioni del segnale EEG per BCI endogene [5] | 5 |
| 1.4 | Andamento onde cerebrali e loro caratteristiche [8] | 7 |
| 1.5 | Schema di posizionamento degli elettrodi secondo lo Standard Internazionale 10/20 [1] | 8 |
| 1.6 | Andamento ERS/ERD con mappe topografiche attraverso cui è possibile visualizzare le attivazioni cerebrali per un semplice motor task [13] | 10 |
| 1.7 | Corteccia primaria motoria e sensoriale [5] | 11 |
| 2.1 | Flow-chart PRISMA Statement | 13 |
| 2.2 | Distribuzione dei dataset pubblici utilizzati | 19 |
| 2.3 | Range anni di pubblicazione degli articoli | 19 |
| 2.4 | Flow-chart PRISMA Statement | 21 |
| 2.5 | Acquisizione EEG a 64 canali [43] | 28 |
| 2.6 | Protocollo di acquisizione del MI task [27] | 29 |
| 2.7 | Task binario vs Task multi-classe | 29 |
| 2.8 | Task multi-classe | 30 |
| 2.9 | Filtro passabanda reale [51] | 33 |
| 2.10 | Pre-processing | 35 |

| | |
|---|----|
| 2.11 Autoencoder: in blu sono rappresentati gli input layers, in verde gli output layers [54] | 36 |
| 2.12 GAN [54] | 36 |
| 2.13 Data Augmentation | 37 |
| 2.14 Trial crops strategy [30] | 38 |
| 2.15 Machine Learning vs Deep Learning | 40 |
| 2.16 FBCSP [58] | 44 |
| 2.17 Tipologia reti convoluzionali CNN | 45 |
| 2.18 Esempio di rete neurale convoluzionale CNN [60] | 46 |
| 2.19 Common Feature Extractor e Class-Specific Feature Extractor [21] | 48 |
| 2.20 Squeeze-and-Excitation Feature Fusion Block [29] | 48 |
| 2.21 Phadikar <i>et al.</i> ,2022 [32] Feature Extraction | 49 |
| 2.22 Distribuzione DL | 51 |
| 2.23 Multi Layer Perceptron [65] | 52 |
| 2.24 Linear Discriminant Analysis [67] | 53 |
| 2.25 Support Vector Machine [68] | 54 |
| 2.26 Fully Connected Layer [69] | 55 |
| 2.27 Stacked Sparse Autoencoder [37] | 56 |
| 2.28 Ensemble-based approach [41] | 57 |
| 3.1 Matrice di confusione | 59 |
| 3.2 Accuratezza task binario | 60 |
| 3.3 Pipeline MI task binario | 61 |
| 3.4 Pipeline MI task multi-classe | 63 |

Bibliografia

- [1] Luis Fernando Nicolas-Alonso e Jaime Gomez-Gil. «Brain computer interfaces, a review». In: *sensors* 12.2 (2012), pp. 1211–1279 (cit. alle pp. 1–3, 7, 8).
- [2] Shiv Kumar Mudgal, Suresh K Sharma, Jitender Chaturvedi e Anil Sharma. «Brain computer interface advancement in neurosciences: Applications and issues». In: *Interdisciplinary Neurosurgery* 20 (2020), p. 100694 (cit. a p. 1).
- [3] Lei Zhang, Xiao-jing Guo, Xiao-Pei Wu e Beng-yan Zhou. «Low-cost circuit design of EEG signal acquisition for the brain-computer interface system». In: *2013 6th International Conference on Biomedical Engineering and Informatics*. IEEE. 2013, pp. 245–250 (cit. a p. 2).
- [4] Reza Abiri, Soheil Borhani, Eric W Sellers, Yang Jiang e Xiaopeng Zhao. «A comprehensive review of EEG-based brain–computer interface paradigms». In: *Journal of neural engineering* 16.1 (2019), p. 011001 (cit. a p. 3).
- [5] Valentina Agostini. *Lessons 18,19 – Brain Computer Interfaces (BCIs)*. Materiale del corso 'Neuroengineering' tenuto presso Politecnico di Torino. 2022. URL: [Slides](#) (cit. alle pp. 4, 5, 11).
- [6] Jonathan R Wolpaw. «Brain–computer interfaces». In: *Handbook of clinical neurology*. Vol. 110. Elsevier, 2013, pp. 67–74 (cit. a p. 5).
- [7] Mostafa Orban, Mahmoud Elsamanty, Kai Guo, Senhao Zhang e Hongbo Yang. «A review of brain activity and EEG-based brain–computer interfaces for rehabilitation application». In: *Bioengineering* 9.12 (2022), p. 768 (cit. a p. 6).
- [8] Institute of Science e Technology Austria. «Meccanismi sinaptici delle onde cerebrali». In: (2013). URL: <https://www.alzheimer-riese.it/contributi-dal-mondo/ricerche/3445-meccanismi-sinaptici-delle-onde-cerebrali.html> (cit. a p. 7).
- [9] Richard W Homan. «The 10-20 electrode system and cerebral location». In: *American Journal of EEG Technology* 28.4 (1988), pp. 269–279 (cit. a p. 8).

-
- [10] Sarah N Abdulkader, Ayman Atia e Mostafa-Sami M Mostafa. «Brain computer interfacing: Applications and challenges». In: *Egyptian Informatics Journal* 16.2 (2015), pp. 213–230 (cit. a p. 9).
- [11] Hui-yen Yap, Yun-huoy Choo e Wee-how Khoh. «Overview of acquisition protocol in EEG based recognition system». In: *Brain Informatics: International Conference, BI 2017, Beijing, China, November 16-18, 2017, Proceedings*. Springer. 2017, pp. 129–138 (cit. a p. 9).
- [12] Gert Pfurtscheller e Christa Neuper. «Motor imagery activates primary sensorimotor area in humans». In: *Neuroscience letters* 239.2-3 (1997), pp. 65–68 (cit. alle pp. 10, 27).
- [13] Zhichuan Tang, Hongnian Yu, Chunfu Lu, Pengcheng Liu e Xuexue Jin. «Single trial classification of different movements on one arm based on ERD/ERS and corticomuscular coherence». In: *IEEE Access* 7 (2019), pp. 128185–128197 (cit. a p. 10).
- [14] Bradley J Edelman, Bryan Baxter e Bin He. «EEG source imaging enhances the decoding of complex right-hand motor imagery tasks». In: *IEEE Transactions on Biomedical Engineering* 63.1 (2015), pp. 4–14 (cit. a p. 10).
- [15] Alessandro Liberati et al. «The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration». In: *Annals of internal medicine* 151.4 (2009), W–65 (cit. a p. 12).
- [16] *PubMed*. URL: <https://pubmed.ncbi.nlm.nih.gov/> (cit. a p. 20).
- [17] *Scopus*. URL: <https://www.scopus.com/> (cit. a p. 20).
- [18] *Google Scholar*. URL: <https://scholar.google.com/> (cit. a p. 20).
- [19] ASAN Ahmet e Ahmet Aslan. «Quartile scores of scientific journals: Meaning, importance and usage». In: *Acta Medica Alanya* 4.1 (2020), pp. 102–108 (cit. a p. 22).
- [20] Nicholas J DeVito e Ben Goldacre. «Catalogue of bias: publication bias». In: *BMJ Evidence-Based Medicine* (2018) (cit. a p. 23).
- [21] Byeong-Hoo Lee, Jeong-Hyun Cho e Byoung-Hee Kwon. «A Factorization Approach for Motor Imagery Classification». In: *2022 10th International Winter Conference on Brain-Computer Interface (BCI)*. IEEE. 2022, pp. 1–5 (cit. alle pp. 23, 30, 32, 41, 47, 48, 50, 53, 72, 74).

- [22] Jun Ma, Banghua Yang, Wenzheng Qiu, Yunzhe Li, Shouwei Gao e Xinxing Xia. «A large EEG dataset for studying cross-session variability in motor imagery brain-computer interface». In: *Scientific Data* 9.1 (2022), p. 531 (cit. alle pp. 23, 30, 32, 34, 41, 50, 70, 71).
- [23] Xin Deng, Boxian Zhang, Nian Yu, Ke Liu e Kaiwei Sun. «Advanced TSGL-EEGNet for motor imagery EEG-based brain-computer interfaces». In: *IEEE access* 9 (2021), pp. 25118–25130 (cit. alle pp. 23, 30, 32, 41, 43, 50, 62, 72, 74).
- [24] Xuying Wang, Rui Yang e Mengjie Huang. «An unsupervised deep-transfer-learning-based motor imagery EEG classification scheme for brain-computer interface». In: *Sensors* 22.6 (2022), p. 2241 (cit. alle pp. 24, 30, 32, 34, 41, 50, 70, 71).
- [25] Jing Luo, Xing Gao, Xiaobei Zhu, Bin Wang, Na Lu e Jie Wang. «Motor imagery EEG classification based on ensemble support vector learning». In: *Computer methods and programs in biomedicine* 193 (2020), p. 105464 (cit. alle pp. 24, 30, 32, 41, 43, 44, 50, 54, 62, 72, 74).
- [26] Pramod Gaur, Harsh Gupta, Anirban Chowdhury, Karl McCreadie, Ram Bilas Pachori e Hui Wang. «A sliding window common spatial pattern for enhancing motor imagery classification in EEG-BCI». In: *IEEE Transactions on Instrumentation and Measurement* 70 (2021), pp. 1–9 (cit. alle pp. 24, 30, 32, 41, 50, 53, 62, 72, 74).
- [27] Kaishuo Zhang, Neethu Robinson, Seong-Whan Lee e Cuntai Guan. «Adaptive transfer learning for EEG motor imagery classification with deep convolutional neural network». In: *Neural Networks* 136 (2021), pp. 1–10 (cit. alle pp. 24, 29, 30, 32, 41, 50, 61, 70, 71).
- [28] Shalu Chaudhary, Sachin Taran, Varun Bajaj e Abdulkadir Sengur. «Convolutional neural network based approach towards motor imagery tasks EEG signals classification». In: *IEEE Sensors Journal* 19.12 (2019), pp. 4494–4500 (cit. alle pp. 24, 30, 32, 41, 50, 61, 70, 71).
- [29] Yang Li, Lianghui Guo, Yu Liu, Jingyu Liu e Fangang Meng. «A temporal-spectral-based squeeze-and-excitation feature fusion network for motor imagery EEG decoding». In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 29 (2021), pp. 1534–1545 (cit. alle pp. 24, 30, 32, 41, 48, 50, 72, 74).

-
- [30] Daily Milanés Hermosilla, Rafael Trujillo Codorniú, René López Baracaldo, Roberto Sagaró Zamora, Denis Delisle Rodríguez, Yolanda Llosas Albuerne e José Ricardo Núñez Álvarez. «Shallow convolutional network excel for classifying motor imagery EEG in BCI applications». In: *IEEE Access* 9 (2021), pp. 98275–98286 (cit. alle pp. 25, 30, 33, 38, 41, 50, 72, 74).
- [31] Lili Duan, Jie Li, Hongfei Ji, Zilong Pang, Xuanci Zheng, Rongrong Lu, Maozhen Li e Jie Zhuang. «Zero-shot learning for EEG classification in motor imagery-based BCI system». In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 28.11 (2020), pp. 2411–2419 (cit. alle pp. 25, 30, 33, 41, 50, 55, 62, 72, 74).
- [32] Souvik Phadikar, Nidul Sinha e Rajdeep Ghosh. «Unsupervised feature extraction with autoencoders for EEG based multiclass motor imagery BCI». In: *Expert Systems with Applications* 213 (2023), p. 118901 (cit. alle pp. 25, 30, 32, 41, 49, 50, 54, 62, 73, 75).
- [33] Navid Ayoobi e Elnaz Banan Sadeghian. «Unsupervised Motor Imagery Saliency Detection Based on Self-Attention Mechanism». In: *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. IEEE. 2022, pp. 4817–4820 (cit. alle pp. 25, 30, 32, 41, 50, 53, 62, 73, 75).
- [34] Sergio Pérez-Velasco, Eduardo Santamaría-Vázquez, Víctor Martínez-Cagigal, Diego Marcos-Martínez e Roberto Hornero. «EEGSym: Overcoming inter-subject variability in motor imagery based BCIs with deep learning». In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 30 (2022), pp. 1766–1775 (cit. alle pp. 25, 30, 32, 34, 38, 41, 50, 61, 62, 70, 71).
- [35] Gaowei Xu, Xiaoang Shen, Sirui Chen, Yongshuo Zong, Canyang Zhang, Hongyang Yue, Min Liu, Fei Chen e Wenliang Che. «A deep transfer convolutional neural network framework for EEG signal classification». In: *IEEE Access* 7 (2019), pp. 112767–112776 (cit. alle pp. 25, 30, 32, 41, 50, 70, 71).
- [36] Zhengqing Miao, Xin Zhang, Carlo Menon, Yelong Zheng, Meirong Zhao e Dong Ming. «Priming cross-session motor imagery classification with a universal deep domain adaptation framework». In: *arXiv preprint arXiv:2202.09559* (2022) (cit. alle pp. 26, 30, 32, 41, 50, 73, 75).
- [37] Jun Yang, Zhengmin Ma, Jin Wang e Yunfa Fu. «A novel deep learning scheme for motor imagery EEG decoding based on spatial representation fusion». In: *IEEE Access* 8 (2020), pp. 202100–202110 (cit. alle pp. 26, 30, 32, 34, 41, 50, 55, 56, 61, 70, 71).

- [38] Wei-Yen Hsu e Ya-Wen Cheng. «EEG-Channel-Temporal-Spectral-Attention Correlation for Motor Imagery EEG Classification». In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 31 (2023), pp. 1659–1669 (cit. alle pp. 26, 30, 32, 41, 47, 50, 62, 73, 75).
- [39] Radia Rayan Chowdhury, Yar Muhammad e Usman Adeel. «Enhancing Cross-Subject Motor Imagery Classification in EEG-Based Brain–Computer Interfaces by Using Multi-Branch CNN». In: *Sensors* 23.18 (2023), p. 7908 (cit. alle pp. 26, 30, 32, 41, 50, 73, 75).
- [40] Jing Luo, Jundong Li, Qi Mao, Zhenghao Shi, Haiqin Liu, Xiaoyong Ren e Xinhong Hei. «Overlapping filter bank convolutional neural network for multi-subject multicategory motor imagery brain-computer interface». In: *BioData Mining* 16.1 (2023), p. 19 (cit. alle pp. 26, 30, 32, 41, 50, 73, 75).
- [41] Abdulhamit Subasi, Saeed Mian Qaisar et al. «The ensemble machine learning-based classification of motor imagery tasks in brain-computer interface». In: *Journal of Healthcare Engineering* 2021 (2021) (cit. alle pp. 26, 30, 33, 41, 44, 50, 56, 57, 70, 71).
- [42] Yonghao Song, Qingqing Zheng, Bingchuan Liu e Xiaorong Gao. «EEG conformer: Convolutional transformer for EEG decoding and visualization». In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 31 (2022), pp. 710–719 (cit. alle pp. 27, 30, 33, 39, 41, 47, 50, 73, 75).
- [43] Ellen C Ketola, Mikenzie Barankovich, Stephanie Schuckers, Aratrika Ray-Dowling, Daqing Hou e Masudul H Intiaz. «Channel Reduction for an EEG-Based Authentication System While Performing Motor Movements». In: *Sensors* 22.23 (2022), p. 9156 (cit. a p. 28).
- [44] Kyle E Mathewson, Tyler JL Harrison e Sayeed AD Kizuk. «High and dry? Comparing active dry EEG electrodes to active and passive wet electrodes». In: *Psychophysiology* 54.1 (2017), pp. 74–82 (cit. a p. 28).
- [45] Julia WY Kam, Sandon Griffin, Alan Shen, Shawn Patel, Hermann Hinrichs, Hans-Jochen Heinze, Leon Y Deouell e Robert T Knight. «Systematic comparison between a wireless EEG system with dry electrodes and a wired EEG system with wet electrodes». In: *NeuroImage* 184 (2019), pp. 119–129 (cit. a p. 28).
- [46] Ali Al-Saegh, Shefa A Dawwd e Jassim M Abdul-Jabbar. «Deep learning for motor imagery EEG-based classification: A review». In: *Biomedical Signal Processing and Control* 63 (2021), p. 102172 (cit. a p. 31).

-
- [47] Jose Antonio Uriguen e Begona Garcia-Zapirain. «EEG artifact removal state of the art and guidelines». In: *Journal of neural engineering* 12.3 (2015), p. 031001 (cit. a p. 31).
- [48] Dennis J McFarland, Laurie A Miner, Theresa M Vaughan e Jonathan R Wolpaw. «Mu and beta rhythm topographies during motor imagery and actual movements». In: *Brain topography* 12 (2000), pp. 177–186 (cit. a p. 31).
- [49] Youngjoo Kim, Jiwoo Ryu, Ko Keun Kim, Clive C Took, Danilo P Mandic, Cheolsoo Park et al. «Motor imagery classification using mu and beta rhythms of EEG with strong uncorrelating transform based complex common spatial patterns». In: *Computational intelligence and neuroscience 2016* (2016) (cit. a p. 31).
- [50] Chun Mei Wang e Wei Cai Xiao. «Second-order IIR Notch Filter Design and implementation of digital signal processing system». In: *Applied Mechanics and Materials* 347 (2013), pp. 729–732 (cit. a p. 31).
- [51] CADENCE PCB SOLUTIONS. «Creating and Analyzing an RF Bandpass Filter Simulation». In: (2024). URL: <https://resources.pcb.cadence.com/blog/2023-creating%20and-analyzing-an-rf-bandpass-filter-simulation> (cit. a p. 33).
- [52] Shohei Tsuchimoto, Shuka Shibusawa, Seitaro Iwama, Masaaki Hayashi, Kohei Okuyama, Nobuaki Mizuguchi, Kenji Kato e Junichi Ushiba. «Use of common average reference and large-Laplacian spatial-filters enhances EEG signal-to-noise ratios in intrinsic sensorimotor activity». In: *Journal of neuroscience methods* 353 (2021), p. 109089 (cit. a p. 34).
- [53] Connor Shorten e Taghi M Khoshgoftaar. «A survey on image data augmentation for deep learning». In: *Journal of big data* 6.1 (2019), pp. 1–48 (cit. a p. 35).
- [54] Chao He, Jialu Liu, Yuesheng Zhu e Wencai Du. «Data augmentation for deep neural networks model in EEG classification task: a review». In: *Frontiers in Human Neuroscience* 15 (2021), p. 765525 (cit. alle pp. 35, 36).
- [55] Alhassan Mumuni e Fuseini Mumuni. «Data augmentation: A comprehensive survey of modern approaches». In: *Array* (2022), p. 100258 (cit. a p. 39).
- [56] *What Is Feature Extraction?* URL: <https://it.mathworks.com/discovery/feature-extraction.html> (cit. a p. 39).

- [57] Nameirakpam Premjit Singh, Anil Kumar Gautam e Tripurari Sharan. «An insight into the hardware and software aspects of a BCI system with focus on ultra-low power bulk driven OTA and Gm-C based filter design, and a detailed review of the recent AI/ML techniques». In: *Artificial Intelligence-Based Brain-Computer Interface* (2022), pp. 283–315 (cit. a p. 42).
- [58] Kai Keng Ang, Zheng Yang Chin, Haihong Zhang e Cuntai Guan. «Filter bank common spatial pattern (FBCSP) in brain-computer interface». In: *2008 IEEE international joint conference on neural networks (IEEE world congress on computational intelligence)*. IEEE. 2008, pp. 2390–2397 (cit. alle pp. 43, 44).
- [59] Makoto Kobayashi e Kazushi Nakano. «Two problems of wavelet packet transform». In: *2013 10th International Conference on Information Technology: New Generations*. IEEE. 2013, pp. 153–159 (cit. a p. 45).
- [60] Yuan Liu, Yu-Xuan Huang, Xuexi Zhang, Wen Qi, Jing Guo, Yingbai Hu, Longbin Zhang e Hang Su. «Deep C-LSTM neural network for epileptic seizure and tumor detection using high-dimension EEG signals». In: *IEEE Access* 8 (2020), pp. 37495–37504 (cit. a p. 46).
- [61] Zhaoyang Niu, Guoqiang Zhong e Hui Yu. «A review on the attention mechanism of deep learning». In: *Neurocomputing* 452 (2021), pp. 48–62 (cit. a p. 47).
- [62] Vernon J Lawhern, Amelia J Solon, Nicholas R Waytowich, Stephen M Gordon, Chou P Hung e Brent J Lance. «EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces». In: *Journal of neural engineering* 15.5 (2018), p. 056013 (cit. a p. 47).
- [63] Qiang Yang, Yu Zhang, Wenyuan Dai e Sinno Jialin Pan. *Transfer learning*. Cambridge University Press, 2020 (cit. a p. 51).
- [64] Joanne Quinn, Joanne McEachen, Michael Fullan, Mag Gardner e Max Drummy. *Dive into deep learning: Tools for engagement*. Corwin Press, 2019 (cit. a p. 52).
- [65] SangGyu An. *MLP’s applications with tweaks in its structure*. 2021. URL: <https://medium.com/codex/mlps-applications-with-tweaks-in-its-structure-c9aa3f05578> (cit. a p. 52).
- [66] Pethuru Raj e Preetha Evangeline David. *The digital twin paradigm for smarter systems and environments: The industry use cases*. Academic Press, 2020 (cit. a p. 53).

- [67] Ambika. *Linear Discriminant Analysis (LDA) in Machine Learning: Example, Concept and Applications*. 2023. URL: <https://medium.com/aimonks/linear-discriminant-analysis-lda-in-machine-learning-example-concept-and-applications-37f27e7c7e98> (cit. a p. 53).
- [68] Caterina Urban e Antoine Miné. «A review of formal methods applied to machine learning». In: *arXiv preprint arXiv:2104.02466* (2021) (cit. a p. 54).
- [69] Danny Soriano, Carlos Aguilar, Ivan Ramirez-Morales, Eduardo Tusa, Wilmer Rivas e Maritza Pinta. «Mammogram classification schemes by using convolutional neural networks». In: *International Conference on Technology Trends*. Springer. 2017, pp. 71–85 (cit. a p. 55).
- [70] Gabriella Balestra. *Intelligenza artificiale in medicina*. Materiale del corso 'Intelligenza artificiale in medicina' tenuto presso Politecnico di Torino. 2021. URL: [Slides](#) (cit. alle pp. 56, 57).
- [71] Irfan Sudahri Damanik, Agus Perdana Windarto, Anjar Wanto, Poningsih, Sundari Retno Andani e Widodo Saputra. «Decision tree optimization in C4. 5 algorithm using genetic algorithm». In: *Journal of Physics: Conference Series*. Vol. 1255. 1. IOP Publishing. 2019, p. 012012 (cit. a p. 57).
- [72] Tao Li, Shenghuo Zhu e Mitsunori Ogihara. «Using discriminant analysis for multi-class classification: an experimental investigation». In: *Knowledge and information systems* 10 (2006), pp. 453–472 (cit. a p. 64).
- [73] Alyssa M Batula, Jesse A Mark, Youngmoo E Kim, Hasan Ayaz et al. «Comparison of brain activation during motor imagery and motor movement using fNIRS». In: *Computational intelligence and neuroscience 2017* (2017) (cit. a p. 66).