

**ALMA MATER STUDIORUM – UNIVERSITÀ DI BOLOGNA
CAMPUS DI CESENA
SCUOLA DI INGEGNERIA E ARCHITETTURA**

CORSO DI LAUREA MAGISTRALE IN INGEGNERIA BIOMEDICA

TITOLO DELLA TESI:

**Sviluppo di un sistema BCI EEG-based per il controllo
del movimento di un modello di arto superiore**

Tesi in

Bioingegneria della Riabilitazione LM

Relatore

Prof. Angelo Cappello

Presentata da

Valeria Mondini

Correlatrice

Ing. Anna Lisa Mangia

Sessione Terza

Anno Accademico 2013-2014

Indice

Introduzione	7
1. I sistemi Brain-Computer Interface (BCI).....	10
1.1 Definizione di sistema BCI.....	10
1.2 Tecniche di estrazione del segnale cerebrale	12
<i>Elettroencefalografia (EEG)</i>	<i>13</i>
<i>Elettrocorticografia (ECoG)</i>	<i>14</i>
<i>Registrazione intracorticale (Intracortical Neuron Recording)</i>	<i>15</i>
<i>Magnetoencefalografia (MEG).....</i>	<i>15</i>
<i>Risonanza magnetica funzionale (fMRI).....</i>	<i>17</i>
<i>Spettroscopia nel vicino infrarosso (NIRS).....</i>	<i>17</i>
1.3 Il segnale EEG.....	19
<i>Elettrodi per EEG (passivi o attivi, wet o dry)</i>	<i>19</i>
<i>Il Sistema Internazionale 10/20</i>	<i>20</i>
<i>Spettro del segnale EEG</i>	<i>22</i>
1.4 Segnali di controllo nei sistemi BCI EEG-based	24
<i>Visual Evoked Potentials (VEP)</i>	<i>25</i>
<i>Potenziali evocati P300</i>	<i>26</i>
<i>Slow Cortical Potentials (SCP)</i>	<i>28</i>
<i>Ritmi sensorimotori e protocollo Motor Imagery</i>	<i>29</i>
1.5 Il presente lavoro di tesi	32
2. Materiali e Metodi	34
2.1 Acquisizione e processing del segnale.....	34
<i>Acquisizione dei segnali.....</i>	<i>34</i>
<i>Re-referencing con CAR (Common Average Reference) modificato</i>	<i>35</i>
<i>Filtraggio temporale</i>	<i>37</i>
<i>Il metodo CSP</i>	<i>37</i>
<i>Feature Selection.....</i>	<i>40</i>

<i>Classificatore Lineare Support Vector Machine (SVM)</i>	41
2.2 Il software sviluppato (piattaforma LabVIEW 2011)	44
<i>Modello di arto superiore</i>	45
<i>Training</i>	46
<i>Training e Updating</i>	49
<i>Classification</i>	56
2.3 Test del software sviluppato	58
<i>I soggetti</i>	58
<i>Modalità di svolgimento delle prove</i>	60
2.4 Independent Component Analysis	62
<i>Il metodo ICA (Independent Component Analysis)</i>	62
2.5 Modalità di presentazione dei risultati	66
<i>Presentazione dei risultati dei soggetti</i>	66
<i>Presentazione dei risultati del sistema</i>	69
3. Risultati e Discussione	72
3.1 Soggetto DB	72
<i>Timeline delle sessioni di addestramento</i>	72
<i>Performances in fase di Training e Updating</i>	72
<i>Performances in Classification</i>	73
<i>Sorgenti ICA associabili a ERD/ERS (sessione migliore)</i>	73
<i>Commento generale</i>	74
3.2 Soggetto ALM	76
<i>Timeline delle sessioni di addestramento</i>	76
<i>Performances in fase di Training e Updating</i>	76
<i>Performances in Classification</i>	77
<i>Sorgenti ICA associabili a ERD/ERS (sessione migliore)</i>	77
<i>Commento generale</i>	78
3.3 Soggetto MR	80
<i>Timeline delle sessioni di addestramento</i>	80
<i>Performances in fase di Training e Updating</i>	80
<i>Performances in Classification</i>	81
<i>Sorgenti ICA associabili a ERD/ERS (sessione migliore)</i>	81

<i>Commento generale</i>	82
3.4 Soggetto VM	84
<i>Timeline delle sessioni di addestramento</i>	84
<i>Performances in fase di Training e Updating</i>	84
<i>Performances in Classification</i>	85
<i>Sorgenti ICA associabili a ERD/ERS (sessione migliore)</i>	85
<i>Commento generale</i>	86
3.5 Performances del sistema	88
<i>Evoluzione della separabilità del training set</i>	88
<i>Commento generale</i>	91
3.6 Discussione generale	93
<i>Confronto con la letteratura</i>	93
<i>Possibili miglioramenti del sistema</i>	100
Conclusioni	104
Bibliografia	108

Introduzione

Con il termine brain-computer interface (BCI) si intende un sistema in grado di misurare e tradurre direttamente i segnali cerebrali in istruzioni per periferiche di vario tipo (sistemi per la comunicazione, carrozzine, protesi e ortesi etc.), realizzando un canale di comunicazione che prescinde dai normali output neuromuscolari del sistema nervoso centrale. La possibilità di realizzare un sistema di questo tipo, utilizzabile anche da pazienti a stadi più o meno avanzati di SLA (Sclerosi Laterale Amiotrofica) o anche solo semplicemente paralizzati, ha nutrito negli ultimi decenni l'interesse della ricerca.

Da un punto di vista concettuale, possiamo pensare ad un generico sistema BCI come composto da tre blocchi: un blocco di acquisizione del segnale, uno di condizionamento (che traduce il segnale acquisito in istruzioni per la periferica) e uno di feedback, che chiude il cerchio dando un riscontro al soggetto dello stato mentale in cui si è portato. I sistemi BCI sono tanti e diversi, e possono essere categorizzati secondo diversi punti di vista: uno di questi è la tecnica di acquisizione del segnale cerebrale, che può essere invasiva o non invasiva. Tra le modalità non invasive, la tecnica più diffusa in quest'ambito è l'elettroencefalografia (EEG), grazie alla sua buona portabilità, bassi rischi per il paziente e buona risoluzione temporale. A loro volta, le BCI EEG-based possono sfruttare diversi segnali di controllo: i più comuni sono i VEP (Visual Evoked Potentials), i potenziali evocati P300, gli SCP (Slow Cortical Potentials) e i ritmi sensorimotori.

In questo lavoro di tesi, è stato sviluppato un sistema BCI EEG-based che sfrutta, come segnale di controllo, la modulazione dei ritmi sensorimotori tramite immaginazione motoria della mano destra o sinistra. Maggiori dettagli in generale sulle modalità di acquisizione del

segnale cerebrale, sulla tecnica EEG in particolare, sui segnali di controllo dei sistemi BCI EEG-based e sui ritmi sensorimotori, sono presenti nel primo capitolo della tesi.

Il cuore di questo lavoro è naturalmente consistito nella progettazione del software del sistema, in grado di leggere i segnali acquisiti e di processarli per dare un feedback al soggetto. Il software qui descritto è stato in particolare basato su piattaforma LabVIEW 2011. L'obiettivo dell'esperimento era quello di addestrare un soggetto a controllare tramite EEG il movimento (rotazione) di un modello di arto superiore simulato sullo schermo. Per ora, l'arto superiore è stato modellato come un semplice segmento rigido 1-link, vincolato alla spalla.

Oltre a progettare il software LabVIEW, in questo lavoro di tesi il sistema è stato anche testato su quattro persone. Maggiori informazioni su come siano stati processati i segnali, sull'implementazione del software e sulle modalità di svolgimento degli esperimenti possono essere ritrovati nel secondo capitolo.

Nel terzo e ultimo capitolo della tesi, infine, si riporteranno i risultati ottenuti. Seguirà un'ultima parte in cui il sistema qui descritto sarà confrontato con lavori simili in letteratura. In questo modo, il sistema potrà essere contestualizzato, e nuove idee per possibili miglioramenti potranno emergere.

1. I sistemi Brain-Computer Interface (BCI)

1.1 Definizione di sistema BCI

Secondo la definizione di J. Wolpaw del 2002, una brain-computer interface (BCI) è “un sistema in grado di misurare e convertire l’attività del sistema nervoso centrale in un output artificiale che può sostituire, ripristinare, enfatizzare, supplire o migliorare gli output naturali, cambiando in questo modo le interazioni in atto tra il sistema nervoso centrale e l’ambiente interno od esterno” [1]. In altri termini, un sistema BCI realizza un nuovo canale di comunicazione verso l’esterno, traducendo direttamente i segnali cerebrali in istruzioni per periferiche di vario tipo (es. sistemi per la comunicazione, protesi e ortesi, carrozzine), senza che sia necessaria la mediazione dei muscoli o dei nervi periferici [2].

Con un sistema di questo tipo, la comunicazione e l’interazione con l’ambiente sarebbero nuovamente possibili anche in soggetti affetti da gravi disordini neuromuscolari, il che spiega in parte il grande interesse della ricerca in questo campo negli ultimi decenni [3].

Concettualmente, possiamo pensare ad un generico sistema BCI come costituito dalle seguenti parti:

1. Signal Acquisition
2. Signal Processing
3. Feedback

Il modulo di acquisizione del segnale (**signal acquisition**) è quello che permette di registrare l’attività cerebrale del paziente, convertendola in un segnale fruibile per successive elaborazioni. Le modalità di acquisizione del segnale possono essere varie, e saranno meglio descritte nel prossimo paragrafo.

Il modulo di condizionamento del segnale (**signal processing**) è quello che di fatto traduce i segnali cerebrali estratti in comandi per la periferica, e può essere a sua volta pensato come composto dalle seguenti sottoparti:

- preprocessing del segnale: comprende i vari tipi di filtraggio (spaziale o temporale) e in generale le operazioni finalizzate al miglioramento del rapporto segnale/rumore, identificazione delle porzioni di segnale più significative, rimozione di artefatti etc.
- estrazione di features dal segnale preprocessato
- classificazione
- selezione dell'azione da intraprendere in base alla classificazione

Il **feedback** (es. movimento dell'arto meccanico/carrozzina, selezione di un simbolo su uno schermo) rappresenta la conseguenza tangibile dell'attività cerebrale del soggetto. Se la specifica applicazione BCI richiede un addestramento dell'utente, il feedback svolge un ruolo fondamentale: palesando infatti alla persona le conseguenze dello stato mentale in cui si è portata, le permette di capire come interagire con il sistema. Il feedback stesso rappresenta al contempo elemento sia di "ricompensa" che di "punizione", a seconda della sua concordanza o meno rispetto alle intenzioni del soggetto.

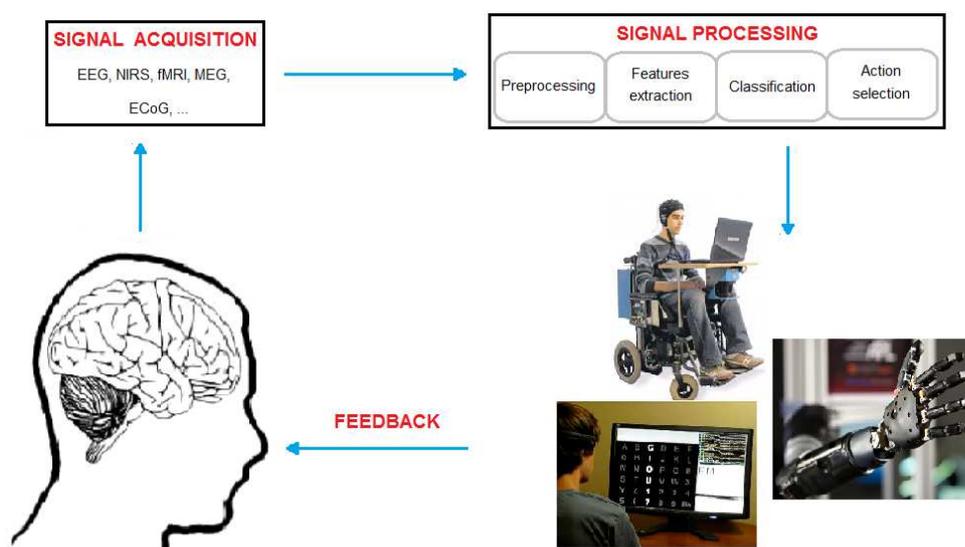


Figura 1. Schema a blocchi di un generico sistema BCI real-time.

Una rappresentazione schematica di quanto appena detto può essere ritrovata in Figura 1.

1.2 Tecniche di estrazione del segnale cerebrale

Parlando di BCI, è possibile descrivere la grande varietà di sistemi secondo diversi punti di vista: uno di questi riguarda la tecnica utilizzata per la detezione del segnale.

All'interno di questo paragrafo si andranno a descrivere diverse tecniche di neuroimaging che possono essere impiegate all'interno di sistemi BCI. Una prima distinzione può essere fatta in base al tipo di attività cerebrale monitorata:

1. segnali elettrofisiologici
2. segnali emodinamici

Con il termine “segnale elettrofisiologico” si intendono le variazioni di campo elettromagnetico/i flussi di corrente locali che sono diretta conseguenza dell'attività neuronale. In campo BCI, le modalità di detezione del segnale che rilevano l'attività elettrofisiologica sono l'elettroencefalografia e la magnetoencefalografia (EEG e MEG, non-invasive), l'elettrocorticografia (ECoG) e la registrazione intracorticale (invasive).

Per quanto riguarda invece il “segnale emodinamico”, questo si basa sul fatto che il glucosio nel sangue viene rilasciato ad un tasso maggiore in un'area di neuroni attivi rispetto ad una di neuroni inattivi [4][5]. Come conseguenza, si può osservare una variazione locale dell'equilibrio tra la concentrazione di ossiemoglobina e deossiemoglobina: il valore del rapporto tra le due forme mostra dunque localmente un andamento che è funzione del livello di attività delle aree cerebrali [4][5][6]. Le variazioni del rapporto locale tra ossiemoglobina e deossiemoglobina possono essere quantificate da metodi di neuroimaging come la risonanza magnetica funzionale (fMRI) o la spettroscopia nel vicino infrarosso (NIRS) [4][5]. Non essendo la risposta emodinamica una conseguenza immediata dell'attività dei neuroni, come lo è invece il segnale elettrofisiologico,

queste due ultime modalità di neuroimaging sono anche dette “indirette” [5].

Dopo questa breve introduzione sui principi alla base delle modalità di estrazione del segnale cerebrale, si fornirà di seguito una breve descrizione di ciascuna tecnica, evidenziando vantaggi e svantaggi nell’ottica della progettazione di un sistema BCI.

Elettroencefalografia (EEG)

L’elettroencefalografia (EEG, Figura 2) è una tecnica non invasiva che valuta l’attività elettrofisiologica del cervello attraverso la misura dei potenziali sullo scalpo. Il segnale EEG è un segnale ottenuto come differenza di potenziale tra due elettrodi (di cui almeno uno posizionato sullo scalpo) [5]. Ciò che rappresenta l’EEG è principalmente l’attività elettrica dei neuroni piramidali nella corteccia poiché, grazie alle loro caratteristiche di sincronizzazione, disposizione e prossimità rispetto allo scalpo, danno luogo a campi elettrici che si sommano efficacemente e sono così rilevabili in superficie [7].

I principali problemi dell’EEG sono la ridotta ampiezza dei segnali, unitamente a un’elevata sensibilità al rumore (linee di distribuzione elettrica, artefatti muscolari, artefatti da movimento oculare etc), nonché una risoluzione spaziale intrinsecamente deteriorata dal passaggio dei segnali attraverso più strati di tessuto e soprattutto attraverso il cranio, che opera come elemento di “sfocatura spaziale”[8]. Nonostante questi problemi, l’EEG rimane di gran lunga la modalità di neuroimaging più diffusa in ambito BCI [5]. Tra i

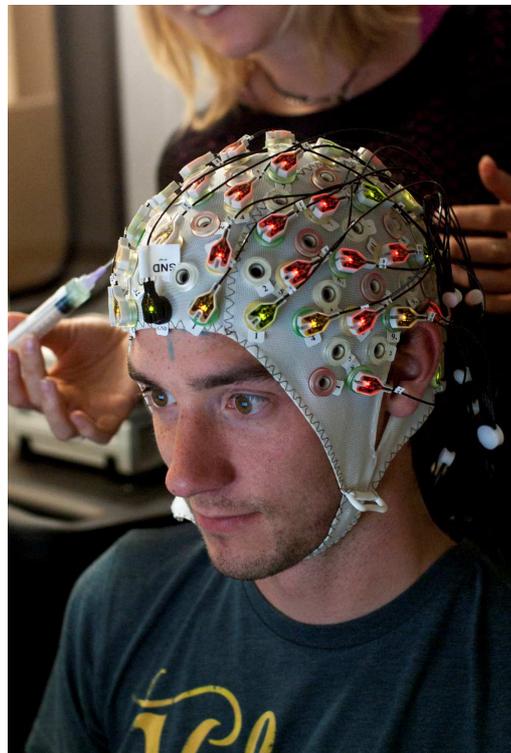


Figura 2: EEG

punti di forza ritroviamo infatti una buona risoluzione temporale (dell'ordine delle decine di millisecondi [8]), buona portabilità del sistema, costi relativamente bassi, semplicità e sicurezza di utilizzo (essendo un metodo non invasivo).

Data la grande diffusione dei sistemi BCI EEG-based e dato che il sistema sviluppato nel presente lavoro di tesi è di questo tipo, si riprenderà più estesamente la descrizione della tecnica EEG anche nel prossimo paragrafo, mentre nel paragrafo successivo si introdurranno i segnali di controllo più utilizzati nei sistemi BCI EEG-based. La tecnica EEG è stata già qui brevemente citata solo per completezza e per facilitare il confronto con altre tecniche di neuroimaging.

Elettrocorticografia (ECoG)

L'elettrocorticografia (ECoG, Figura 3) è un metodo di registrazione invasivo in cui un array di elettrodi viene posizionato direttamente sulla corteccia cerebrale, in seguito a craniotomia [4][5][8]. L'array di elettrodi può essere posizionato esternamente rispetto alla dura madre (ECoG epidurale) oppure internamente (ECoG subdurale) [5].

I vantaggi di questa tecnica rispetto all'EEG, essendo in questo caso l'array di elettrodi a contatto con la corteccia, sono ovviamente una maggiore ampiezza del segnale e un miglior rapporto segnale-rumore, grazie anche ad una minore sensibilità agli artefatti [5][8]. L'ECoG presenta anche una maggiore risoluzione temporale ma soprattutto spaziale, per via dell'assenza di tessuti da attraversare, che mescolano ed attenuano i segnali [8][9].

Naturalmente, il grande svantaggio dell'ECoG è la sua invasività, che comporta rischi non trascurabili per il paziente: per questo motivo, i primi studi su ECoG sono stati eseguiti su animali [5]. Un altro problema dell'ECoG riguarda il fatto che tuttora non è stato del tutto chiarito quale sia la stabilità a lungo termine dei segnali acquisiti [5][8].

Attualmente, l'impianto di ECoG non è diffuso, anche se la tecnica viene a volte utilizzata prima di trattare chirurgicamente i pazienti affetti da epilessia, per localizzare i centri epilettici [8]. Durante il periodo di

monitoraggio, è possibile sfruttare l'impianto anche per finalità di ricerca, tra cui anche quella sulle BCI basate su immaginazione motoria [8][10]–[12].

Registrazione intracorticale (Intracortical Neuron Recording)

La registrazione intracorticale (Figura 3) è una tecnica invasiva che misura l'attività elettrica nella materia grigia cerebrale [5]. La tecnica prevede l'inserimento di un array di microelettrodi che penetrano nella corteccia, per catturare potenziali d'azione e local field potentials dai neuroni [4].

Dall'array di microelettrodi impiantato possono essere ottenuti, tramite processing diversi, tre tipi di segnale:

1. single-unit activity (SUA), che analizza lo spiking di un neurone
2. multiple-unit activity (MUA), che analizza lo spiking di un insieme di neuroni
3. local field potentials (LFP), ottenuti da un filtraggio passa-basso dei valori di potenziale extracellulare [13]

Come l'ECoG, anche le registrazioni intracorticali condividono i vantaggi di avere un'elevata risoluzione spaziale e temporale e di essere sistemi portabili. Per quanto riguarda invece i problemi, oltre all'invasività, occorre ricordare che l'accuratezza dei segnali potrebbe essere deteriorata a seconda della reazione del tessuto cerebrale all'impianto del microelettrodo [5]. Inoltre, anche la sensibilità dello strumento potrebbe variare nel corso del tempo [5].

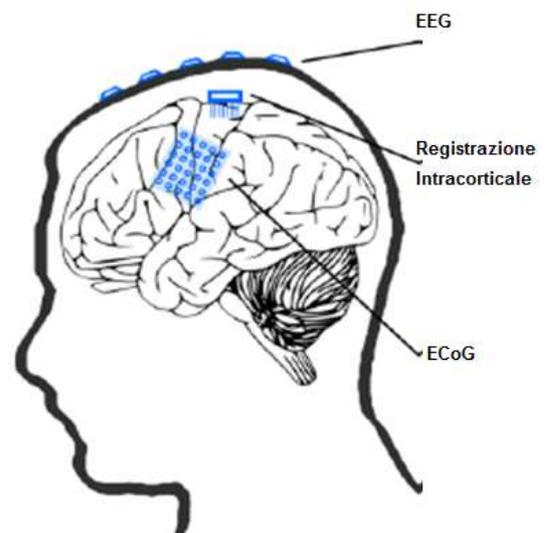


Figura 3: Le tecniche EEG, ECoG e Intracortical neuron recording

Magnetoencefalografia (MEG)

La magnetoencefalografia (MEG, Figura 4) torna ad essere una tecnica non invasiva. In particolare, la MEG registra sullo scalpo le

fluttuazioni del campo magnetico indotte dalle popolazioni di neuroni cerebrali, principalmente corticali [8]. Uno dei vantaggi dell'utilizzo dei campi magnetici rispetto a quelli elettrici è che i primi risultano essere meno disturbati dalla presenza del cranio e dello scalpo [5], anche se i processi neurofisiologici che producono i segnali MEG sono gli stessi che per i segnali EEG [5].



Figura 4: MEG

Dal momento che l'ampiezza dei segnali rilevati dalla MEG è estremamente piccola (dell'ordine dei 10^{-14} Tesla [8]) e trascurabile rispetto al campo magnetico terrestre, le registrazioni MEG vanno effettuate in una stanza magneticamente schermata, il che contribuisce a rendere il sistema non portatile [4][5][8][14]. Inoltre, per rilevare segnali di così piccola entità sono necessari dispositivi superconduttori a interferenza quantistica (SQUID), che devono essere continuamente raffreddati per garantire la superconduttività [5][14]. I moderni sistemi MEG sono costituiti tipicamente da array di circa 300 sensori SQUID; all'array viene data una forma "a elmo", e i sensori vengono continuamente raffreddati grazie al passaggio di elio liquido a una temperatura prossima allo zero assoluto [4][14]. A partire dai dati di campo magnetico rilevati attorno allo scalpo dai sensori SQUID, un computer ricava una mappa nel tempo dell'attività cerebrale, risolvendo un problema inverso simile a quello dell'EEG [4][14]. Per quanto riguarda l'accuratezza spazio-temporale, la MEG risulta essere leggermente migliore rispetto all'EEG [5].

A causa della non-portabilità del sistema MEG e dei costi elevati dell'apparecchiatura, le BCI MEG-based si trovano ancora allo stadio iniziale, anche se qualche studio è stato fatto [5][15]–[17].

Risonanza magnetica funzionale (fMRI)

Diversamente dalle modalità viste finora, la risonanza magnetica funzionale (fMRI, Figura 5) è una tecnica “indiretta”, che si basa sul segnale emodinamico.

La fMRI è una tecnica di neuroimaging non invasiva in grado di rilevare, oltre alle variazioni di volume e al flusso ematico cerebrale, il livello di ossigenazione del sangue durante l’attivazione dei neuroni [5][14]. In particolare, la modulazione del rapporto tra ossiemoglobina e deossiemoglobina indotta dall’attività neuronale genera una variazione di contrasto nell’immagine dovuta al cosiddetto fenomeno “blood oxygenation level dependent” (BOLD) [4]. Il fenomeno BOLD dipende dalle diverse proprietà magnetiche delle forme ossigenata e deossigenata dell’emoglobina (la deossiemoglobina è paramagnetica, l’ossiemoglobina è leggermente diamagnetica), per cui alla variazione del rapporto locale tra le due forme corrisponde una diversa intensità dell’immagine [4][18]. Grazie al fenomeno BOLD, la fMRI può fornire mappe di attivazione che rivelano le aree cerebrali coinvolte in particolari processi mentali [4].

Nell’ottica della realizzazione di un sistema BCI, uno dei grandi vantaggi della fMRI è l’elevata risoluzione spaziale (circa 2-3mm il lato del voxel [14]), mentre tra gli svantaggi abbiamo la non-portabilità, l’elevata sensibilità rispetto a movimenti della testa e la bassa risoluzione temporale [5][14]. In effetti, la risoluzione temporale della fMRI è di soli 1-2 secondi, cui si aggiungono i fisiologici ritardi delle risposte emodinamiche, che vanno dai 3 ai 6 secondi [5][14].

Per questi motivi, l’uso di fMRI in tecnologie BCI è relativamente recente [5][19], [20].

Spettroscopia nel vicino infrarosso (NIRS)

Anche la spettroscopia nel vicino infrarosso (NIRS, Figura 5), come la fMRI, è un metodo indiretto per l’analisi dell’attività cerebrale. In particolare, la NIRS è un metodo ottico, che sfrutta la radiazione infrarossa per rilevare le variazioni dell’ossigenazione del sangue a seconda dell’attività dell’area analizzata [5]. La stima dell’ossigenazione

è resa possibile dalle proprietà ottiche dell'emoglobina, che assorbe la radiazione infrarossa in modo differente nella forma ossigenata o meno [4]. Il grado di ossigenazione di un tessuto può dunque essere determinato illuminando la porzione e misurando la quantità di luce che emerge, anche perché nell'intervallo di lunghezze d'onda in cui lavora la NIRS (700-900 nm) la pelle, il tessuto e l'osso sono quasi trasparenti, mentre l'emoglobina è molto sensibile [4]. Data la natura del sistema, in cui i sensori vengono appoggiati sullo scalpo, la luce infrarossa penetra all'interno del cranio ad una profondità massima di 1-3 cm, perciò l'analisi non può essere che limitata agli strati più esterni della corteccia [5]. L'informazione spaziale sull'attività della corteccia è ottenuta applicando array multipli di sensori NIRS (optodi) attorno allo scalpo, dando origine a quella che viene anche chiamata DOT, "diffuse optical tomography" [4][5][14].

Nell'ottica della progettazione di un sistema BCI real-time anche la NIRS, come la fMRI, soffre delle limitazioni dovute ai ritardi della risposta emodinamica, anche se la sua risoluzione temporale sarebbe accettabile (dell'ordine dei millisecondi [5]). Inoltre, anche la risoluzione spaziale è piuttosto bassa (circa 1 cm [5]).

Dal lato dei vantaggi, la NIRS presenta un'ottima portabilità, la non invasività e costi piuttosto limitati [5]. In effetti, la fattibilità della detezione di task mentali tramite NIRS è stata già mostrata in alcuni studi [5][21], [22].

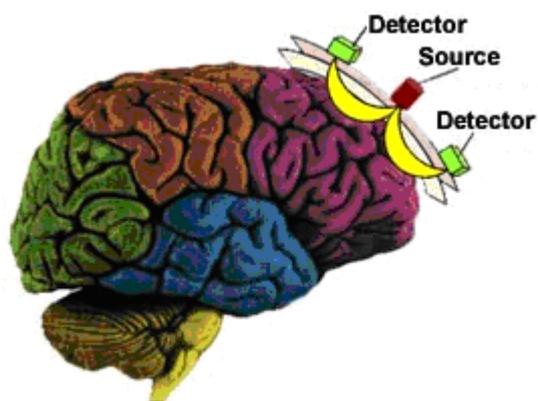


Figura 5: A sinistra: fMRI, a destra: NIRS

La Tabella 1 riassume brevemente le caratteristiche delle modalità di neuroimaging appena descritte. Prima vedere quali siano i segnali di controllo tipicamente utilizzati nei sistemi BCI, si tratterà più estesamente nel prossimo paragrafo il segnale EEG.

Neuroimaging method	Activity measured	Direct/ Indirect Measurement	Temporal resolution	Spatial resolution	Risk	Portability
EEG	Electrical	Direct	~0.05 s	~10 mm	Non-invasive	Portable
MEG	Magnetic	Direct	~0.05 s	~5 mm	Non-invasive	Non-portable
ECoG	Electrical	Direct	~0.003 s	~1 mm	Invasive	Portable
Intracortical neuron recording	Electrical	Direct	~0.003 s	~0.5 mm (LFP) ~0.1 mm (MUA) ~0.05 mm (SUA)	Invasive	Portable
fMRI	Metabolic	Indirect	~1 s	~1 mm	Non-invasive	Non-portable
NIRS	Metabolic	Indirect	~1 s	~5 mm	Non-invasive	Portable

Tabella 1: Tabella riassuntiva delle caratteristiche delle modalità di neuroimaging descritte[5]

1.3 Il segnale EEG

Come già accennato, i segnali EEG vengono ottenuti come differenze di potenziale tra elettrodi posizionati sullo scalpo. Maggiori informazioni sul tipo di elettrodi utilizzabili, sul loro posizionamento e sulle caratteristiche spettrali del segnale EEG possono essere ritrovate nelle seguenti sezioni.

Elettrodi per EEG (passivi o attivi, wet o dry)

L'elettrodo è il mezzo attraverso il quale il potenziale elettrico sullo scalpo viene registrato [23]. Normalmente, gli elettrodi usati in clinica sono costituiti di AgCl [5][23], e necessitano dell'interposizione di gel tra elettrodo e scalpo per abbassare l'impedenza di contatto. Per registrare il segnale in modo accurato, infatti, l'impedenza di contatto elettrodo-cute dovrebbe essere sempre rimanere tra 1 k Ω e 10 k Ω [24], il che può essere ottenuto solo attraverso una corretta preparazione della pelle e con l'interposizione di gel o pasta elettrolitica.

I principali problemi dell'utilizzo di gel/pasta elettrolitica sono l'allungamento dei tempi di preparazione del soggetto, proporzionale al

numeri di canali acquisiti, e la continua manutenzione richiesta per assicurare una buona qualità del segnale [5]. Il progressivo seccarsi del gel, infatti, modifica poco alla volta l'impedenza di contatto, il che influenza negativamente la qualità delle registrazioni [24]. Inoltre, soprattutto nelle configurazioni con elevato numero di canali, occorre prestare attenzione affinché il gel non scivoli anche tra un elettrodo e l'altro, perché questo formerebbe un cortocircuito [24].

Per far fronte a questo tipo di problemi, sono stati introdotti anche elettrodi di tipo *dry*, "a secco", che non necessitano dell'uso di gel [5]. Gli elettrodi del tipo *dry*, dovendo gestire impedenze di contatto elettrodo-cute piuttosto elevate, sono generalmente elettrodi *attivi*, ossia sfruttano una preamplificazione e/o dei buffer direttamente a valle dell'elettrodo [5][25], [26]. La tecnologia degli elettrodi *attivi* si può ad ogni modo trovare anche su elettrodi di tipo *wet*. Naturalmente, il fatto di avere un circuito direttamente a valle di ogni elettrodo aumenta il costo del sistema.

Ricapitolando, possiamo distinguere gli elettrodi da EEG in questo modo:

- a secco (*dry*) oppure con gel (*wet*), a seconda che sia prevista o meno l'interposizione di un mezzo conduttivo per abbassare l'impedenza di contatto
- *attivi* o *passivi*, a seconda della presenza o meno di un circuito di preamplificazione a direttamente sull'elettrodo

In questo lavoro di tesi è stato fatto uso di elettrodi *passivi* di tipo *wet*.

Il Sistema Internazionale 10/20

Nelle registrazioni multicanale, normalmente si segue per il posizionamento degli elettrodi sullo scalpo il Sistema Internazionale 10/20 [27]. Questo sistema utilizza come riferimenti quattro punti di repere anatomico:

- il **nasion**, punto craniometrico situato sulla linea mediana alla radice del naso e identificabile da una piccola depressione [28]

- l'**inion**, punto craniometrico sulla nuca corrispondente alla protuberanza occipitale esterna [28]
- i **punti preauricolari**, piccole depressioni alla radice degli zigomi, subito anteriormente al trago [27]

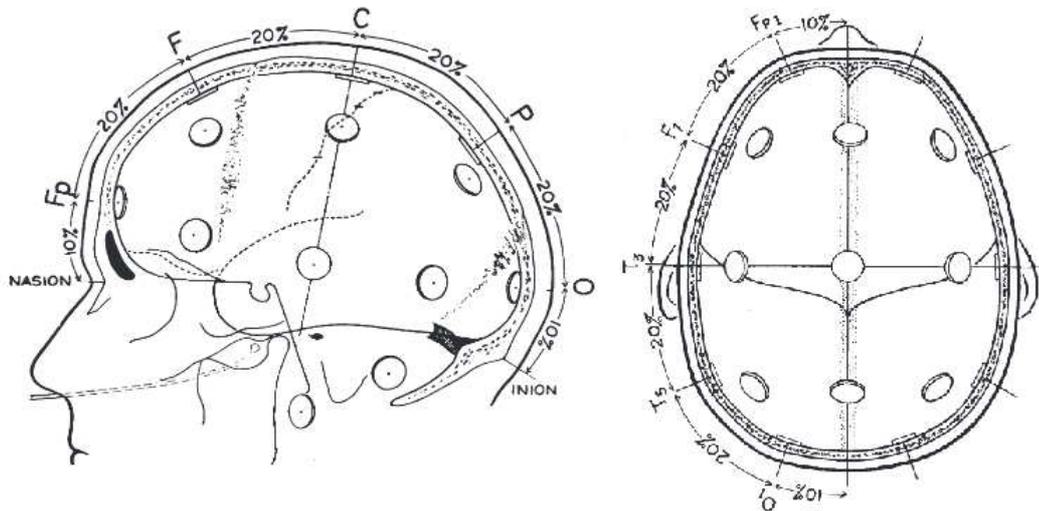


Figura 6 Sistema Internazionale 10/20

Il nome del sistema deriva dal fatto che le posizioni degli elettrodi sono determinate a intervalli del 10% e del 20% della distanze che congiungono i punti nasion-inion e i punti preauricolari destro e sinistro (Figura 6).

Lo standard definisce anche la nomenclatura degli elettrodi. In particolare, il nome di ogni elettrodo inizia con una sigla che dipende dalla localizzazione, per cui avremo A per le localizzazioni auricolari, C per la regione centrale, P per le parietali, F per le frontali, Fp per quelle fronto-polari, O per quelle occipitali. I nomi degli elettrodi sono completati poi da un'appendice, che è un numero pari per gli elettrodi a destra, dispari per gli elettrodi a sinistra, la lettera 'z' (che sta per zero) per gli elettrodi sulla linea mediana [27].

Il Sistema Internazionale 10/20 del 1958 [27] definiva le localizzazioni di 19 elettrodi + 2 sui lobi auricolari. Successivamente, per permettere il posizionamento di più elettrodi, il sistema è stato esteso alle versioni 10/10 e 10/5, per arrivare a definire più di 300 localizzazioni [29], [30]. La versione 10/5 descritta in [30] non è però standardizzata [24].

Per ridurre i tempi di preparazione del soggetto, spesso si utilizzano elettrodi premontati su cuffia già nelle posizioni definite dallo standard.

Spettro del segnale EEG

Due parametri fondamentali per descrivere il segnale EEG sono l'ampiezza e la frequenza delle oscillazioni. In termini di ampiezza, mentre le oscillazioni sulla superficie cerebrale possono anche arrivare alla decina di mV, sullo scalpo le ampiezze registrabili sono dell'ordine del centinaio di μV [31]. Dal punto di vista spettrale, invece, il segnale EEG occupa un range di frequenze compreso tra gli 0.5 e 100 Hz [31]. All'interno di questo range possiamo individuare poi delle sotto-bande (ritmi EEG, Figura 7), di interesse perché correlate a stati fisiologici (sonno, rilassamento, attenzione, concentrazione etc) o patologici (epilessia, tumori, coma etc) [32].

I ritmi EEG sono cinque (theta, delta, alfa, beta e gamma), e saranno brevemente qui descritti.

Ritmi delta (δ): le onde delta hanno frequenza compresa tra 0.5 e 4Hz, ed un'ampiezza normalmente inferiore ai 100 μV [31]. Negli adulti, le onde delta sono associate a stati di sonno profondo, mentre una grande attività in banda delta nello stato di veglia è da considerarsi patologica [5]. Nei bambini, l'ampiezza delle onde delta diminuisce all'aumentare dell'età.

Ritmi theta (θ): le onde theta hanno frequenza compresa tra 4 e 7Hz, e ampiezza normalmente inferiore ai 100 μV [31]. Come il ritmo delta, anche le onde theta sono maggiormente presenti nei bambini, mentre negli adulti sono associate a stati di sonno o di meditazione [5]. In alcuni adulti il ritmo theta è associato anche a stress emotivo, in particolare frustrazione, ad esempio subito dopo l'improvvisa rimozione di uno stimolo piacevole [31].

Ritmi alfa (α): le onde alfa cadono nella banda compresa tra 8 e 13Hz, ed hanno un'ampiezza inferiore a 10 μV [31]. Queste onde si registrano in condizione di veglia, ma indicano uno stato di rilassamento. Nelle aree occipitali, ad esempio, l'ampiezza delle onde alfa aumenta molto quando si chiudono gli occhi, mentre diminuisce drasticamente alla riapertura, oppure se viene fatto uno sforzo mentale

[5]. In particolare, quando il soggetto è attento e concentrato su una specifica attività, alle onde alfa si sostituiscono ritmi a frequenza maggiore [31].

Nello stesso range di frequenze del ritmo alfa ma con localizzazione nell'area della corteccia motoria si rileva anche il ritmo mu, particolarmente interessante perché fortemente correlato sia al movimento, sia alla sua semplice osservazione quando eseguito da altri (grazie ai neuroni specchio [33][34]), sia alla sua sola immaginazione, dopo un po' di addestramento [5][35], [36].

Ritmi beta (β): le onde beta occupano il range di frequenze tra 13 e 30Hz e hanno ampiezza inferiore a 20 μ V [31]. Queste onde si registrano nelle aree frontali, centrali e parietali, e si manifestano durante lo stato di veglia ad occhi aperti quando il soggetto è coinvolto in un'attività mentale [5][31]. I ritmi beta sono anche associati all'attività motoria, e vengono modulati sia durante il movimento reale che con l'immaginazione motoria [35].

Ritmi gamma (γ): i ritmi gamma hanno frequenze maggiori di 30Hz e indicano uno stato di profonda concentrazione [5]. Il ritmo gamma si instaura anche in relazione ad alcune funzioni motorie e durante la contrazione massimale dei muscoli [5]. I ritmi gamma sono meno utilizzati nei sistemi BCI basati su EEG perché maggiormente suscettibili ad artefatti muscolari o elettrooculografici [5].

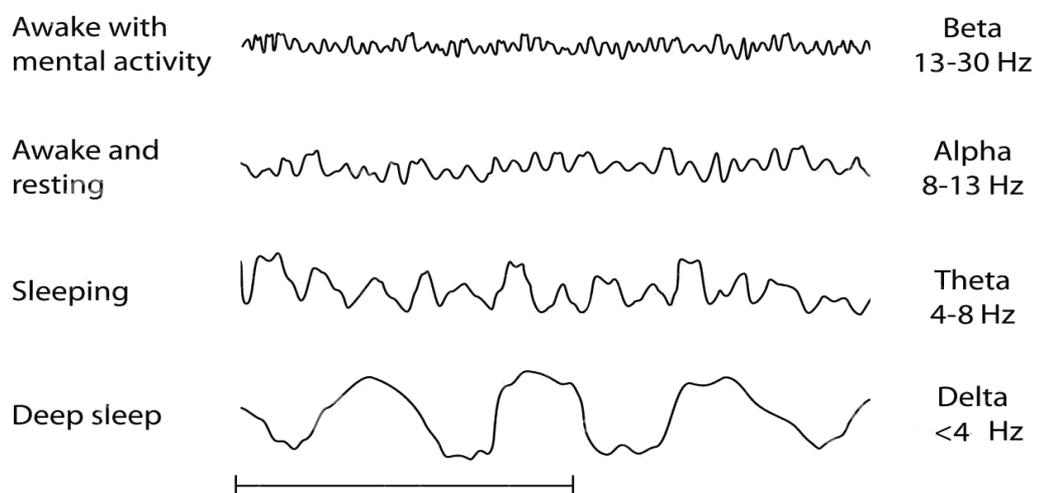


Figura 7. Ritmi EEG

1.4 Segnali di controllo nei sistemi BCI EEG-based

Rispetto al tipo di segnale di controllo utilizzato, possiamo classificare i sistemi BCI in questo modo:

- *esogeni* o *endogeni*, a seconda che sia necessaria o meno la presenza di uno stimolo esterno per indurre la manifestazione del segnale
- *dipendenti* o *indipendenti*, a seconda che il buon funzionamento della BCI necessiti o meno della mediazione delle normali vie d'uscita del sistema nervoso centrale (ad esempio, i muscoli degli occhi per dirigere lo sguardo verso un punto)

In questo paragrafo saranno descritti quattro segnali di controllo tipicamente utilizzati nei sistemi BCI EEG-based: visual-evoked potentials e potenziali evocati P300 (esogeni), Slow Cortical Potentials e ritmi sensorimotori (endogeni). Prima di iniziare questa breve descrizione, è utile accennare i concetti di potenziale evocato (evoked potential, EP) e potenziale evento-correlato (event-related potential, ERP).

Un potenziale evocato (EP) è un segnale rilevabile come variazione dell'EEG che si manifesta in seguito alla presentazione di uno stimolo [37]. I potenziali evocati sono normalmente segnali molto piccoli, perciò richiedono particolari tecniche di filtraggio per essere estratti [37] (ad esempio, la media dei segnali EEG su più ripetizioni dello stimolo).

I potenziali evento-correlati (ERP) sono piccoli cambiamenti dell'attività EEG legati a eventi esterni (come ad esempio un atto motorio) o interni (come ad esempio un pensiero) [38].

Si può a questo punto procedere con la descrizione dei segnali di controllo più comunemente utilizzati nelle BCI EEG-based. In base alle loro caratteristiche, alcuni dei segnali descritti in seguito potranno essere più adatti alla progettazione di sistemi BCI per *comunicazione* oppure per *controllo* (del movimento di carrozzine, di una protesi etc).

Visual Evoked Potentials (VEP)

I Visual Evoked Potentials (VEP) sono potenziali evocati rilevabili sulla corteccia occipitale a seguito della ricezione di uno stimolo visivo [5] e riflettono il processamento dell'informazione visiva da parte del cervello [39]. A seconda della frequenza della stimolazione, possiamo distinguere i potenziali VEP "transienti" (TVEP) dai potenziali VEP "steady-state" (SSVEP) [5]. In particolare, se la frequenza di stimolazione visiva è bassa ($<2\text{Hz}$ [40]), allora il segnale indotto è una risposta transiente, chiamata appunto TVEP. Se invece la stimolazione visiva è ripetuta ad una frequenza superiore ai 6Hz [40], tale per cui l'intervallo di stimolazione è inferiore alla durata di un singolo TVEP, allora le risposte evocate si accavalleranno, e ciò che viene generato è un SSVEP [5][39]. Avendo caratteristiche differenti, i segnali TVEP e SSVEP sono solitamente rilevati con approcci diversi: se da un lato i TVEP possono essere riconosciuti da algoritmi di template-matching [39], la detezione degli SSVEP avviene solitamente attraverso l'analisi spettrale dei segnali, ad esempio stimando la PSD (power spectral density) [39].

Un potenziale TVEP può essere indotto con diverse strategie, purché queste comportino cambiamenti nel campo visivo [5]. In particolare, gli stimoli utilizzati possono essere di due tipi:

- stimoli *flash*, se sono emessi da punti luminosi che lampeggiano
- stimoli *pattern*, se prevedono o la comparsa/scomparsa improvvisa di un pattern sul background, o l'inversione del pattern (ad esempio, una scacchiera) [41]

Chiaramente, le risposte evocate sono diverse a seconda del tipo di stimolo presentato [5].

I segnali SSVEP sono indotti dagli stessi stimoli visivi dei TVEP, ma ripetuti nel tempo. Ad esempio, se lo stimolo è di tipo flash, l'SSVEP tende ad assomigliare a una sinusoide con frequenza fondamentale uguale a quella di stimolazione [5], perciò un'analisi dello spettro del segnale riesce ad individuarlo.

Grazie alle loro caratteristiche, gli SSVEP possono essere sfruttati in ambito BCI ad esempio per la selezione di bottoni/lettere. In

particolare, se i bottoni sono fatti lampeggiare con frequenze diverse, sarà possibile identificare quale sia quello che il soggetto sta fissando andando ad analizzare lo spettro del segnale. Esempi di sistemi di questo tipo sono quelli di Middendorf et al. del 2000 [42] e di Gao et al. del 2003 [40], che utilizzava una griglia di 48 stimolatori LED.

Uno dei vantaggi dei sistemi BCI VEP-based è che questi richiedono pochissimo training [5]. D'altra parte, i sistemi VEP-based richiedono spesso che l'utente sia in grado di fissare lo sguardo in un punto, il che esclude l'utilizzo su pazienti allo stadio avanzato di SLA, non più in grado di controllare i muscoli del collo e degli occhi [5][43]. Per questo motivo, i sistemi BCI VEP-based sono generalmente considerati sistemi *dipendenti*. In realtà, diversi studi [44]–[46] hanno mostrato che i VEP possono essere modulati anche dalla sola attenzione prestata verso un determinato punto nello spazio, in modo quindi *indipendente* dalla funzione neuromuscolare [43].

Per le loro caratteristiche, i sistemi BCI VEP-based possono essere adatti sia per la comunicazione (attraverso ad esempio la selezione di lettere sullo schermo [47]) sia per il controllo di carrozzine [48][49] o anche di protesi [50].

Potenziali evocati P300

I potenziali evocati P300 si manifestano come piccoli picchi positivi a seguito di stimoli infrequenti di tipo visivo, somatosensoriale o auditivo [5], quando questi sono interposti a stimoli più frequenti o di routine [43]. I potenziali evocati P300 sono rilevabili sulla corteccia parietale [43], circa 300 ms dopo lo stimolo “strano”.

MESSAGE					
BRAIN					
Choose one letter or command					
A	G	M	S	Y	*
B	H	N	T	Z	*
C	I	O	U	*	TALK
D	J	P	V	FLN	SPAC
E	K	Q	W	*	BKSP
F	L	R	X	SPL	QUIT

Figura 8: Matrice di simboli utilizzata nella BCI di Farwell e Donchin del 1988. In alto la parola composta “B-R-A-I-N”

Per spiegare come i potenziali P300 possano essere usati in una BCI, si prenderà come esempio uno dei primi sistemi BCI di questo tipo, di Farwell e Donchin del 1988 [51]. Nel sistema, su uno schermo veniva mostrata una matrice 6x6 di simboli, che potevano essere lettere o brevi comandi come “space” o “backspace” (Figura 8). Le righe e le colonne della matrice lampeggiavano una alla volta ogni 125 ms [43], mentre all’utente veniva chiesto di prestare attenzione contando quante volte la riga o la colonna contenente il simbolo desiderato era illuminata. Dal momento che l’evento “la riga/colonna di interesse lampeggia” è un evento improbabile frapposto a tanti più probabili, quando queste si illuminavano si manifestava il potenziale P300, il che rendeva possibile capire quale fosse il simbolo desiderato [43][51]. In generale, le BCI basate su P300 sviluppate anche in seguito presentano un funzionamento di base analogo a quello di Farwell e Donchin [5]. In persone con problemi alla vista, anche stimoli di tipo auditivo sono stati tentati [52].

Uno dei vantaggi delle BCI basate su P300 è che queste non richiedono training [5]. Più è “improbabile” lo stimolo e più è grande è l’ampiezza della P300 [53] tuttavia, se l’utente si abitua agli stimoli “infrequenti”, si ridurrà l’ampiezza della P300 e le performance della BCI potrebbero peggiorare [5][54]. Un altro svantaggio dei sistemi BCI P300-based è il ridotto flusso di informazione in uscita, che permette la selezione di solo pochi caratteri al minuto [5]. In effetti, data la piccola entità del picco P300, per identificarlo occorre che le righe/colonne lampeggino più volte per ogni scelta, in modo da poter fare una media tra più ripetizioni cancellando così i contributi EEG non in fase [5]. Negli anni, per migliorare l’accuratezza delle BCI basate su P300 sono stati proposte diverse strategie [5], tra cui quella di impiegare algoritmi più complessi della semplice media tra epoche per evidenziare i potenziali evocati [55], variare la dimensione e il colore dei simboli nella matrice di selezione [56], utilizzare algoritmi a correzione d’errore [57].

Nonostante il ridotto flusso d’informazione permesso dal segnale P300, oltre che nelle BCI per la comunicazione (come in [51]) il

segnale è stato negli anni utilizzato anche per il controllo di carrozzine (come ad esempio in [58]).

Slow Cortical Potentials (SCP)

Gli Slow Cortical Potentials (SCP) sono piccole e lente variazioni del potenziale corticale che durano da 300ms a qualche secondo [59], rilevabili anche tramite EEG [5][43]. In particolare, gli SCP fanno parte dello spettro EEG <1Hz [5]. Questi lenti shift di potenziale sono legati a cambiamenti del livello di attività corticale [5], tali per cui SCP negativi corrispondono ad un'aumentata attività, mentre shift positivi si associano ad una ridotta attivazione della corteccia [43]. Attraverso l'addestramento, è possibile sia per pazienti sani che paralizzati imparare a controllare volontariamente gli SCP, che possono essere così impiegati come segnali di controllo in sistemi BCI [5][43], ad esempio per muovere un cursore su uno schermo [59].

Uno dei gruppi più attivi nell'ambito dei sistemi BCI basati su SCP è quello di Birbaumer et al, di cui si ricorda qui il dispositivo "Thought Translation Device" (TTD) del 2000 [59]. Nella pubblicazione [59] viene descritto il TTD e i risultati ottenuti su cinque pazienti totalmente paralizzati. Il sistema TTD era utilizzato sia per il training della persona (in regime di condizionamento operante) sia per la comunicazione, una volta che l'accuratezza della classificazione avesse superato stabilmente il 75% [59]. Il sistema prelevava il segnale EEG da 5 elettrodi sullo scalpo, ed era completato da un dispositivo di rilevamento del movimento oculare per rimuovere questo tipo di artefatto. Durante una prima fase di training, il soggetto imparava a controllare sia gli shift SCP positivi che negativi attraverso la visualizzazione del movimento verticale di un cursore sullo schermo, rinforzato positivamente anche da una faccina sorridente che compariva ogniqualvolta un target presentato in alto o in basso fosse raggiunto. Dopo questa prima fase, veniva chiesto alla persona se si trovasse meglio ad utilizzare come segnale di controllo l'SCP positivo oppure negativo [59], continuando di conseguenza il training fino ad arrivare alla fase di "free spelling". In quest'ultima fase, la lettera veniva

selezionata dimezzando di volta in volta l'alfabeto, fino ad arrivare al carattere desiderato [59]. Di cinque pazienti testati, tre sono arrivati alle fasi di spelling, uno di questi dopo qualche settimana di training mentre gli altri due dopo alcuni mesi [59]. Con un programma di questo tipo, l'utente che presentava un'accuratezza compresa tra il 65% e il 90% poteva scrivere da 0.15 fino a 3 lettere al minuto [43], e la velocità di scrittura poteva essere eventualmente migliorata applicando algoritmi di predizione delle parole più probabili basati sulle prime lettere digitate [59].

In generale, anche se il successo del training SCP dipende da numerosi fattori, tra cui ad esempio lo stato psicologico del paziente, la motivazione e il contesto sociale [5], e nonostante il flusso di informazione relativamente basso fornito da un sistema BCI SCP-based, questo segnale di controllo rimane comunque utile per permettere la comunicazione a pazienti locked-in in maniera non invasiva [43].

Ritmi sensorimotori e protocollo Motor Imagery

Sono comunemente chiamati “ritmi sensorimotori” le oscillazioni del segnale EEG rilevabili nelle aree prossime alla corteccia motoria e sensoriale primarie, e che occupano le bande mu (8-13Hz) e beta (13-30Hz). I ritmi sensorimotori hanno come caratteristica quella di essere modulati in corrispondenza di un qualsiasi task motorio, ma il grande successo di questi ritmi in ambito BCI deriva dal fatto che un soggetto può apprendere come controllarli anche senza la necessità di un vero movimento [5]. In particolare, è stato ampiamente provato da numerosi studi ([35], [36], [60], [61]...) che è possibile innescare anche tramite la sola immaginazione del movimento (*motor imagery*), cambiamenti del pattern dei ritmi sensorimotori simili a quelli che si ottengono con il movimento reale [5][43].

Le modulazioni dei ritmi sensorimotori che risultano da una stimolazione sensoriale, da un atto motorio o dalla sua immaginazione possono essere di due tipi, chiamati *event-related desynchronization* (ERD) e *event-related synchronization* (ERS) dei ritmi mu e beta [62].

In particolare, gli ERD si associano ad una diminuzione dell'ampiezza dei ritmi, mentre gli ERS sono legati ad un aumento [62]. Le dinamiche delle oscillazioni cerebrali possono formare pattern spaziotemporali anche complessi, per cui in una specifica locazione possono verificarsi contemporaneamente ad esempio desincronizzazioni alle basse frequenze e sincronizzazioni alle alte frequenze [62].

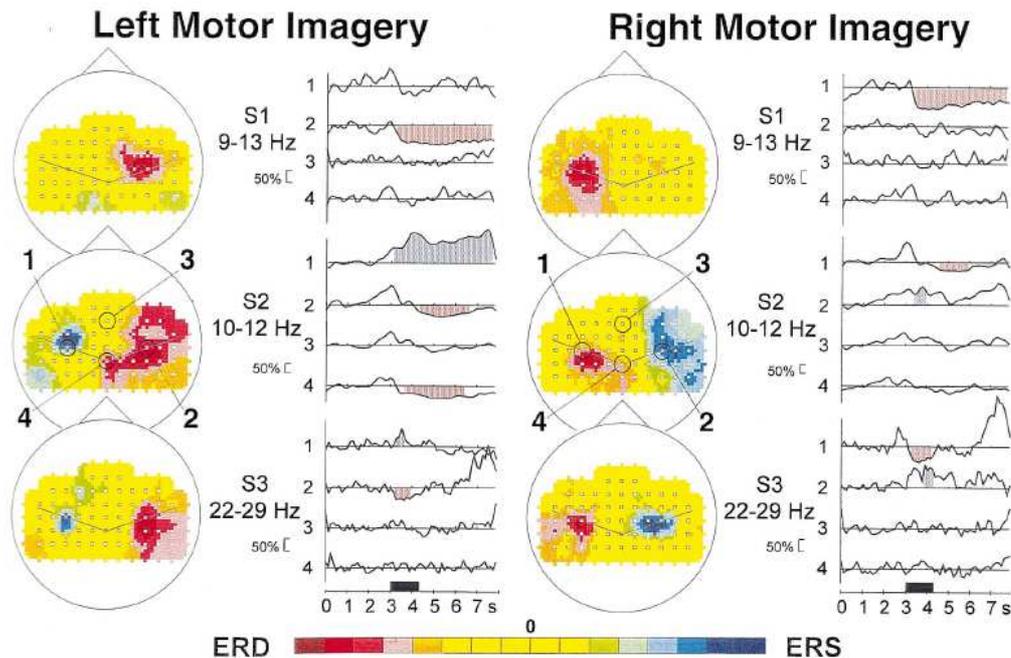


Figura 9. ERD ed ERS nei tre soggetti dello studio di Pfurtscheller e Neuper [61] durante l'immaginazione motoria della mano destra o sinistra.

Una caratteristica nota del movimento volontario è che questo induce la desincronizzazione ERD dei ritmi mu e beta sensorimotori [61]. In particolare, la desincronizzazione inizia circa 2 secondi prima dell'atto motorio nell'emisfero controlaterale, e diventa simmetrica con l'esecuzione del movimento [61]. Poiché, come accennato precedentemente, l'immaginazione motoria coinvolge funzioni e regioni cerebrali simili a quelli attivi nella programmazione e preparazione dei movimenti veri [60][62], anche durante l'immaginazione motoria si può osservare una desincronizzazione ERD in banda mu e beta nell'emisfero controlaterale [61]. Non solo, la desincronizzazione ERD si accompagna spesso ad una sincronizzazione ERS nell'emisfero ipsilaterale, a simili componenti di frequenza

[61][63]. Un'importante caratteristica di queste oscillazioni è inoltre la precisa organizzazione somatotopica [62], motivo per cui i pattern associati all'immaginazione del movimento di una mano, ad esempio, saranno distinguibili (e simmetrici) rispetto a quelli associati all'immaginazione del movimento dell'altra. Per capire meglio questo concetto, in Figura 9 sono riportati come esempio i tre soggetti dello studio [61] durante l'immaginazione motoria della mano destra e della mano sinistra. Per ognuno dei soggetti è stata riportata la banda di frequenza all'interno della quale si evidenziavano le maggiori differenze tra le due immaginazioni. Si noti come per il primo soggetto sia ben visibile solo l'ERD nell'emisfero controlaterale al movimento, mentre per gli altri due sia accennata anche l'ERS nell'emisfero ipsilaterale.

Data la localizzazione degli ERD ed ERS sulle aree sensori motorie, per registrare in modo appropriato questi cambiamenti è utile posizionare gli elettrodi in prossimità di queste aree [63]. Anche se gli elettrodi solitamente ritenuti più interessanti per lo studio dell'immaginazione motoria della mano destra vs sinistra sono C3 e C4 [63][59], è ragionevole pensare che più segnali si registrano dalle aree prossime alla corteccia motoria (e sensoriale) primaria e più possa migliorare, in teoria, l'accuratezza di classificazione dei due stati mentali [63]. Naturalmente, più segnali si sceglie di registrare e più diminuisce la portabilità del sistema BCI, dato il maggiore ingombro degli elettrodi e i tempi di preparazione proporzionalmente più lunghi.

Uno degli svantaggi dei sistemi BCI di questo tipo è che richiedono il training del soggetto, poiché il controllo volontario dei ritmi sensorimotori non è immediato e molte persone trovano difficile l'immaginazione motoria [5]. Tuttavia, l'indipendenza della BCI e l'endogenicità del segnale, una volta completato l'addestramento, giustificano il grande interesse verso questo tipo di controllo. Sistemi molto noti come la Graz BCI [64], Berlin BCI [65] e Wadsworth BCI [66] impiegano infatti i ritmi sensorimotori come segnali di controllo [5]. Infine, essendo i ritmi sensorimotori segnali versatili e veloci,

possono essere impiegati con successo sia per il controllo sia di carrozzine [67] che di cursori nello spazio sia 2D [68] che 3D [69].

1.5 Il presente lavoro di tesi

All'interno del presente lavoro di tesi è stato sviluppato il software per la realizzazione di un sistema BCI non invasivo basato su segnale EEG.

L'obiettivo di questo particolare studio era quello di permettere il controllo del movimento di un modello di arto superiore, visualizzato su uno schermo. Poiché il grado di libertà del modello è uno solo (movimento verso l'alto oppure verso il basso), sono necessari due soli stati mentali, associati a diversi pattern EEG. Si è scelto di utilizzare il protocollo motor imagery, e di impiegare come stati mentali l'immaginazione del movimento della mano destra vs mano sinistra.

Maggiori dettagli sui metodi utilizzati e sui soggetti testati all'interno del presente lavoro di tesi saranno forniti nel prossimo capitolo.

2. Materiali e Metodi

2.1 Acquisizione e processing del segnale

In questa sezione sarà descritto l'hardware tramite il quale il segnale EEG è stato acquisito, il numero di elettrodi utilizzati e la loro configurazione. Successivamente, si passerà a descrivere i diversi step di condizionamento del segnale, dal preprocessing tramite filtraggio spaziale e temporale alla classificazione. Grazie a questi elementi, sarà possibile nel prossimo paragrafo spiegare come sia organizzato il software sviluppato in questo lavoro di tesi.

Acquisizione dei segnali

Per l'acquisizione del segnale EEG è stato impiegato l'amplificatore Brainbox EEG-1166 (Braintronix), in grado di acquisire contemporaneamente fino a 64 canali. All'interno dell'amplificatore, ogni canale veniva digitalizzato separatamente e contemporaneamente (non è dunque stato necessario il ri-allineamento temporale) con un campionamento a 32768 Hz e 16 bit di risoluzione. Il segnale poteva essere poi successivamente sottocampionato ad una frequenza di campionamento scelta, che in questo lavoro di tesi era di 128 Hz.

Per l'acquisizione sono stati utilizzati elettrodi da EEG *passivi* in Ag/AgCl di tipo *wet* (si è dunque reso necessario l'uso di gel elettrolitico per la riduzione delle impedenze di contatto), premontati su cuffia in accordo al Sistema Internazionale 10/20 esteso [29]. Siccome in questo lavoro di tesi si sono utilizzati come segnali di controllo i ritmi sensorimotori e la strategia scelta era quella dell'immaginazione motoria della mano destra vs sinistra, gli elettrodi acquisiti sono stati tutti posizionati nell'area sovrastante la corteccia motoria/sensoriale primaria. In particolare, sono stati acquisiti in totale

11 elettrodi + l'elettrodo di riferimento (lobo auricolare destro) e l'elettrodo di massa. Gli undici elettrodi acquisiti (evidenziati in Figura 10) erano Fc5, Fc1, Fc2, Fc6, C3, Cz, C4, Cp5, Cp1, Cp2 e Cp6.

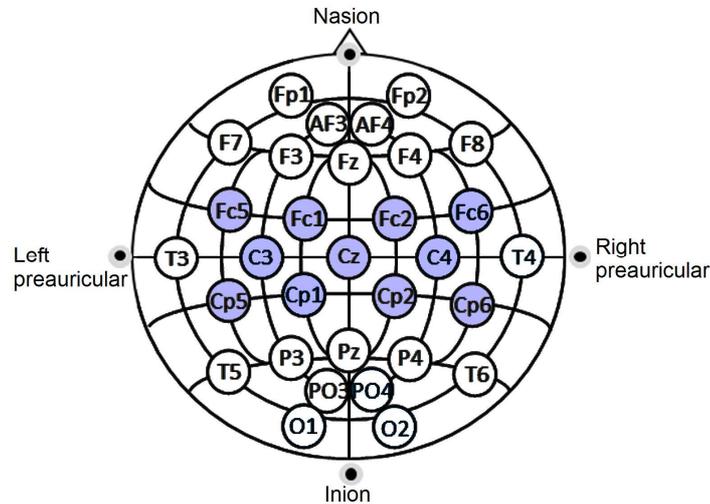


Figura 10 Gli 11 elettrodi acquisiti per il controllo del sistema BCI

Re-referencing con CAR (Common Average Reference) modificato

Il primo processing subito dai segnali EEG acquisiti era una re-referenziazione, poiché nel 1997 McFarland et al. asserirono [70] che i migliori montaggi per sistemi BCI basati sui ritmi sensorimotori erano il *Large Laplacian* e il *Common Average Reference (CAR)*.

Applicare il filtro *Large Laplacian* significa stimare la derivata seconda spaziale della distribuzione di potenziale sullo scalpo sottraendo ad ogni locazione la media dei potenziali nelle 4 locazioni di contorno, saltando in ogni direzione la locazione più prossima (Figura 11). Applicare il filtro spaziale CAR significa invece sottrarre alla tensione misurata in ogni locazione la media delle tensioni di tutti gli elettrodi registrati, supposti equamente distribuiti sullo scalpo (Figura 11), e con l'opzione di includere o meno l'elettrodo posizionato sul lobo auricolare. Secondo McFarland et al [70], il motivo per cui il *Large Laplacian* e il CAR sono migliori rispetto al normale riferimento auricolare è che questi due metodi si comportano come filtri spaziali passa-alto, che enfatizzano dunque l'attività focalizzata dalle sorgenti EEG locali mentre al contempo riducono le attività largamente

distribuite, come quelle dovute agli artefatti (es. artefatto muscolare, movimenti oculari e blinking, ritmo alfa visivo, ECG) [70].

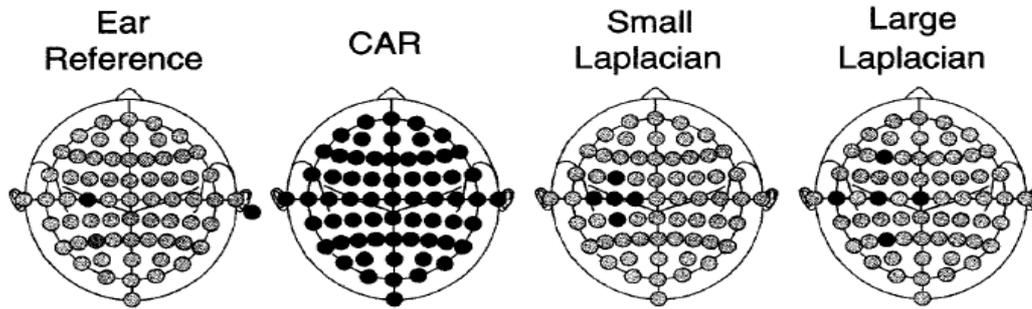


Figura 11. I montaggi Ear Reference, CAR, Small Laplacian e Large Laplacian.

Nel sistema sviluppato in questo lavoro di tesi, avendo scelto di impiegare solamente 11 elettrodi + il riferimento auricolare per questioni di aumentata portabilità, il segnale EEG è stato re-referenziato con un “CAR modificato”. In particolare, invece di utilizzare per il CAR elettrodi distribuiti su tutto lo scalpo, si sono impiegati solamente gli 11 elettrodi acquisiti, decidendo però di includere anche la tensione rilevata sull’orecchio destro. Il motivo dell’inclusione dell’elettrodo auricolare dipende dal fatto che in questo modo, una volta che il segnale sia stato re-referenziato, comunque le sequenze temporali relative agli 11 elettrodi sullo scalpo sono ancora linearmente indipendenti. L’indipendenza dei segnali è un aspetto molto importante, come sarà chiarito in seguito, dal momento che in questo lavoro di tesi si fa uso del metodo CSP (Common Spatial Pattern).

Si è ritenuto che il metodo “CAR modificato” fosse una scelta ragionevole dal momento che, per come è implementato, ci si aspetta che il suo comportamento come filtro spaziale sia intermedio tra un *Large Laplacian* e un CAR tradizionale (ritenuti da McFarland et al [70] i migliori filtri per questo tipo di applicazione). Ricapitolando, ogni segnale sullo scalpo è stato dunque re-referenziato come segue:

$$V_{iCAR} = V_i - \frac{1}{n+1} \left(\sum_{i=1}^n V_i + V_{auricolare} \right) \quad (1)$$

con $n=11$ (numero di elettrodi acquisiti).

Un ultimo aspetto da sottolineare quando si applicano filtri tipo il CAR o il Laplaciano, come raccomandato McFarland et al. nel loro studio [70], è che questi funzionano meglio se tutti i canali sono allineati temporalmente. Questo significa che, nel caso in cui i segnali siano digitalizzati in modo sequenziale tramite MUX (multiplexer), è raccomandabile un ri-allineamento temporale tramite interpolazione. In questo lavoro di tesi si è tenuto conto di questo aspetto ma il ri-allineamento non è stato necessario, poiché l'hardware a disposizione permetteva la digitalizzazione simultanea dei canali.

Filtraggio temporale

Dopo la re-referenziazione tramite CAR modificato, gli 11 segnali relativi agli elettrodi sullo scalpo venivano filtrati in frequenza nella banda 8-30Hz. Il filtraggio era eseguito tramite un filtro di Butterworth passa-banda di ordine 8.

La scelta di filtrare in questo modo dipende dal fatto che nella banda 8-30Hz sono contenute tutte le componenti di frequenza μ e β interessanti per la discriminazione degli stati mentali. Inoltre, Müller e Gerking [71] hanno mostrato che l'accuratezza di classificazione del movimento della mano destra e della mano sinistra possono essere migliorate utilizzando interamente questa larga banda passante, piuttosto che utilizzare bande più ristrette (come ad esempio le banda α (8-13Hz) e β alta (19-30Hz)) [63].

Il metodo CSP

Uno dei possibili approcci alla classificazione di dati EEG multi-canale relativi a diverse immaginazioni motorie prevede l'uso dell'algoritmo Common Spatial Pattern (CSP). L'applicazione del metodo CSP in quest'ambito fu suggerita per la prima volta da Ramoser [72] nel 2000 [73].

L'idea di base del metodo CSP è quella di trovare una matrice W che permetta di proiettare i dati EEG multi-canale in un nuovo spazio, all'interno del quale i segnali presentino massima differenza di varianza tra una classe e l'altra [73]. In particolare, chiamando X la

matrice $N \times T$ dei segnali EEG eventualmente preprocessati (con N numero di canali, T numero di campioni per ogni canale), la matrice di proiezione W trasforma X in Z in questo modo:

$$Z = WX \quad (2)$$

Le righe della matrice W contengono i diversi pesi dati agli elettrodi registrati, mentre i segnali in Z sono le nuove serie temporali sulla base delle quali verrà fatta la classificazione degli stati mentali [73].

Per ottenere la matrice W , il metodo CSP prevede la simultanea diagonalizzazione delle matrici di covarianza normalizzate medie relative alle due classi di segnali. In particolare, date due matrici di segnali EEG multicanale X_R e X_L relative alle classi “R” (right) e “L” (left) con segnali a valor medio nullo, entrambe di dimensione $N \times T$, le corrispondenti matrici di covarianza normalizzate si calcolano come:

$$R_R = \frac{X_R X_R^T}{\text{traccia}(X_R X_R^T)} \quad \text{e} \quad R_L = \frac{X_L X_L^T}{\text{traccia}(X_L X_L^T)} \quad (3)$$

dove naturalmente X^T è la trasposta della matrice X e $\text{traccia}(A)$ calcola la somma degli elementi della diagonale di A .

Le matrici di covarianza normalizzate medie \bar{R}_R e \bar{R}_L si calcolano a questo punto mediando i valori di R_R e di R_L rispetto alle varie ripetizioni di ciascuna classe. A partire dalle matrici di covarianza normalizzata medie \bar{R}_R e \bar{R}_L è possibile ora definire la matrice di covarianza composita R , che deve essere diagonalizzata:

$$R = \bar{R}_R + \bar{R}_L = U_0 \Sigma U_0^T \quad (4)$$

dove U_0 è la matrice di autovettori di R , mentre Σ è la matrice diagonale dei corrispondenti autovalori, con ordinamento decrescente.

La matrice di sbiancamento P della matrice R , ottenibile come:

$$P = \sqrt{\Sigma^{-1}} U_0^T \quad (5)$$

permette ora di trasformare le matrici medie di covarianza normalizzata \bar{R}_R e \bar{R}_L nelle matrici S_R e S_L :

$$S_R = P \bar{R}_R P^T \quad \text{e} \quad S_L = P \bar{R}_L P^T \quad (6)$$

Le matrici S_R e S_L hanno la proprietà di condividere gli stessi autovettori (matrice U), mentre la somma dei corrispondenti autovalori per le due matrici sarà sempre pari a 1, ossia:

$$S_R = U\Sigma_R U^T \quad S_L = U\Sigma_L U^T \quad \Sigma_L + \Sigma_R = I \quad (7)$$

Dal momento che la somma dei due corrispondenti autovalori in Σ_R e Σ_L è sempre pari a uno, ciò significa che gli autovettori con i maggiori autovalori in S_R corrispondono a quelli con i minori autovalori in S_L , e viceversa. Questa proprietà rende gli autovettori in U utili per la classificazione delle due distribuzioni [72]. In effetti, la proiezione dell'EEG sbiancato con P sul primo e sull'ultimo autovettore di U (ossia, i due autovettori corrispondenti rispettivamente ai massimi autovalori λ_R e λ_L), fornirà dei vettori di feature che saranno ottimi per la discriminazione delle due popolazioni nel senso dei minimi quadrati [72]. Dunque, la matrice di proiezione W cercata dall'algoritmo CSP si ottiene a questo punto come:

$$W = U^T P \quad (8)$$

Con la matrice di proiezione W , il segnale originale EEG può essere trasformato nelle componenti scorrelate Z (Equazione (2), $Z=WX$). Il segnale originale EEG può poi naturalmente essere ricostruito a partire da Z in questo modo:

$$X = W^{-1}Z \quad (9)$$

dove la matrice W^{-1} è l'inversa di W , e le colonne di W^{-1} sono i cosiddetti "spatial pattern". Gli spatial pattern possono essere considerati come vettori di distribuzione delle sorgenti EEG tempo-invarianti [72][73]. La prima e l'ultima colonna di W^{-1} sono i più importanti spatial pattern, che spiegano la massima varianza di un task contemporaneamente alla minima varianza dell'altro [73].

Si noti come la matrice di sbiancamento P preveda l'inversione della matrice Σ . Questo è il motivo per cui, come già accennato nel precedente paragrafo, è importante che i segnali relativi ai canali acquisiti rimangano linearmente indipendenti anche dopo eventuali filtraggi temporali e/o spaziali. Se così non fosse, almeno uno degli

autovalori sulla diagonale di Σ sarebbe nullo, da cui deriva che $\det(\Sigma)=0$ e dunque che Σ non è invertibile.

Feature Selection

Per costruzione, la varianza della prima riga di \mathbf{Z} è massima per l'immaginazione motoria della mano destra, e diminuisce gradualmente nelle successive righe. Viceversa, la varianza della prima riga di \mathbf{Z} sarà minima per l'immaginazione motoria della mano sinistra, aumentando a mano a mano nelle seguenti righe [63]. Da questo deriva naturalmente che le varianze dei segnali in \mathbf{Z} saranno massimamente differenti tra i due task di immaginazione motoria nelle primissime e nelle ultimissime righe della matrice [63].

Per la classificazione dei due stati mentali, saranno proprio le varianze delle nuove serie temporali in \mathbf{Z} ad essere utilizzate, non necessariamente tutte, ma solo le più significative. In particolare, Müller e Gerking [71] si sono chiesti quale fosse il numero ottimale di proiezioni per la costruzione del vettore di features, concludendo che questo numero è quattro (ossia le prime due e le ultime due righe di \mathbf{Z}) [63]. Considerando dunque N canali EEG acquisiti, il vettore di varianze utilizzato in questo lavoro di tesi è:

$$VAR = [\sigma_1^2 \quad \sigma_N^2 \quad \sigma_2^2 \quad \sigma_{N-1}^2] \quad (10)$$

in cui:

$$\sigma_i^2 = \sum_{t=1}^T (z_i(t))^2 \quad (11)$$

sempre perché, dato il filtraggio temporale nella banda 8-30Hz, i segnali hanno valor medio nullo.

Dal vettore di varianze di dimensione $d=4$, si è ottenuto dunque il vettore di features f in questo modo:

$$f = \log\left(\frac{VAR}{\sum_{d=1}^4 VAR_d}\right) \quad (12)$$

la divisione di ogni elemento di VAR per la somma delle varianze e la trasformazione logaritmica del rapporto servono per normalizzare la

distribuzione degli elementi di f [63]. I vettori di features così estratti possono essere a questo punto utilizzati per addestrare un classificatore lineare [63], che in questo lavoro di tesi è un SVM (Support Vector Machine).

Classificatore Lineare Support Vector Machine (SVM)

Il classificatore scelto in questo lavoro di tesi è il Support Vector Machine (SVM) lineare [74][75][76].

L'idea di base del classificatore SVM lineare è quella di cercare di determinare l'iperpiano di separazione ottimo, in grado di separare *al meglio* (ovvero, con il maggior *margin* possibile) le classi, senza alcuna assunzione sulla densità di probabilità delle stesse [74].

Iniziamo dal caso più semplice, ossia quello di dati linearmente separabili. Date due classi di pattern linearmente separabili e un training set di n campioni:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)$$

dove $\mathbf{x}_i \in \mathcal{R}^d$ sono i pattern e $y_i \in \{+1, -1\}$ sono le label, esistono normalmente diversi iper-piani in grado di separare le due classi di pattern. L'iperpiano di separazione può essere ora descritto da due parametri, \mathbf{w} e b , con \mathbf{w} vettore normale all'iperpiano e $|b|/||\mathbf{w}||$ distanza dell'iperpiano dall'origine (Figura 12), dove con $||\cdot||$ si intende la norma euclidea [74][75].

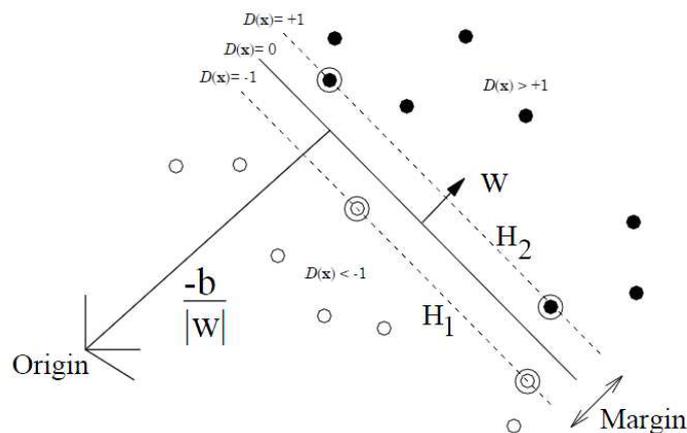


Figura 12. Iperpiani di separazione per il caso linearmente separabile. I support vectors sono cerchiati.

L'equazione:

$$D(\mathbf{x}) = \mathbf{w} \cdot \mathbf{x} + b = 0 \quad (13)$$

descrive dunque il luogo dei punti \mathbf{x} che appartengono all'iperpiano di separazione. Non imponendo inoltre la norma unitaria al vettore \mathbf{w} normale, allora la distanza di un generico pattern \mathbf{x}_p dall'iperpiano è esprimibile come:

$$r = (\mathbf{w} \cdot \mathbf{x}_p + b) / \|\mathbf{w}\| = D(\mathbf{x}_p) / \|\mathbf{w}\| \quad (14)$$

La famiglia di iperpiani descritti da (\mathbf{w}, b) in grado di separare i pattern del problema sia ora quella per cui:

$$\begin{aligned} \mathbf{w} \cdot \mathbf{x}_i + b &\geq 1 \text{ se } y_i = +1 \\ \mathbf{w} \cdot \mathbf{x}_i + b &\leq -1 \text{ se } y_i = -1 \quad \forall i \text{ con } i=1, 2, \dots, n \end{aligned} \quad (15)$$

o, in forma più compatta:

$$y_i \cdot (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \quad \forall i \text{ con } i=1, 2, \dots, n \quad (16)$$

mentre i pattern più vicini all'iperpiano di separazione, sia da una parte che dall'altra, sono quelli giacenti o su H_1 o su H_2 (Figura 12), luoghi dei punti per cui vale:

$$|D(\mathbf{x})| = 1 \quad \text{ossia} \quad r = 1 / \|\mathbf{w}\| \quad (17)$$

Si definisce **margin** (Figura 12) la distanza tra i due iperpiani H_2 (corrispondente a $D(\mathbf{x})=1$) e H_1 (corrispondente a $D(\mathbf{x})=-1$), pertanto il margine corrisponde formalmente a:

$$\text{margin} = 2 / \|\mathbf{w}\| \quad (18)$$

Nella teoria SVM, l'iperpiano ottimo di separazione è quello che soddisfa i vincoli dei pattern mentre al contempo *massimizza il margine*. Per trovare l'iperpiano ottimo (\mathbf{w}, b) occorre dunque risolvere il seguente problema di ottimizzazione:

Massimizzare: $2 / \|\mathbf{w}\|$
 Vincolo: $y_i \cdot (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 \quad \forall i \text{ con } i=1, 2, \dots, n$

Questo problema può essere più agevolmente risolto passando attraverso una formulazione Lagrangiana e utilizzando le condizioni di Karush-Kuhn-Tucker, come spiegato in dettaglio nel documento [75].

I pattern del training set che giacciono sul margine (cerchiati in Figura 12) sono detti *support vector*. Uno dei vantaggi del classificatore SVM è dunque quello per cui la soluzione finale sarà funzione solo di questi pattern, indipendentemente dal numero di elementi n del training set [74]. In questo modo, si riduce la complessità del calcolo della soluzione.

Per scongiurare l'ipotesi che l'algoritmo di ricerca dell'iperpiano SVM fallisca perché non tutti i pattern sono perfettamente separabili, è possibile rilassare i vincoli di separazione, per far sì che alcuni pattern (comunque il minimo possibile) possano valicare il confine della classe [74]. Per fare questo, si introducono n variabili di slack $\xi_i \geq 0$, una per ogni pattern, e si modifica il vincolo in questo modo:

$$y_i \cdot (\mathbf{w} \cdot \mathbf{x} + b) \geq 1 - \xi_i \quad \text{con } i=1, 2, \dots, n \quad (19)$$

Una rappresentazione grafica di quanto appena detto può essere ritrovata in (Figura 13).

Per ciascuno dei pattern \mathbf{x}_i del training set, la variabile di slack $\xi_i \geq 0$ codifica la deviazione dal margine [74], per cui per i pattern del training set separabili la variabile di slack sarà nulla, riconducendosi in questo modo al caso precedente [74].

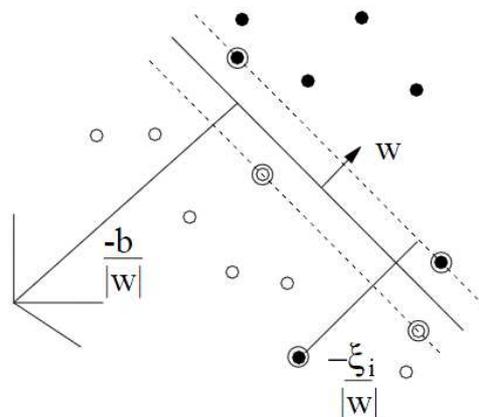


Figura 13 Classificatore SVM lineare nel caso di pattern non linearmente separabili

In questa estensione, la teoria SVM indica che l'iperpiano ottimo è quello che contemporaneamente *massimizza il margine* e allo stesso tempo *minimizza il numero di elementi non correttamente classificati*, modificando il problema di ottimizzazione come segue:

Minimizzare: $\ w\ /2 + c \cdot \sum_{i=1}^n \xi_i$
Vincolo: $y_i \cdot (w \cdot x + b) \geq 1 - \xi_i \quad \forall i \text{ con } i=1, 2, \dots, n$

Nella formulazione appena mostrata compare il parametro c , detto *soft margin parameter*. Questo parametro definisce quale peso abbiano le variabili di slack nella funzione da minimizzare. In particolare, scegliendo un *soft margin parameter* elevato, allora sarà data molta importanza all'evitare il più possibile le misclassificazioni (a discapito, eventualmente, di un margine più ridotto). Viceversa, con un *soft margin parameter* piccolo, allora il vincolo sulle misclassificazioni sarà più rilassato, mentre viene data più importanza alla massimizzazione del margine.

In questo lavoro di tesi è stata impiegata questa seconda formulazione del classificatore SVM lineare, scegliendo per il soft margin parameter il valore $c=1$.

2.2 Il software sviluppato (piattaforma LabVIEW 2011)

L'obiettivo principale di questo lavoro di tesi era la realizzazione di un sistema BCI EEG-based per il controllo del movimento di un modello di arto superiore. Il cuore di questo progetto risiede naturalmente nello sviluppo del software che, comunicando con il dispositivo di acquisizione, permette di processare il segnale e di utilizzarlo per finalità di controllo, restituendo anche un feedback al soggetto. Il software sviluppato in questo lavoro di tesi si basa su piattaforma LabVIEW 2011, ed è innanzitutto organizzato in tre parti:

- *Training*, per permettere un'iniziale stima del filtro CSP e l'addestramento del classificatore, senza feedback

- *Training e Updating*, per fornire il feedback al soggetto (che in questo modo apprende in regime di condizionamento operante), aggiornando al contempo il filtro CSP e il classificatore (che nel tempo si adatta sempre meglio alle peculiarità dell'utente)
- *Classification*, per testare il sistema precedentemente addestrato e la capacità del soggetto di muovere l'arto simulato tramite controllo EEG

La concezione ed il funzionamento delle tre parti del software saranno illustrati in dettaglio nelle prossime sezioni, insieme ad una descrizione del modello di arto superiore impiegato. Nelle seguenti descrizioni si darà per scontato il preprocessing del segnale (costituito da re-referenziazione con CAR modificato e filtraggio temporale nella banda 8-30Hz), concentrandosi solamente sul filtro CSP e sul classificatore SVM.

Modello di arto superiore

L'arto superiore, da sottoporre a controllo EEG, viene modellato in questo lavoro come un semplice segmento rigido, vincolato alla spalla e con un solo grado di libertà (rotazione, positiva in senso antiorario).

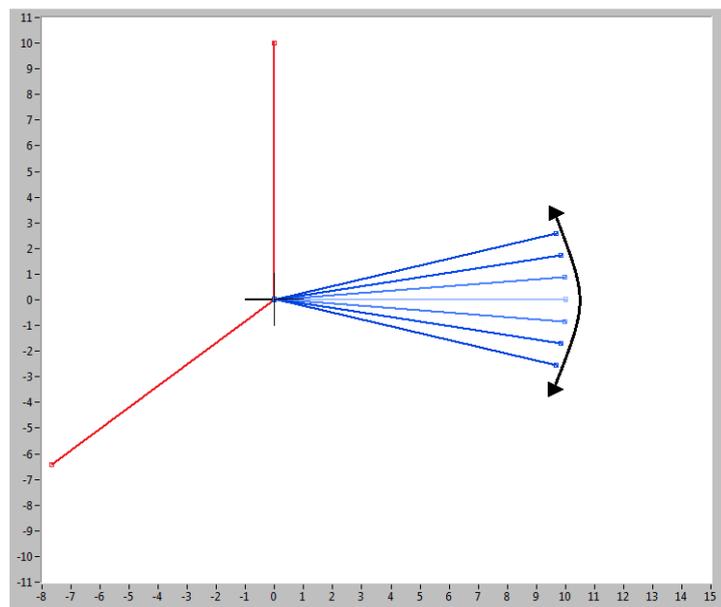


Figura 14. Il modello 1-link di arto superiore: quelle evidenziate in rosso sono le posizioni-limite permesse. In blu sono invece disegnate alcune delle posizioni occupabili.

La variabile controllata è l'angolo di spalla, che viene incrementato o decrementato conseguentemente allo stato mentale in cui si porta il soggetto. All'angolo di spalla è stato inoltre dato come limite il ROM (Range Of Motion) fisiologico, da -140° a 90° rispetto all'orizzontale [77]. Il movimento permesso al braccio, infine, non è continuo ma discreto, e le posizioni occupabili sono solo quelle corrispondenti ad angoli di spalla multipli di 5° (Figura 14).

Training

La prima parte del software che andremo a descrivere è quella relativa al Training. Anche da un punto di vista grafico il programma sviluppato si mostra diviso in tre parti, e ciò che compare accedendo alla schermata di *Training* è mostrato in Figura 15 .

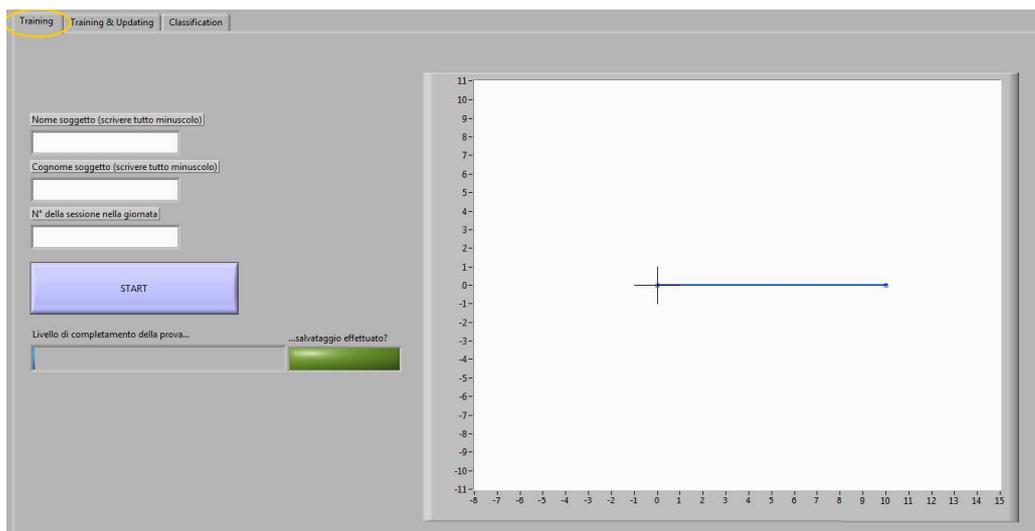


Figura 15. Schermata di *Training* all'accesso

Sulla sinistra sono presenti dei campi per inserire il nome e cognome del soggetto e il numero di sessione della giornata. L'inserimento di questi dati è obbligatorio, altrimenti alla pressione del pulsante "Start" viene visualizzato un messaggio di errore e la prova non può iniziare. I dati del soggetto servono naturalmente per la creazione di una cartella personale in cui salvare tutti i progressi e i risultati ottenuti in una particolare sessione. Una volta inseriti i dati, si può iniziare la prova premendo il pulsante "Start", e controllare il livello di completamento tramite la barra di avanzamento sottostante.

Al termine della prova di *Training*, una volta che il computer abbia terminato le elaborazioni il led verde si illumina, e il software passa automaticamente alla schermata di *Training e Updating*.

Come accennato nell'introduzione, la parte *Training* del software è necessaria per poter computare una prima stima del filtro CSP e per avere un training set iniziale con il quale addestrare il classificatore. In questa prima parte della prova non è naturalmente possibile dare un feedback al soggetto, perché il sistema non conosce ancora le caratteristiche dei suoi pattern EEG.

Alla pressione del tasto "Start", compare sopra il modello dell'arto una freccia, che può essere rivolta verso l'alto o verso il basso (Figura 16). Poiché la strategia di controllo scelta è la *motor imagery*, si chiede al soggetto di immaginare il movimento della mano destra quando la freccia è rivolta verso l'alto, quello della mano sinistra quando è rivolta verso il basso. Durante l'intera sessione di *Training* la freccia viene presentata 14 volte (7 verso l'alto e 7 verso il basso, per avere un training set bilanciato). Ogni freccia rimane visibile per 10 secondi, mentre vengono dati 2.5s di pausa tra una e l'altra. Naturalmente, è richiesto al soggetto di mantenere lo stato mentale indicato dalla freccia per tutto il tempo in cui questa è visibile, mentre può riposarsi durante le brevi pause. L'ordine di presentazione delle frecce verso l'alto o verso il basso è randomizzato. Infine, per rendere immediato il riconoscimento, è stato dato alla freccia un colore diverso a seconda del suo orientamento (Figura 16).

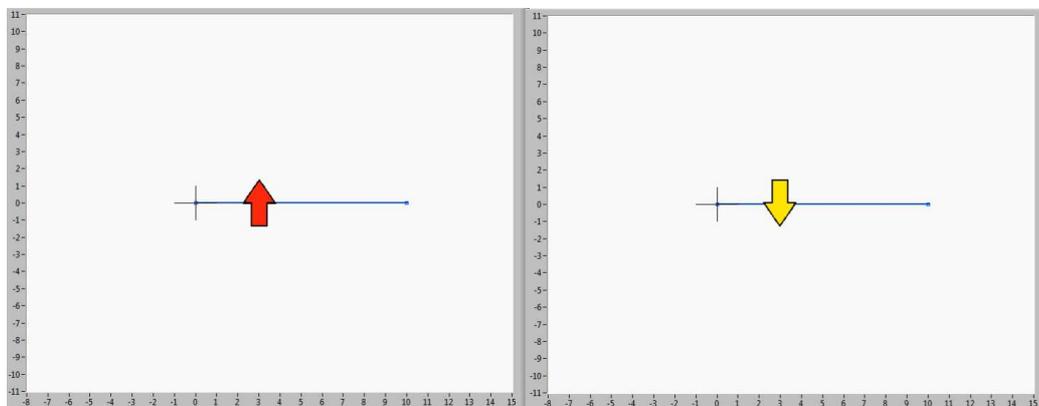


Figura 16. Freccia rivolta verso l'alto o verso il basso. Per i due versi sono stati scelti colori diversi per rendere immediato il riconoscimento.

Per poter progettare il filtro CSP e il classificatore, si considerano ogni 0.5s tratti di segnale lunghi 2s, durante le fasi in cui la freccia è visibile. In questo modo, grazie all'overlap delle porzioni di segnale considerate, da ogni presentazione della freccia lunga 10s vengono estratte 17 porzioni di segnale. Ognuna di queste porzioni avrà come label il verso della freccia in quell'istante, ossia +1 (se rivolta verso l'alto) o -1 (se rivolta verso il basso). Considerando l'intera fase di *Training*, con un totale di 14 ripetizioni della freccia avremo alla fine a disposizione $17 \times 14 = 238$ porzioni di segnale (metà corrispondenti alla motor imagery della mano destra, metà della mano sinistra) con cui progettare il filtro CSP ed estrarre le features per il classificatore.

Per prima cosa, da ogni porzione di segnale estratta si calcola la matrice di covarianza normalizzata (equazione (3)). Mediando nel tempo le matrici di ogni classe si ottengono poi le matrici di covarianza media normalizzate e infine la matrice di covarianza composta (equazione (4)), da cui con vari semplici passaggi si arriva alla stima del filtro CSP. Una volta ottenuto quest'ultimo, tutte le 238 porzioni di segnale acquisite durante il *Training* vengono trasformate con l'equazione $Z_i = WX_i$ (dove W matrice di proiezione del filtro CSP, X_i matrice relativa all' i -esima porzione di segnale), e da ognuna delle matrici Z_i si ricava un vettore di feature f contenente quattro varianze normalizzate e log-trasformate (come spiegato in dettaglio al paragrafo precedente, equazione (12)). I 238 vettori di feature così estratti, insieme alle loro label, costituiscono il training set del classificatore lineare SVM. Una volta addestrato anche il classificatore, il led verde nella schermata di *Training* si accende e si passa automaticamente alla fase di *Training e Updating*.

Prima di descrivere la fase successiva, si aggiunge qui una nota sulla scelta del valore di 2s per la durata dei segmenti considerati. Come notato da Guger et al. nel loro studio [63], più si allunga la finestra temporale e più migliora l'accuratezza della classificazione, ma al contempo diminuisce la prontezza del sistema. Il valore di 2s ci è sembrato un buon compromesso tra queste due esigenze.

Training e Updating

La seconda porzione di software, *Training e Updating*, è stata concepita per essere ripetuta più volte, e serve per continuare ad eseguire un training sul soggetto mentre, al contempo, si aggiornano anche il filtro CSP e il classificatore. L'obiettivo di *Training e Updating* è quello di migliorare sia l'abilità del soggetto nel portarsi negli stati mentali richiesti, sia la capacità del sistema di riconoscere questi stati mentali, favorendo in questo modo l'incontro tra uomo e sistema.

Dal punto di vista grafico, la schermata di *Training e Updating* (Figura 17) è analoga a quella di *Training*. Quando si accede a questa schermata, i dati del soggetto (nome, cognome e sessione) sono ricopiati automaticamente, così da non doverli re-inserire rischiando errori di battitura.

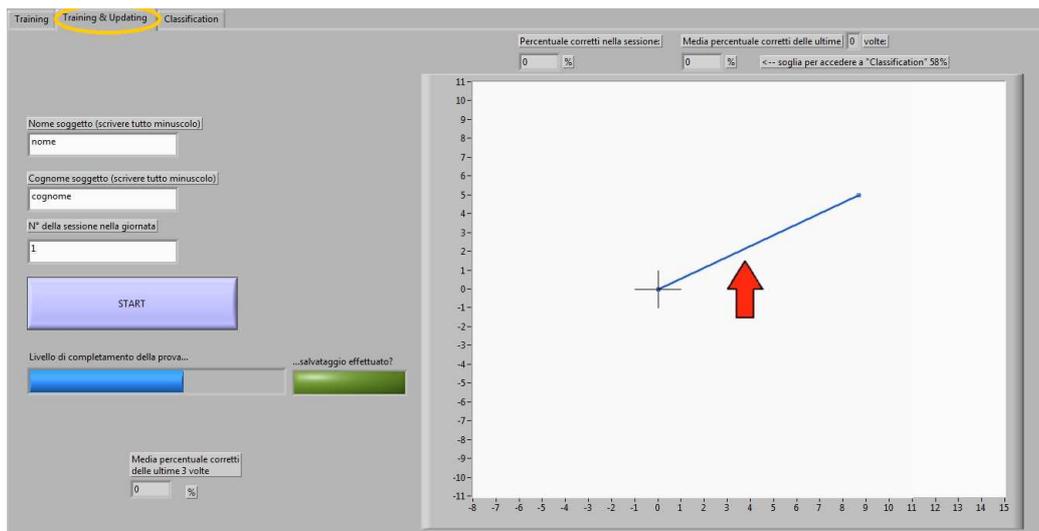


Figura 17. *Training e Updating*

La novità della fase di *Training e Updating* è la presenza del feedback, codificato in un incremento/decremento di 5° dell'angolo di spalla in base allo stato mentale rilevato. Dal punto di vista dello svolgimento, in questa fase viene ancora mostrata al soggetto la freccia indicante il verso richiesto ma, grazie al feedback che contemporaneamente viene dato, il soggetto è anche reso cosciente degli effetti del suo stato mentale. In questo modo, l'apprendimento per l'utente è più efficace grazie al condizionamento operante (il feedback

stesso è infatti elemento sia di *reward* che di *punizione* a seconda della sua concordanza rispetto al movimento richiesto), nonché il tutto è reso più coinvolgente.

Il feedback fornito è tempo-discreto, e viene dato ogni 0.5s. Per poterlo calcolare, vengono considerate di volta in volta porzioni di segnale lunghe 2s, analogamente a quanto fatto nella fase di *Training* (dunque, il primo feedback sarà dato dopo 2s e i successivi ogni 0.5s). Ogni porzione di segnale considerata viene istantaneamente filtrata dalla matrice W risultante dalla sessione precedente (che può essere o una sessione di *Training* o un'altra sessione di *Training e Updating*), e da qui viene estratto il vettore di features f , che sarà valutato dal classificatore. In base al risultato del classificatore, che restituisce sia la classe di appartenenza che la distanza dall'iperpiano di separazione (equazione (14)), il feedback risultante può essere o un incremento/decremento dell'angolo di 5° o anche un non-movimento del braccio. Per stimolare infatti il soggetto a produrre stati mentali sempre più definiti, viene impiegato un meccanismo a soglia adattiva, per cui il braccio simulato si muove solamente se la distanza del pattern dall'iperpiano di separazione supera un certo valore (Figura 18).

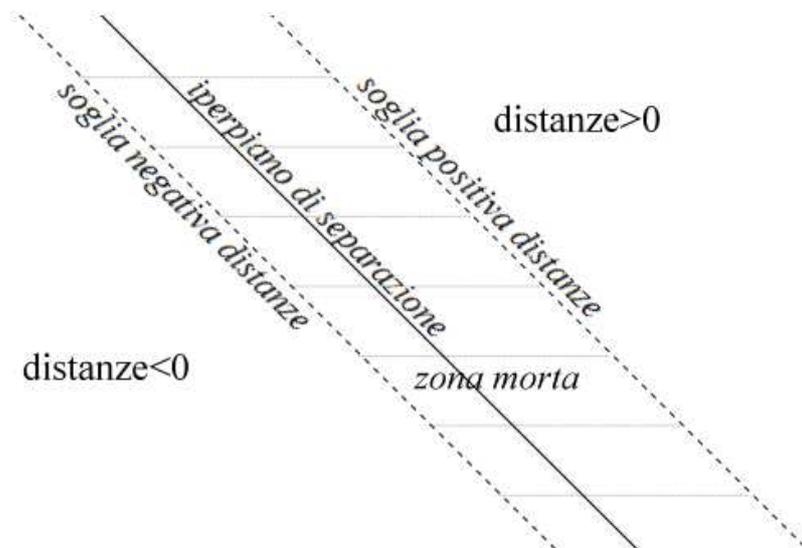


Figura 18. Iperpiano di separazione e soglie sulle distanze. Se il pattern cade all'interno della zona morta, allora non si produrrà alcun movimento del braccio. Si noti come le soglie per le distanze positive e negativa possano essere diverse, soprattutto in un primo momento.

Poiché è possibile che, soprattutto all'inizio, per una persona sia più semplice entrare in uno stato mentale piuttosto che nell'altro, le soglie per le distanze positive e negative sono calcolate separatamente. In particolare, ogni soglia viene sempre calcolata come il 60% del valor medio delle distanze positive/negative viste dal software fino a quel momento. In questo modo, a mano a mano che il soggetto migliora (e produce quindi pattern con distanze sempre maggiori dall'iperpiano), la soglia si adatta aumentando, ma senza mai esagerare. Per il calcolo delle soglie si prendono in considerazione solo le distanze relative a pattern correttamente classificati (ossia pattern lo stato mentale prodotto dal soggetto è concorde a quello richiesto).

La prima volta che si esegue *Training e Updating* entrambe le soglie partono da 0, mentre ad ogni successiva ripetizione si riparte sempre dall'ultima soglia calcolata. A mano a mano che si procede, oltre ad aggiornarsi entrambe le soglie si stabilizzeranno, perché frutto della media di un numero sempre maggiore di distanze.

All'interno di ogni fase di *Training e Updating*, la freccia viene presentata 10 volte. Nuovamente, ogni indicazione viene mantenuta 10s, e sono presenti 2.5s di pausa tra una e l'altra.

Al termine di *Training e Updating*, come precedentemente accennato, sia il filtro CSP che il classificatore vengono aggiornati per cercare di andare incontro al soggetto. Per favorire tuttavia l'inserimento all'interno del training set del classificatore solo dei dati "migliori", tra tutte le porzioni di segnale processate nella fase *Training e Updating* si memorizzano solamente quelle correttamente classificate e soprasoglia. A questo punto, poiché è probabile che i dati così collezionati non siano bilanciati tra segnali relativi alla mano destra e alla mano sinistra, un'ulteriore scrematura viene fatta pareggiando le due classi ed eliminando della classe con più elementi i dati che avevano riportato minore distanza dall'iperpiano (dati dunque meno "definiti"). In questo modo, di tutte le porzioni di segnale acquisite ho mantenuto solo quelle migliori in termini di separabilità, oltre ad avere per ogni classe un numero uguale di esempi (questo mi serve per mantenere il classificatore bilanciato).

Per spiegare meglio questo processo di scrematura e ribilanciamento dei dati, si veda la Figura 19.

<i>Distanza dall'iperpiano</i>	<i>Label</i>	<i>Porzione di segnale relativa alla label e alla distanza</i>
1.53	+1	s_1
0.47	+1	s_2
0.25	+1	s_3
2.01	+1	s_4
0.33	+1	s_5
-1.7	-1	s_6
-0.27	-1	s_7

Figura 19 Modalità di scrematura e ribilanciamento dei dati “migliori” (ossia quelli al termine di Training e Updating sono risultati concordi allo stato mentale richiesto e soprasoglia). Le righe evidenziate sono relative ai dati che verranno eliminati al termine dell’operazione di ribilanciamento. Si noti come, se la differenza tra il numero di campioni di una classe e quelli dell’altra è elevata, è possibile che in questo modo si eliminino anche parecchi dati.

Per aggiornare il filtro CSP, prendo ora tutte le porzioni di segnale risultanti dal processo di scrematura e bilanciamento, e le utilizzo per calcolare delle nuove matrici di covarianza normalizzata. Le nuove matrici così ottenute vengono *aggiunte* a quelle viste fino a quel momento da quando si è iniziato il primo *Training*. In questo modo, si calcoleranno di volta in volta per ogni classe matrici di covarianza medie sempre più stabili, arrivando ad una stima della matrice W del filtro CSP in teoria sempre migliore.

Per aggiornare il classificatore, tutte le porzioni di segnale risultanti dal processo di scrematura e bilanciamento vengono ora rilette alla luce del W appena calcolato, per ri-estrarne le features. Contrariamente a quanto avviene per il filtro CSP, nel caso dell’aggiornamento del training set i nuovi pattern non vengono *aggiunti* ai precedenti, ma vanno a piuttosto a *sostituire* i pattern più vecchi. In questo modo, si ha

la possibilità di rimpiazzare nel training set pattern potenzialmente poco separabili (o comunque sia “datati”) con nuovi vettori di features sicuramente più separabili e che “seguono” (entro un certo limite) i progressi del soggetto. Il tutto, mantenendo un numero costante di elementi del training set, che rimane anche sempre bilanciato. Naturalmente, dato che dopo ogni *Training e Updating* la matrice W si aggiorna, per mantenere una coerenza all’interno del training set, nel momento in cui si recuperano segnali relativi a vecchie sessioni questi vengono riletti secondo la nuova W e vengono nuovamente estratte anche le features. Con il nuovo training set così aggiornato, anche il classificatore SVM viene ri-addestrato.

Per visualizzare meglio quanto appena spiegato circa l’aggiornamento della matrice W e del classificatore SVM si veda la Figura 20.

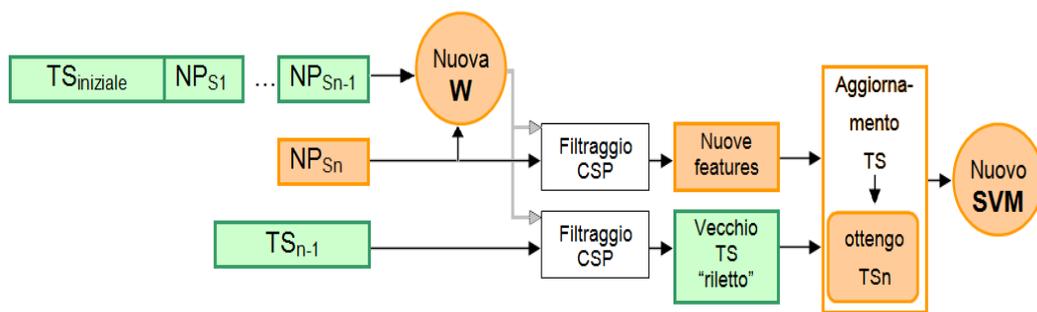


Figura 20. Modalità di aggiornamento di W e del classificatore SVM. Si noti come il nuovo W sia ottenuto considerando, oltre al training set (TS) iniziale, tutte le nuove porzioni (NP) di segnale corrette nelle sessioni precedenti (s_1, s_2, \dots, s_{n-1}), aggiungendo anche quelle appena ottenute (NP_{S_n}). La nuova W così calcolata si utilizza a questo punto sia per filtrare le nuove porzioni di segnale ottenute dalla sessione (NP_{S_n}), sia per “rileggere” il training set della sessione precedente (TS_{n-1}). Dalle nuove features ottenute e dalla “rilettura” del vecchio training set è possibile ottenere il nuovo training set (TS_n), e dunque il nuovo classificatore SVM

Un ultimo aspetto della fase *Training e Updating* rimane da descrivere, e questo riguarda lo sbilanciamento nella presentazione frecce. In particolare, contrariamente a quanto avviene nella fase di

Training, in cui metà delle frecce erano rivolte verso l'alto e metà verso il basso, in questa fase di *Training e Updating* è previsto possa esserci uno sbilanciamento fino ad un rapporto di 7:3 (o viceversa). La ragione dell'inclusione di questa caratteristica dipende da due elementi: da una parte, la modalità con cui viene aggiornato il classificatore, dall'altra l'intento di esercitare maggiormente il soggetto allo stato mentale per lui più "problematico". Capita infatti spesso che all'inizio, o perché il soggetto non è in grado di produrre stati mentali ben separabili, o perché effettivamente si trova meglio a produrne uno rispetto all'altro, la classificazione sia agevolata da un lato o dall'altro. In un esempio estremo, supponiamo accada che su 10 frecce presentate in modo bilanciato, il soggetto riesca sempre a muovere il modello verso l'alto ma mai verso il basso. In un caso simile, chiaramente, non sarebbe possibile aggiornare il classificatore, poiché nel momento in cui i "segnali migliori" vengono scremati dal bilanciamento non rimarrebbe più nulla perché per una delle due classi non ho nessun esempio con cui bilanciare. Anche senza considerare esempi così estremi, in generale per come si aggiorna il classificatore, fornendo sempre e comunque frecce bilanciate non sfrutterei al meglio i "segnali migliori" a disposizione (questo concetto è già accennato anche nella didascalia della Figura 19). Da qui l'idea di sbilanciare le frecce ogni volta che si ripete *Training e Updating*, presentando nella sessione successiva lo stimolo più "problematico" per il soggetto con più frequenza. Per calcolare lo sbilanciamento, si vanno a contare quante porzioni di segnale "buone" (ossia concordi alla richiesta a soprasoglia) al termine della precedente sessione corrispondevano ad una classe o all'altra, e si inverte il rapporto fino ad un limite massimo di sbilanciamento di 7:3 (o viceversa). In questo modo si favoriscono, al contempo, un più veloce aggiornamento del classificatore e l'apprendimento dello stato mentale più "problematico" da parte del soggetto. Naturalmente, alla prima esecuzione di *Training e Updating* le frecce sono presentate in rapporto 5:5, mentre lo sbilanciamento entra in gioco dalla successiva ripetizione in poi. A mano a mano che il soggetto apprende a produrre bene entrambi gli stati mentali, lo

sbilanciamento delle frecce sarà sempre più ridotto e tenderà ad auto-assesstarsi sul 5:5.

Alla fine di ogni sessione di *Training e Updating* la percentuale di pattern correttamente classificati viene calcolata, ed è visualizzabile anche dal soggetto in alto nello schermo. Nel momento in cui il soggetto ottiene performance di classificazione sufficientemente stabili (come meglio spiegato nel prossimo paragrafo), può passare alla fase di *Classification*, in cui né la soglia, né il filtro CSP, né il classificatore vengono più aggiornati. Per il calcolo delle percentuali di pattern correttamente classificati, si considera alla fine di ogni fase di *Training e Updating* il numero totale di pattern correttamente classificati (indipendentemente, stavolta, dal fatto che si trovino sotto- o sopra-soglia) e lo si divide per la totalità dei pattern, ossia 170. Si noti come, dato lo sbilanciamento nella presentazione delle frecce, quest'operazione equivalga a fare una media pesata delle percentuali di pattern correttamente classificati di ciascuna classe. Il fatto che ogni volta venga riproposta con maggiore frequenza la classe più "problematica" rende dunque questa stima leggermente peggiorativa, dal momento che mediamente peserà di più la classe in cui si ottengono i risultati peggiori.

Prima di passare a descrivere la fase *Classification*, si vuole dare qui la ragione di alcune scelte progettuali fatte, come ad esempio il numero di ripetizioni della freccia nel *Training* (14 ripetizioni) rispetto al *Training e Updating* (10 ripetizioni). Il motivo di questa scelta risiede nel fatto di voler sì rendere il classificatore flessibile e in grado di adattarsi al soggetto, ma tutelandosi al contempo dal fatto che l'intero training set potesse essere sostituito nel caso di una sessione di *Training e Updating* particolarmente positiva. In particolare, con 10 ripetizioni della freccia il massimo numero di pattern estraibili in una sessione di *Training e Updating* è $10 \times 17 = 170$, ossia circa 70% del training set (composto da 238 elementi). In questo modo nel training set saranno presenti sempre i dati di almeno due sessioni diverse, il che favorisce una maggiore continuità e stabilità del sistema da una sessione all'altra. Inoltre, pur essendo permesso l'aggiornamento, si

vincola in questo modo un po' il soggetto a cercare di riprodurre stati mentali stabili da una sessione all'altra.

In parte per gli stessi motivi, si è deciso di diversificare la modalità di aggiornamento di W da quella del training set. In particolare, nel caso di W abbiamo visto che le nuove matrici di covarianza vengono *aggiunte*, mentre nel caso del training set i vecchi dati vengono *sostituiti*. Anche in questo caso, è stata fatta questa scelta per permettere sì al sistema di aggiornarsi, ma sempre garantendo la stabilità e obbligando il soggetto a cercare di ripetere sempre il più possibile uguali gli stati mentali prodotti, una volta individuata una strategia. Inoltre, nel caso dell'aggiornamento di W si è ritenuta più idonea un'aggiunta piuttosto che una sostituzione anche per via dell'elevata sensibilità agli artefatti del metodo CSP, come spiegato da Ramoser et al. in [72]. Aumentando il numero di "esempi", le matrici medie di covarianza normalizzata delle due classi vengono stimate in modo più robusto, il che favorisce la stabilità del sistema.

Classification

La terza parte del software, *Classification*, corrisponde alla fase in cui le soglie e il filtro CSP sono già stati calcolati, il classificatore SVM è già stato addestrato e il soggetto è abbastanza abile nel controllare il sistema da poterlo utilizzare. In particolare, nella fase *Classification* non viene più indicata la direzione del movimento con una freccia, ma vengono piuttosto proposti sullo schermo dei target (pallini) che il soggetto è chiamato a raggiungere con l'end-point del braccio, attraverso il controllo EEG.

La schermata di *Classification* è in tutto e per tutto simile a quelle di *Training* e di *Training e Updating* (Figura 21). Anche in *Classification* i dati anagrafici del soggetto vengono riportati automaticamente nei rispettivi campi, e in più è possibile selezionare nella parte bassa dello schermo (Figura 21) quante prove di reaching si desidera portare a termine in ogni ripetizione di *Classification*. Di default, il numero di proposizioni del target in una sessione è 5 perché la fase di *Classification*, soprattutto le prime volte che ci si arriva, può

essere più stancante per il soggetto rispetto al *Training* o al *Training e Updating*. Mentre infatti nelle prime due fasi lo stato mentale andava mantenuto per soli 10s consecutivi con pause di 2.5s tra una presentazione e l'altra della freccia, in *Classification* è possibile che venga richiesto di rimanere concentrati per più tempo. In effetti, se il braccio si muove ogni volta che sia possibile, allora percorrerà 5° ogni 0.5s, ossia avrà una velocità massima di $10^\circ/s$. Ciò significa che, se il target compare nella posizione-limite più lontana (-140°), il soggetto impiega come minimo 14 secondi per raggiungerlo, ma anche più nei casi in cui l'arto non venga sempre mosso nel verso giusto o si producano a volte pattern sottosoglia. Per lo stesso motivo, le pause tra una presentazione e l'altra del target durano 5s in *Classification*, invece che 2.5s.

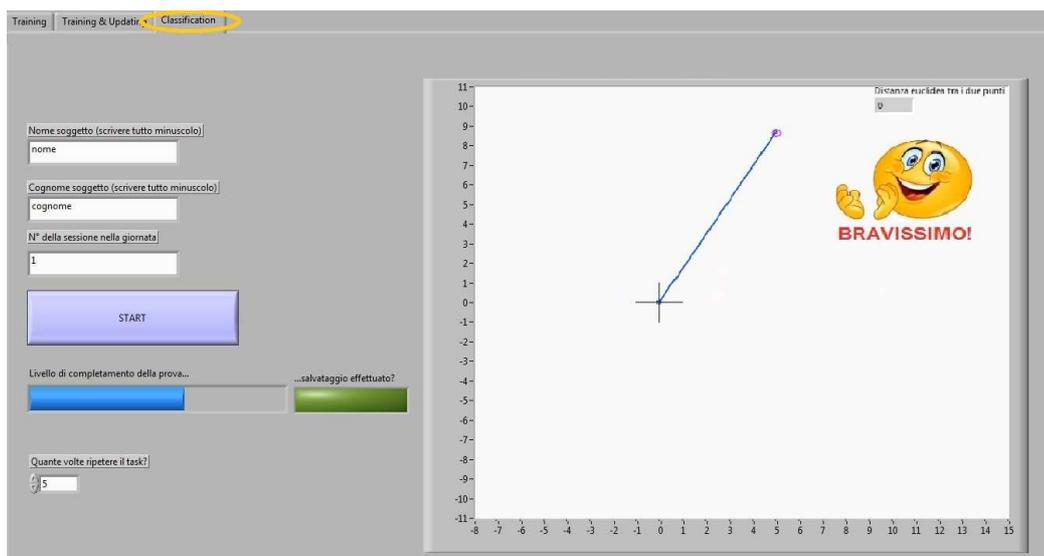


Figura 21. La schermata di *Classification*. Nell'immagine uno dei momenti in cui il target viene raggiunto, con conseguente comparsa del "reward".

Naturalmente, anche durante la fase di *Classification* il soggetto continua ad addestrarsi, perciò si è pensato di inserire anche qui un ulteriore segno di reward come rinforzo positivo. In particolare, tutte le volte che il soggetto riesce a raggiungere il target, compare un'espressione sorridente sullo schermo (Figura 22, a sinistra). Per risolvere infine i casi in cui il soggetto non riesce a controllare bene l'arto modellato e dopo un po' si demoralizza, è stato inserito un

timeout di 120s, al termine del quale compare un'espressione triste (Figura 22, a destra) e, dopo la pausa di 5s, viene presentato il nuovo target.



Figura 22. A sinistra, espressione sorridente che compare quando si raggiunge il target. A destra, espressione triste che indica il raggiungimento del timeout

Al termine della fase di *Classification*, il software salva in un file le coordinate dei 5 target presentati e i tempi impiegati dal soggetto per raggiungerli. In questo modo, è possibile ricostruire offline quale fosse il tempo minimo necessario per raggiungere ogni target e confrontarlo, ad esempio, con il tempo realmente impiegato dal soggetto. Anche i segnali EEG registrati e i parametri del sistema (come le soglie per le distanze, il filtro CSP e il classificatore) vengono salvati, cosicché sia anche possibile capire quante volte, ad esempio, il soggetto avesse prodotto lo stato mentale corretto per raggiungere il target, ma sottosoglia per cui l'arto non si è mosso.

2.3 Test del software sviluppato

In questo lavoro di tesi, oltre a sviluppare il software, si è anche testato il sistema su alcuni soggetti. Nelle due seguenti sezioni si descriveranno meglio i soggetti che hanno preso parte all'esperimento, e le modalità di esecuzione.

I soggetti

Il sistema sviluppato in questo lavoro di tesi è stato testato su quattro persone (3 femmine e 1 maschio, di età compresa tra i 24 e i 60

anni), che hanno preso parte all'esperimento. I soggetti, che saranno d'ora in poi designati con le sole iniziali di nome e cognome per questioni di privacy, al momento di iniziare il test presentavano diversi livelli di esperienza in quanto a sistemi BCI basati su immaginazione motoria. In particolare:

- il *Soggetto DB* non aveva mai avuto in precedenza esperienze BCI
- il *Soggetto ALM* aveva già totalizzato nello stesso anno della sperimentazione, da precedenti esperienze BCI su sistemi diversi, 261 minuti (4 ore e 21 minuti) di training su immaginazione motoria
- il *Soggetto MR* non aveva mai avuto in precedenza esperienze BCI
- il *Soggetto VM* aveva già totalizzato nello stesso anno della sperimentazione, da precedenti esperienze BCI su sistemi diversi, 461 minuti (7 ore e 41 minuti) di training su immaginazione motoria

I tempi di training indicati per il *Soggetto ALM* e per il *Soggetto VM*, che indicano il livello di esperienza BCI precedente all'esperimento, si riferiscono al tempo effettivo di concentrazione sui task di immaginazione motoria, senza considerare eventuali pause.

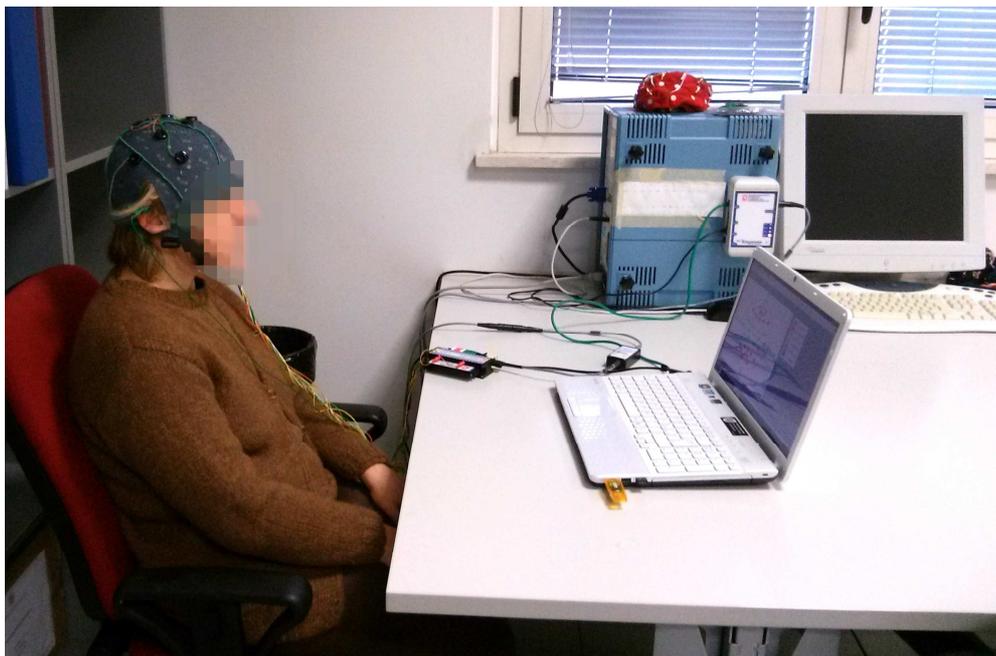


Figura 23. Uno dei soggetti si è rilassato davanti allo schermo durante una delle prove

Modalità di svolgimento delle prove

Durante lo svolgimento delle prove, i soggetti sedevano di fronte allo schermo di un pc, con le braccia rilassate e assumendo una posizione comoda (Figura 23). Per cercare di evitare artefatti nel segnale EEG, si è chiesto ad ogni persona di ricordare durante la prova di non contrarre i muscoli facciali (ad esempio digrignando i denti, corrugando la fronte etc.) e di cercare di tenere gli occhi aperti e lo sguardo fisso.

A priori è stato stabilito con che modalità dovevano essere svolte le prove. In particolare, per decidere quanto dovesse durare una ogni sessione di addestramento si è consultata la letteratura e si è visto che tipicamente si considerano sessioni di 160 trial [62][78]. Ogni trial, nel nostro caso, è una ripetizione della freccia lunga 10s. Dunque, dal momento che ogni fase di *Training e Updating* corrisponde a 10 trial, si è stabilito che ogni sessione di addestramento dovesse essere composta da 1 *Training* iniziale + 16 ripetizioni di *Training e Updating* (timeline in Figura 24). In tutto, ogni sessione di addestramento così composta dura esattamente 29 minuti di concentrazione effettiva, che corrispondono a circa 1 ora considerando anche la preparazione e le eventuali pause tra una ripetizione e l'altra di *Training e Updating*.

A ogni soggetto partecipante è stata chiesta disponibilità per un tempo corrispondente a 6 sessioni di addestramento, per vedere l'evoluzione delle performance. Eventualmente, i soggetti avevano la possibilità di eseguire anche 2 sessioni al giorno, in modo da doversi recare in laboratorio solo 3 volte. Tutti i soggetti hanno seguito questa modalità, per cui in ogni giornata sono state sempre portate a termine 2 sessioni di addestramento. Il tempo trascorso tra la prima e l'ultima delle 6 sessioni non ha mai superato le 2 settimane per nessuno dei soggetti.

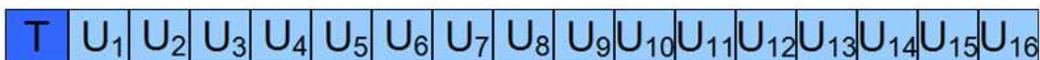


Figura 24. *Timeline di una tipica sessione di addestramento*

La timeline, così come mostrata in Figura 24, è relativa ad una sessione di addestramento “standard” anche se in realtà, a seconda delle performance del soggetto, sono state introdotte delle variazioni.

In dettaglio, per risolvere i casi in cui il *Training* sia andato male oppure quelli in cui dopo un po’ il soggetto abbia cambiato strategia portando il sistema a “non seguirlo più”, si è deciso che se la percentuale di dati correttamente classificati nelle ultime tre ripetizioni di *Training e Updating* era inferiore al 40%, allora si aveva la possibilità di azzerare il sistema ripetendo il *Training*, e completando solo in seguito le mancanti ripetizioni di *Training e Updating* (esempio di timeline in Figura 25). Percentuali di pattern correttamente classificati così basse possono verificarsi nel sistema sviluppato poiché, come accennato in precedenza, le accuratezze di classificazione sono calcolate come media pesata delle accuratezze di ogni classe (ed è la classe per il soggetto più problematica ad essere proposta con maggior frequenza).

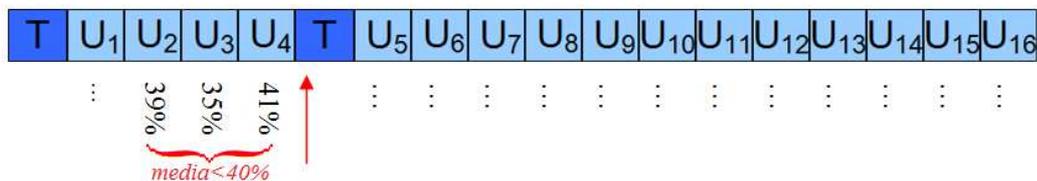


Figura 25 Timeline di una sessione in cui nelle ultime tre volte la media delle percentuali di pattern corretti della sessione è <40%

Viceversa, l’accesso a *Classification* può avvenire nel momento in cui il soggetto raggiunge performance abbastanza buone e stabili. Il requisito minimo per l’accesso alla fase di *Classification* è che, al termine delle 16 ripetizioni di *Training e Updating* della sessione, la media delle ultime 6 percentuali di pattern correttamente classificati superi il 58%. Questa soglia è stata scelta in accordo al lavoro di Müller-Putz et al. [79], che indicano il livello-limite di accuratezza di classificazione al di sotto del quale non si può considerare il proprio sistema migliore del caso nel predire la giusta classe. Con un numero di elementi del training set $n=238$ e 2 classi da discriminare, questo livello è risultato essere pari al 58%.

Quello appena descritto è il requisito minimo per l'accesso a *Classification*. L'altra modalità per accedere a questa fase richiede invece che nelle ultime 6 prove la percentuale di dati correttamente classificati sia superiore al 70%. Non appena si verifichi questo requisito, è possibile terminare anticipatamente le ripetizioni di *Training e Updating* accedendo immediatamente alla fase di *Classification*, poiché si ritiene che il soggetto sia abbastanza abile nel governare il sistema e filtro CSP e classificatore ben addestrati.

Una volta arrivati alla fase di *Classification* tramite una delle due modalità sopra descritte, si è stabilito di ripetere quest'ultima fase per 3 volte. Considerando che all'interno di ogni ripetizione di *Classification* sono eseguite 5 prove di reaching, in totale quando si arriva a questa fase viene richiesto di raggiungere il target (pallino) presentato 15 volte.

2.4 Independent Component Analysis

Prima di passare a descrivere, nel prossimo paragrafo, le modalità con cui saranno presentati i risultati, conviene fermarsi un attimo per descrivere un metodo di analisi del segnale EEG a cui si farà riferimento in seguito. Tale metodo è l'*Independent Component Analysis* (ICA), e sarà introdotto nella seguente sezione.

Il metodo ICA (Independent Component Analysis)

L'obiettivo della ICA (Independent Component Analysis) è quello di trovare una rappresentazione dei dati più significativa, rispetto al segnale registrato, attraverso una trasformazione lineare degli stessi [80]. Per capire meglio l'ICA si prenda l'esempio del *cocktail party problem*: supponiamo che in una stanza si tenga un cocktail party, con diverse persone che parlano indipendentemente le une dalle altre. Supponiamo poi di avere nella stanza più microfoni. I segnali registrati dai vari microfoni saranno allora delle combinazioni dei segnali (voci) emessi dalle varie sorgenti. Considerando il caso semplice in cui ci siano solo due soggetti e due microfoni (Figura 26), allora i segnali

registrati da ciascuno dei due microfoni, $x_1(t)$ e $x_2(t)$, saranno entrambi combinazione lineare delle due sorgenti indipendenti, $s_1(t)$ e $s_2(t)$, in questo modo:

$$\begin{aligned} x_1(t) &= a_{11}s_1(t) + a_{12}s_2(t) \\ x_2(t) &= a_{21}s_1(t) + a_{22}s_2(t) \end{aligned} \quad (20)$$

L'obiettivo della ICA è quello di ricostruire i segnali $s_1(t)$ e $s_2(t)$ a partire dalla sola conoscenza di $x_1(t)$ e $x_2(t)$, ottenendo così le sorgenti a partire dalla loro miscela. Anche se non si conoscono i coefficienti a_{ij} si può dimostrare come, facendo alcune ipotesi sulle sorgenti, sia possibile la separazione. Problemi come il *cocktail party problem* rientrano nella categoria dei problemi di *Blind Source Separation* (BSS).

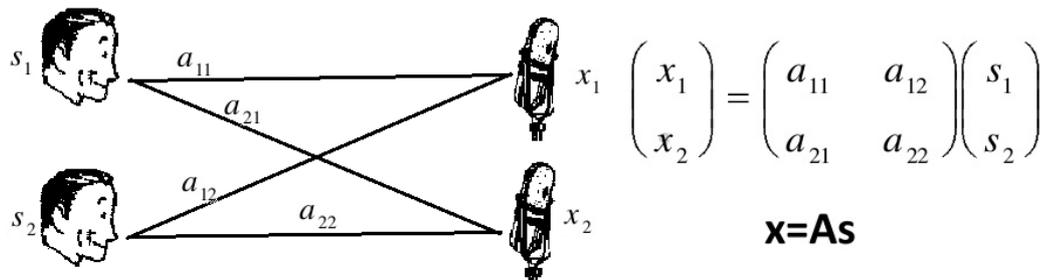


Figura 26 Il cocktail party problem e il problema della Blind Source Separation.

Le assunzioni alla base del metodo ICA, necessarie per poter stimare le componenti indipendenti (sorgenti), riguardano innanzitutto il modello generativo dei dati. Come detto prima, supponiamo di avere un vettore \mathbf{x} di n registrazioni (dunque di dimensione $n \times 1$). Ognuna delle componenti x_i del vettore sia combinazione lineare delle n sorgenti indipendenti s_i (vettore \mathbf{s} delle sorgenti, anch'esso $n \times 1$). In forma matriciale, questo significa scrivere:

$$\bar{\mathbf{x}} = A\bar{\mathbf{s}} \quad (21)$$

dove la matrice A è detta *matrice di mixing*. Sia le sorgenti che il modo in cui si mescolano (i coefficienti della matrice A) sono variabili latenti, non note. L'unica cosa a cui si ha accesso è il vettore di dati \mathbf{x} .

Se però si assume questo modello, allora si può scrivere:

$$\bar{\mathbf{s}} = A^{-1}\bar{\mathbf{x}} \quad (22)$$

ossia che anche le sorgenti in \mathbf{s} possono teoricamente essere stimate come combinazione lineare delle registrazioni in \mathbf{x} . Per stimare la matrice \mathbf{A}^{-1} , detta *matrice di demixing*, occorre ottimizzare una qualche funzione costo proporzionale al “grado di indipendenza” delle sorgenti \mathbf{s} stimate.

Perché io possa stimare \mathbf{s} è necessario tuttavia fare alcune assunzioni, chiamate *vincoli di identificabilità*. I vincoli di identificabilità sono i seguenti:

1. le sorgenti s_i siano statisticamente indipendenti
2. le sorgenti s_i siano non gaussiane
3. il numero di variabili osservate x_i (m) deve essere \geq del numero di sorgenti indipendenti (n). Avendo assunto il modello generativo dei dati dell'equazione (22) allora $m=n$ (assunzione lecita a cui ci si può sempre ricondurre con metodi di riduzione della dimensionalità tramite eliminazione della ridondanza)
4. la matrice \mathbf{A} (supposta quadrata, $m=n$) sia invertibile, ossia $\det \mathbf{A} \neq 0$

Sotto queste condizioni il problema della stima delle componenti indipendenti è ben posto, ossia è possibile applicare il modello ICA.

Tuttavia, l'ICA può stimare \mathbf{s} e \mathbf{A} solo a meno di alcune indeterminazioni. Queste vengono dette *ambiguità del modello ICA*, e sono le seguenti:

1. non è possibile determinare la varianza delle sorgenti indipendenti perché sia le colonne di \mathbf{A} che gli elementi di \mathbf{s} sono identificabili a meno di un fattore moltiplicativo (moltiplicando infatti la colonna A_j per $\alpha \neq 0$ e dividendo la sorgente s_j per lo stesso α il risultato non cambia). L'ICA ipotizza dunque che le varianze di tutte le sorgenti siano arbitrariamente unitarie.
2. le sorgenti sono stimate a meno del segno, per lo stesso motivo che in 1.
3. le sorgenti non hanno un ordine intrinseco perciò, ripetendo la ICA, la stessa sorgente s_i può essere stimata in posizioni diverse in \mathbf{s}

Come detto precedentemente, la stima della matrice di *demixing* A^{-1} è possibile risolvendo un problema di ottimizzazione di una funzione costo che misuri l'indipendenza delle variabili. Due approcci solitamente utilizzati per massimizzare l'indipendenza prevedono ad esempio:

- la massimizzazione della non-gaussianità
- la minimizzazione della mutua informazione tra variabili

Il motivo per cui, per massimizzare l'indipendenza, bisogna massimizzare la non-gaussianità deriva dal teorema del limite centrale, per cui la somma di k variabili aleatorie indipendenti converge a una funzione densità di probabilità gaussiana al crescere di k , indipendentemente da come sono fatte le funzioni densità di probabilità delle singole variabili [80]. Una combinazione lineare di anche solo due variabili sarà dunque “più gaussiana” di ognuna delle variabili originali. Calcolando i coefficienti della combinazione lineare attraverso la massimizzazione della sua non-gaussianità, invece, il risultato dovrebbe stimare esattamente una delle due sorgenti indipendenti.

Per quanto riguarda invece la mutua informazione, questa quantifica l'informazione che una variabile contiene circa le altre. Minimizzare la mutua informazione tra variabili significa dunque massimizzare la loro indipendenza.

Quelli appena mostrati sono i principi e le assunzioni alla base del metodo ICA. Maggiori dettagli sui passaggi matematici che portano all'identificazione della matrice di *demixing* possono invece essere trovati nel libro di Hyvärinen, Karhunen e Oja [81].

Il problema di BSS si presenta in molti ambiti, come l'audio-processing (es. isolare tracce di singoli strumenti da un insieme) o le scienze della terra (per l'analisi dei dati sismici). In ambito biomedico, il problema BSS può essere applicato all'elaborazione del segnale EEG: i segnali registrati alle diverse locazioni non sono infatti altro che una miscela di contributi di origine cerebrale ed extracerebrale (artefatti). La tecnica ICA può essere in effetti utilizzata per rimuovere dall'EEG le sorgenti artefattuali [80]. Il motivo per cui è difficile utilizzare in

real-time il metodo ICA per la rimozione degli artefatti è che le sorgenti, come detto precedentemente, non vengono stimate con un ordine intrinseco. Occorrerebbe dunque implementare una procedura di riconoscimento automatico delle sorgenti artefattuali, eliminandole così di volta in volta quando presenti.

La tecnica ICA può essere utilizzata, in ambito EEG, anche per localizzare le sorgenti sullo scalpo rispetto alle locazioni degli elettrodi. Stimando infatti la matrice di *mixing* A , si può osservare che i coefficienti nelle colonne di A pesano le sorgenti s_i in base alla “vicinanza” rispetto alle locazioni degli elettrodi. Ciò significa che ad esempio, plottando i valori dei coefficienti della colonna j -esima di A su una mappa topografica dello scalpo contenente le locazioni d’elettrodo e interpolando, si può ottenere la localizzazione della sorgente s_j rispetto agli elettrodi registrati.

In questo lavoro di tesi il metodo ICA è stato utilizzato per vedere se, tra le sorgenti EEG stimate durante l’immaginazione motoria dei movimenti della mano sinistra vs destra, ce ne fossero alcune associabili ai noti fenomeni di desincronizzazione evento-correlata (ERD) controlaterale e di sincronizzazione evento-correlata (ERS) ipsilaterale.

2.5 Modalità di presentazione dei risultati

All’interno del prossimo capitolo si mostreranno i risultati ottenuti sul sistema sviluppato in questo lavoro di tesi. I risultati presentati riguarderanno sia le performance dei soggetti nelle 6 sessioni, sia le caratteristiche del sistema in generale. Nelle seguenti sezioni anticiperò in dettaglio cosa verrà mostrato per ogni soggetto/per la valutazione del sistema.

Presentazione dei risultati dei soggetti

Nella prima parte del prossimo capitolo saranno mostrati, per ognuno dei soggetti, i risultati raggiunti. In dettaglio, per ogni soggetto si presenteranno:

- i. la timeline di ogni sessione di addestramento (analoghe a quelle mostrate in Figura 24 e Figura 25), per comprendere meglio la dinamica delle sessioni
- ii. un grafico mostrante in sequenza tutte le percentuali di pattern correttamente classificati nelle 6 sessioni di addestramento
- iii. una tabella contenente i risultati delle fasi di *Classification*, se e quando il soggetto ci sia arrivato
- iv. delle mappe topografiche dello scalpo che mostrano alcune “sorgenti EEG” identificate tramite metodo ICA (Independent Component Analysis), durante l’immaginazione motoria della mano destra e sinistra. In particolare si mostreranno, tra le sorgenti identificate, quelle associabili ai fenomeni di ERD controlaterale e ERS ipsilaterale relativi all’immaginazione motoria dei movimenti delle mani. Questo particolare risultato riguarda le sorgenti separate al termine della sessione in cui il soggetto ha presentato le migliori performances, considerando tutti i segnali della sessione. Poiché, tramite il metodo ICA, le sorgenti vengono stimate a meno del segno, si userà una mappa di colore simmetrica rispetto allo zero.
- v. un breve commento finale su ogni partecipante, includendo anche un altro grafico con le percentuali medie di pattern correttamente classificati in ogni sessione

Per quando riguarda il grafico di cui al punto ii), esso presenterà colorazioni diverse nello sfondo (bianco o grigio) per permettere di capire meglio quando finisce una sessione e ne inizia un’altra. Inoltre, saranno presenti linee tratteggiate verticali color magenta ogni volta che, all’interno di una sessione, si sia dovuto ripetere il *Training* per via di accuratezze di classificazione troppo basse. Nel grafico saranno infine mostrati, oltre alla percentuale totale di pattern correttamente classificati (linea nera spessa), anche le percentuali di pattern correttamente classificati per l’immaginazione della mano destra (linea sottile tratteggiata rossa) e della mano sinistra (linea sottile tratteggiata

blu). Per queste ultime tre informazioni è comunque presente anche una legenda.

Per quanto riguarda la tabella di cui al punto iii), contenente in forma sintetica i risultati delle fasi di *Classification*, essa includerà i seguenti indici:

- numero di volte in cui il soggetto non è riuscito a raggiungere il target (perché scaduto il timeout di 120s)
- rapporto medio tra il tempo impiegato per raggiungere il target e il tempo minimo necessario
- accuratezza media di classificazione, ottenuta valutando quante volte sul totale il soggetto abbia prodotto lo stato mentale corretto (quello che gli permetteva di muovere l'arto nella direzione giusta), indipendentemente dal fatto che il pattern prodotto fosse sotto- o sopra-soglia

Per il calcolo degli ultimi due parametri (rapporto medio tra tempo impiegato e tempo minimo necessario e accuratezza media di classificazione) si sono considerati solo i casi in cui il target sia stato raggiunto senza far scadere il timeout. Questa scelta è stata fatta perché si assume che tutte le volte che è scaduto il tempo sia perché dopo un po' di tentavi il soggetto si è demoralizzato e ha smesso di concentrarsi (aspettando solo il termine della prova).

Per quanto riguarda infine le mappe topografiche delle sorgenti, non è stato sempre immediato scegliere quali potessero essere associate a fenomeni di ERD/ERS. Dal momento che, infatti, il metodo ICA stima le sorgenti con varianza unitaria e non permette di stimare il segno, non si può sapere se queste siano associate a diminuzioni o aumenti della dell'ampiezza dei segnali in una certa zona. Si consideri inoltre, guardando anche l'immagine in Figura 9 relativa allo studio di Pfurtscheller e Neuper [61], che le aree in cui si osservano le desincronizzazioni/sincronizzazioni possono essere anche piuttosto vaste, e non necessariamente centrate su C3 e C4. Infine, essendo il numero di elettrodi utilizzato solo di 11, non si ha molta risoluzione spaziale in merito alla localizzazione delle sorgenti, e l'interpolazione potrebbe dare a volte risultati fuorvianti. Nella sezione di cui al punto

iv), dunque, si riporteranno le sorgenti che, a parere dell'autrice, possono essere associabili per localizzazione a fenomeni di ERD/ERS, tagliando fuori a volte altre sorgenti che, con qualche dubbio in più, potevano anche essere associabili agli stessi fenomeni.

Presentazione dei risultati del sistema

Uno dei motivi per cui si è progettato l'aggiornamento del filtro CSP e del classificatore SVM con le modalità descritte nel paragrafo precedente, era che questo permettesse di fornire al classificatore training set nel tempo sempre migliori in termini di separabilità. Per verificare che questo obiettivo sia stato raggiunto, sono state fatte delle prove offline.

In particolare, dopo ogni ripetizione di *Training e Updating*, si è quantificata la separabilità del training set facendo processare al classificatore gli stessi pattern di training, e contando il numero di misclassificazioni. Naturalmente, un ridotto numero di misclassificazioni indica una buona separabilità nel training set, e viceversa. Se l'obiettivo di miglioramento della qualità dei dati nel training set è stato raggiunto, allora il numero di misclassificazioni ad ogni ripetizione di *Training e Updating* deve avere andamento decrescente.

Come risultato, in questa sezione, si riporteranno dei grafici contenenti l'andamento nel tempo del numero di misclassificazioni. Diversamente dagli altri parametri che vengono calcolati mediamente all'interno di ogni sessione di addestramento (come ad esempio la percentuale media di pattern correttamente classificati della sessione), in questo caso è disponibile un nuovo dato ogni volta che venga rifatto il *Training*. Ciò significa che, se in una sessione di addestramento si richiede una volta di ripetere il *Training*, allora da quella sessione avrà in realtà due grafici sull'andamento del numero di misclassificazioni.

Per questioni di leggibilità, non potranno essere riportati i grafici relativi a tutte le volte che, complessivamente dai 4 soggetti, è stato ripetuto il *Training*. Si tenterà piuttosto di descrivere in generale il comportamento del sistema.

Seguirà infine un breve commento per constatare il raggiungimento o meno dell'obiettivo prefissato.

3. Risultati e Discussione

3.1 Soggetto DB

Timeline delle sessioni di addestramento

1^a sessione:

T U₁ U₂ U₃ U₄ U₅ U₆ U₇ U₈ U₉ U₁₀ U₁₁ T U₁₂ U₁₃ U₁₄ U₁₅ U₁₆

2^a sessione:

T U₁ U₂ U₃ T U₄ U₅ U₆ U₇ U₈ U₉ U₁₀ U₁₁ T U₁₂ U₁₃ U₁₄ U₁₅ U₁₆

3^a sessione:

T U₁ U₂ U₃ U₄ U₅ U₆ U₇ U₈ T U₉ U₁₀ U₁₁ U₁₂ U₁₃ U₁₄ U₁₅

4^a sessione:

T U₁ U₂ U₃ U₄ U₅ U₆ U₇ U₈ U₉ U₁₀ U₁₁ U₁₂ U₁₃ U₁₄ U₁₅ U₁₆ U₁₇

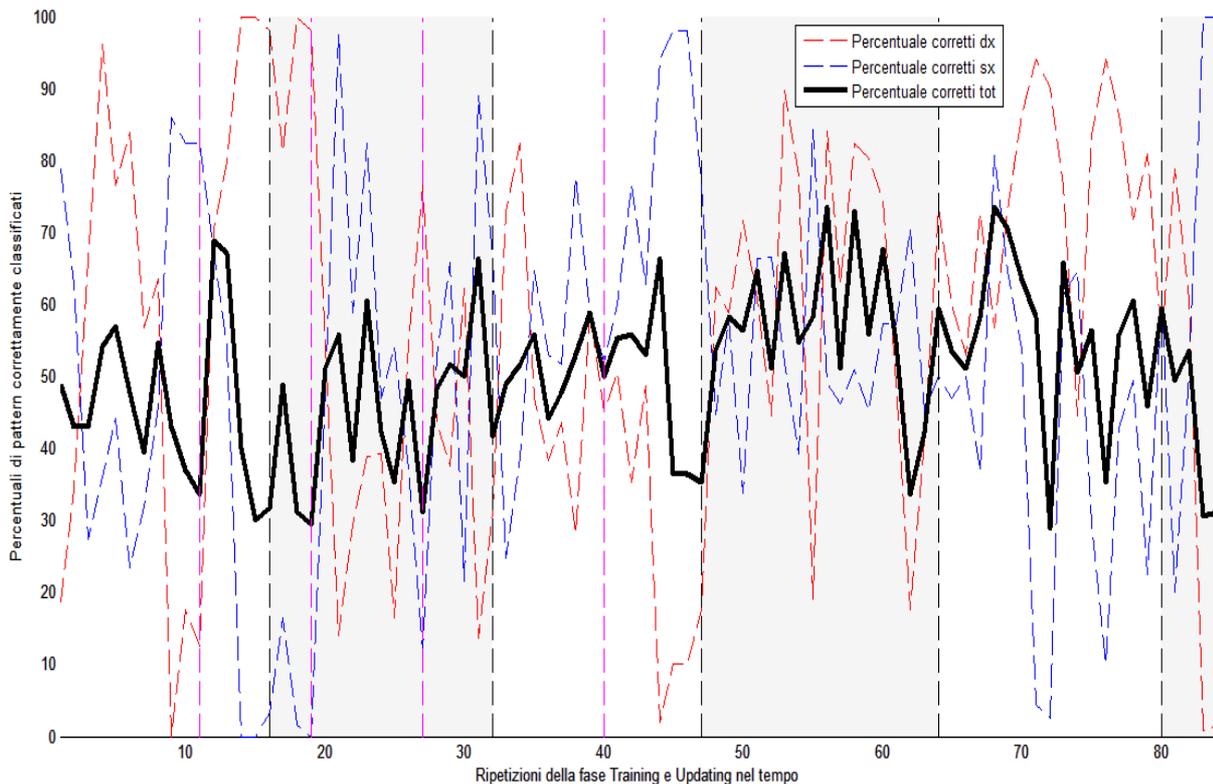
5^a sessione:

T U₁ U₂ U₃ U₄ U₅ U₆ U₇ U₈ U₉ U₁₀ U₁₁ U₁₂ U₁₃ U₁₄ U₁₅ U₁₆

6^a sessione:

T U₁ U₂ U₃ U₄ T U₅ U₆ U₇ U₈ U₉ U₁₀ U₁₁ U₁₂ U₁₃ U₁₄ U₁₅ U₁₆

Performances in fase di Training e Updating



Performances in Classification

Questo soggetto non ha mai raggiunto nel corso delle 6 sessioni di addestramento percentuali di pattern correttamente classificati adeguate per accedere alla fase di *Classification*.

Sorgenti ICA associabili a ERD/ERS (sessione migliore)

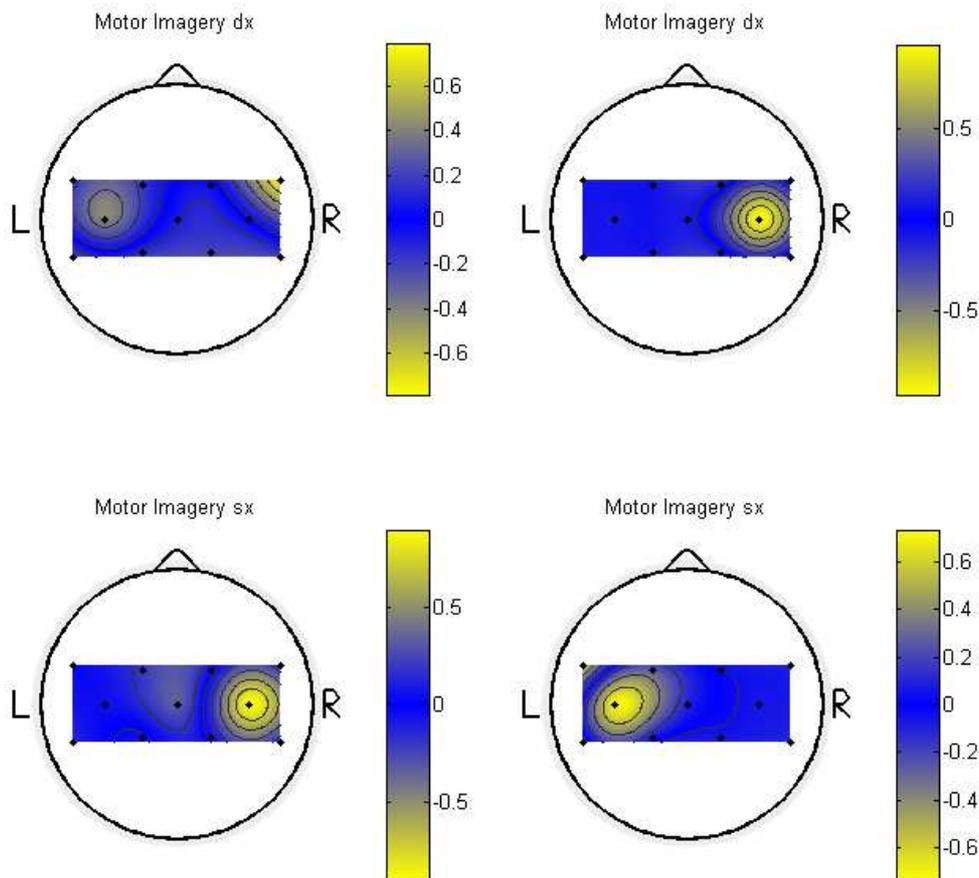


Figura 27. In figura le sorgenti identificate dal metodo ICA associabili (a parere dell'autrice) a fenomeni di ERD ed ERS legati all'immaginazione motoria. In particolare, l'ICA è stata portata a termine utilizzando tutti i dati relativi alla sessione migliore per il soggetto DB (sessione 4). Nella prima riga le sorgenti relative all'immaginazione della mano destra, con l'ERD controlaterale a sinistra e l'ERS ipsilaterale a destra. Nella seconda riga le sorgenti relative all'immaginazione motoria della mano sinistra, riportando sempre l'ERD controlaterale a sinistra e l'ERS ipsilaterale a destra.

Commento generale

All'inizio della sperimentazione, il Soggetto DB non aveva mai avuto alcuna esperienza in merito a sistemi BCI. Al termine delle sei sessioni di addestramento, durate in totale 186 minuti (3 h e 6 minuti), non si può ancora dire che il Soggetto abbia appreso a controllare il sistema tramite immaginazione motoria, né si evidenzia per ora un trend di crescita (Figura 28).

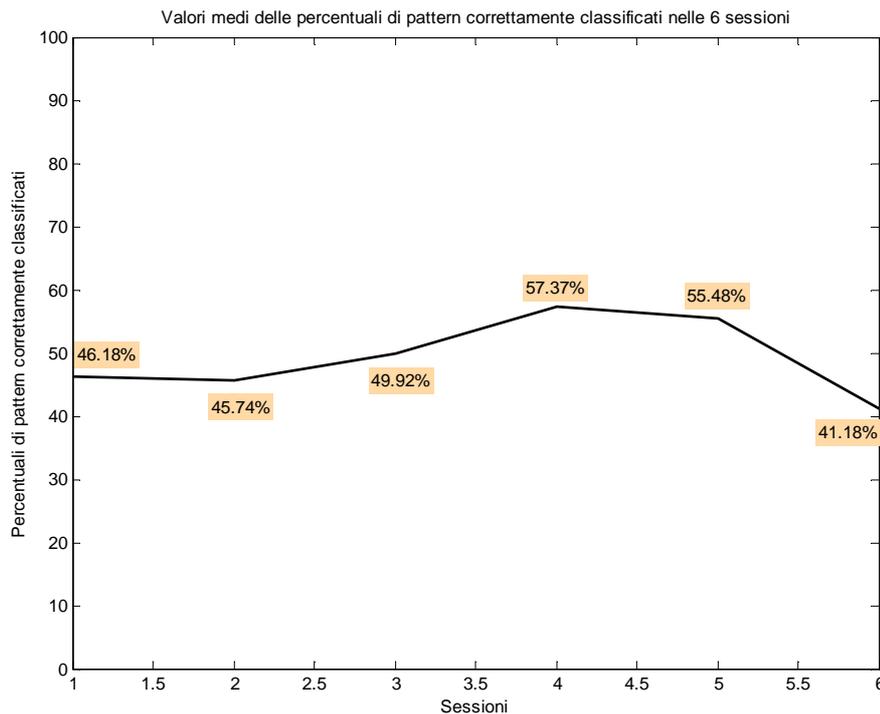


Figura 28 Valori medi delle percentuali di pattern corretti nelle 6 sessioni per il soggetto DB.

Durante le prime sessioni, non avendo mai avuto esperienze precedenti, il Soggetto DB ha esplorato diverse configurazioni mentali per cercare di individuare la strategia migliore. In effetti, si può notare anche dalle *timeline* come durante le prime tre sessioni sia stato richiesto più volte di ripetere il *Training* per via di percentuali di pattern correttamente classificati troppo basse. Durante la quarta sessione, in corrispondenza della quale la persona ha asserito di aver trovato la strategia mentale per lei più favorevole, si sono in effetti registrate le performances migliori (percentuale media di pattern

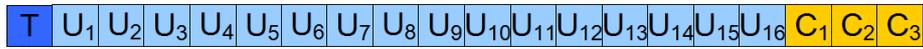
correttamente classificati pari al 57.37%, che sfiora quasi la soglia del 58% individuata da Mueller-Putz et al. [79]). Nonostante questo, come si evince osservando i dati delle successive due sessioni, per ora il soggetto non è riuscito a ripetere o migliorare il risultato ottenuto durante la quarta esperienza, per cui probabilmente sono necessarie ulteriori sessioni di addestramento per vedere un'evoluzione.

Alla fine della sperimentazione, la persona ha anche rivelato di aver avuto difficoltà a mettere a fuoco esperienze cinestetiche relativamente all'immaginazione motoria, focalizzandosi più spesso su una semplice visualizzazione del movimento. Ad ogni modo, osservando i risultati della ICA (Figura 27) al termine della sessione migliore (sessione 4), si può notare come siano state rilevate sorgenti probabilmente correlabili alle ERD contro laterali (parte sinistra della figura) e alle ERS ipsilaterali (parte destra della figura), tipiche dell'immaginazione del movimento delle mani.

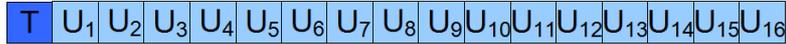
3.2 Soggetto ALM

Timeline delle sessioni di addestramento

1^a sessione:



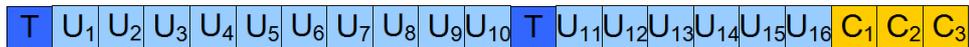
2^a sessione:



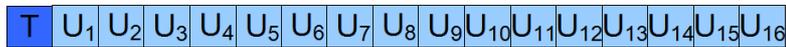
3^a sessione:



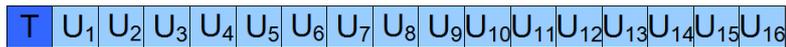
4^a sessione:



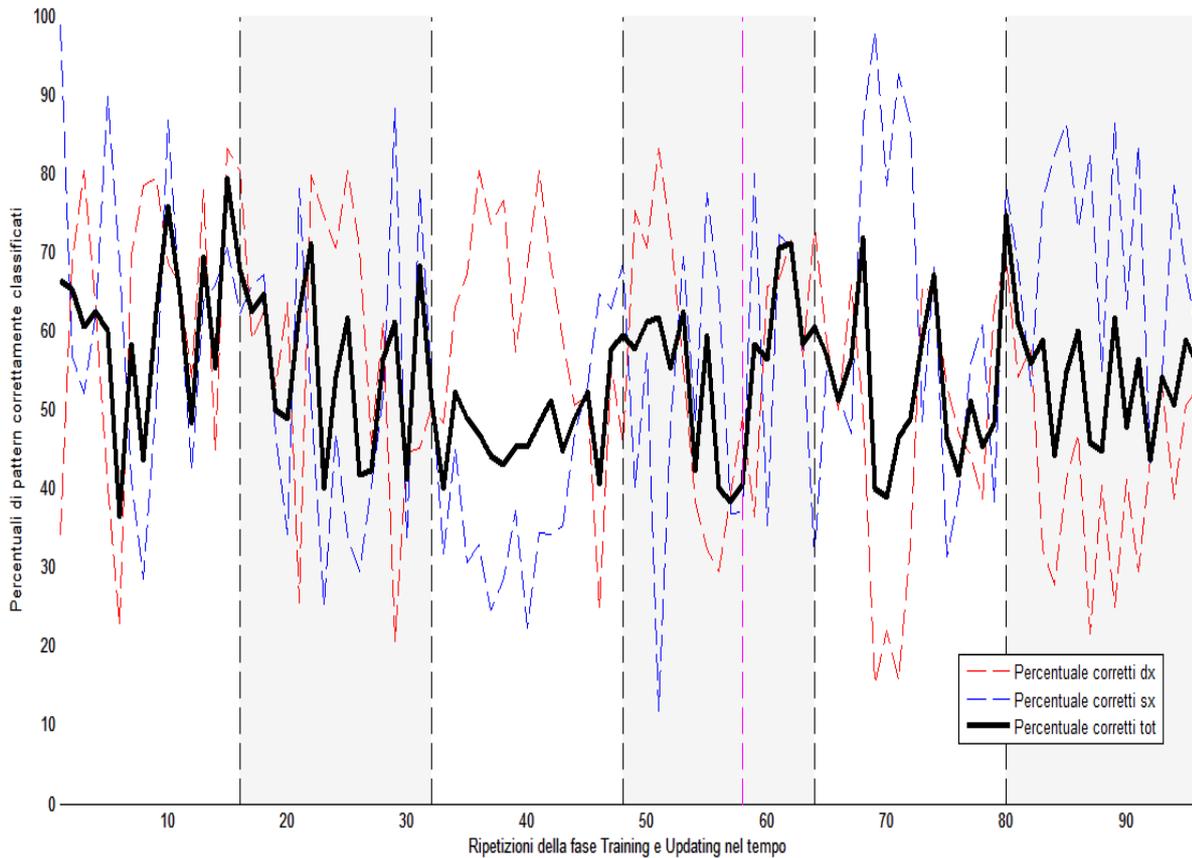
5^a sessione:



6^a sessione:



Performances in fase di Training e Updating



Performances in Classification

	N° di volte in cui il target non è stato raggiunto	Rapporto medio tra tempo impiegato e tempo minimo per raggiungere il target	Percentuale di pattern corretti
Sessione 1	0 su 15	11.47	60.13%
Sessione 4	1 su 15	9.33	64.83%

Sorgenti ICA associabili a ERD/ERS (sessione migliore)

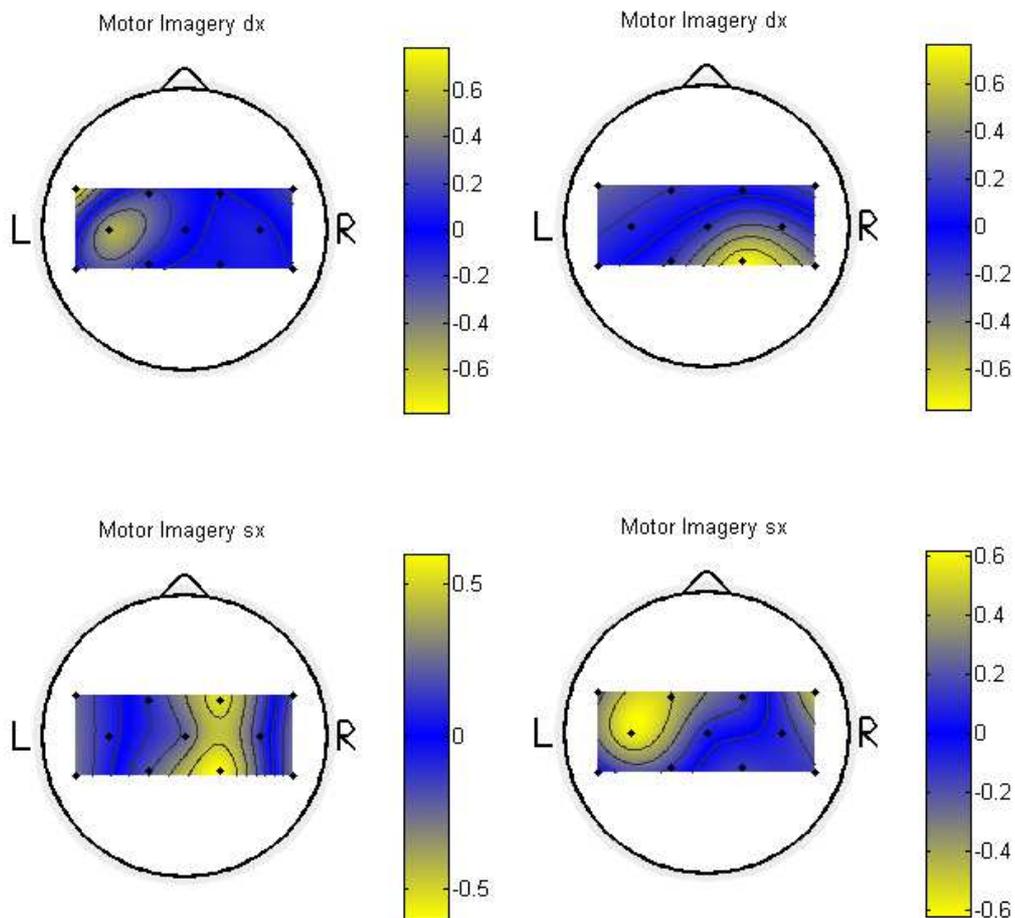


Figura 29. In figura le sorgenti identificate dal metodo ICA che associabili (a parere dell'autrice) a fenomeni di ERD ed ERS legati all'immaginazione motoria. L'ICA è stata portata a termine utilizzando tutti i dati relativi alla sessione migliore per il soggetto ALM (sessione 4, parte 2). Per la disposizione delle immagini l'ordine è lo stesso della **Figura 27** (spiegazione nella didascalia), con gli ERD controlaterali a sinistra e gli ERS ipsilaterali a destra.

Commento generale

Il soggetto ALM, che all'inizio della sperimentazione aveva alle spalle 261 minuti di training su immaginazione motoria da precedenti esperienze su sistemi BCI, ha effettivamente riportato risultati mediamente migliori rispetto al soggetto DB. Addirittura, al termine della prima e della quarta sessione, il soggetto ha anche avuto accesso alla fase di *Classification* (entrambe le volte perché la media delle percentuali delle ultime sei ripetizioni di *Training e Updating* era superiore al 58%).

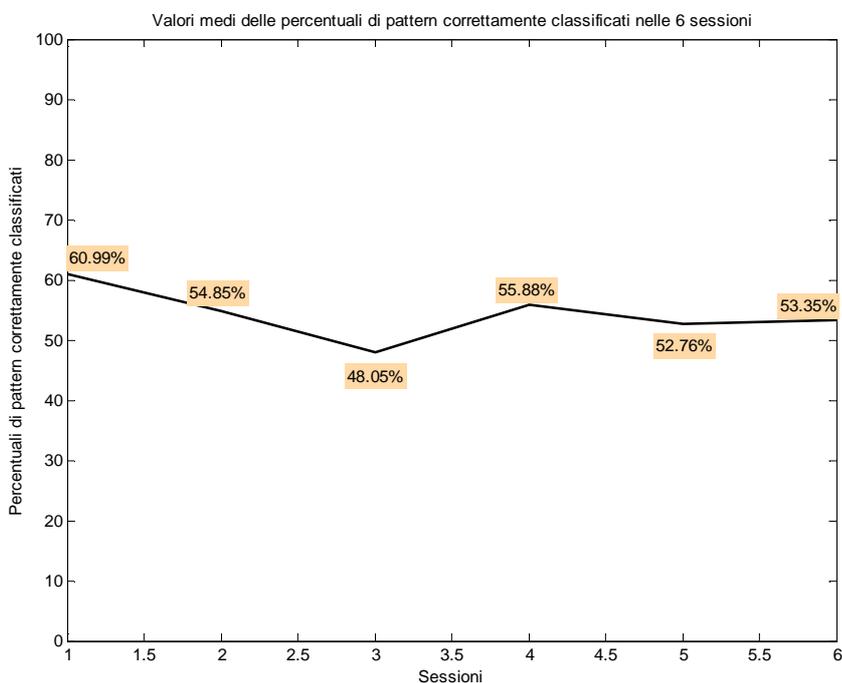


Figura 30. Valori medi delle percentuali di pattern corretti nelle 6 sessioni per il soggetto ALM

Avendo il soggetto già avuto precedenti esperienze BCI, la strategia d'immaginazione motoria utilizzata è rimasta di volta in volta invariata, senza sperimentare particolari variazioni. Inoltre, la persona ha rivelato di aver cercato di prediligere esperienze cinestetiche, piuttosto che la semplice visualizzazione del movimento. In effetti, osservando le mappe topografiche (Figura 29) risultanti dell'analisi ICA della sessione migliore (parte 2 della quarta sessione), sono state trovate sorgenti EEG associabili, a parere dell'autrice, a fenomeni di

ERD controlaterale (parte sinistra della figura) e ERS ipsilaterale (parte destra della figura), tipiche dell'immaginazione del movimento delle mani.

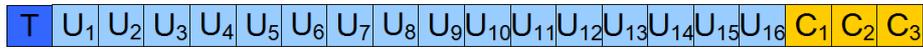
Osservando la Figura 30 si potrebbe pensare che il soggetto ALM, non essendo riuscito in 5 sessioni su 6 a superare mediamente il valore di soglia del 58%, non sia realmente in grado di attuare un controllo sul sistema. In realtà, guardando invece alle performances durante le due sessioni di *Classification*, si può notare che in entrambi i casi la percentuale di pattern corretti stimata superi il livello di soglia. Inoltre, sebbene il rapporto medio tra il tempo impiegato per raggiungere il target e il tempo minimo sia piuttosto elevato, comunque il target è stato raggiunto 29 volte su 30, senza far scadere il timeout.

Dagli elementi appena forniti si può intuire che il soggetto abbia già acquisito effettivamente un certo livello di controllo sul sistema, anche se la tecnica può essere certamente perfezionata. Probabilmente, per migliorare le performances, sono semplicemente necessarie altre sessioni di addestramento.

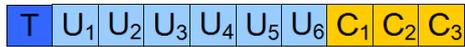
3.3 Soggetto MR

Timeline delle sessioni di addestramento

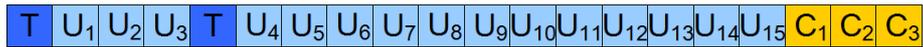
1^a sessione:



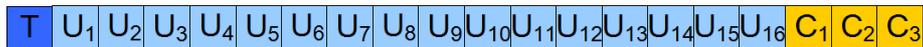
2^a sessione:



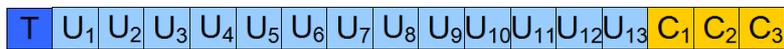
3^a sessione:



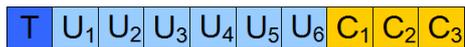
4^a sessione:



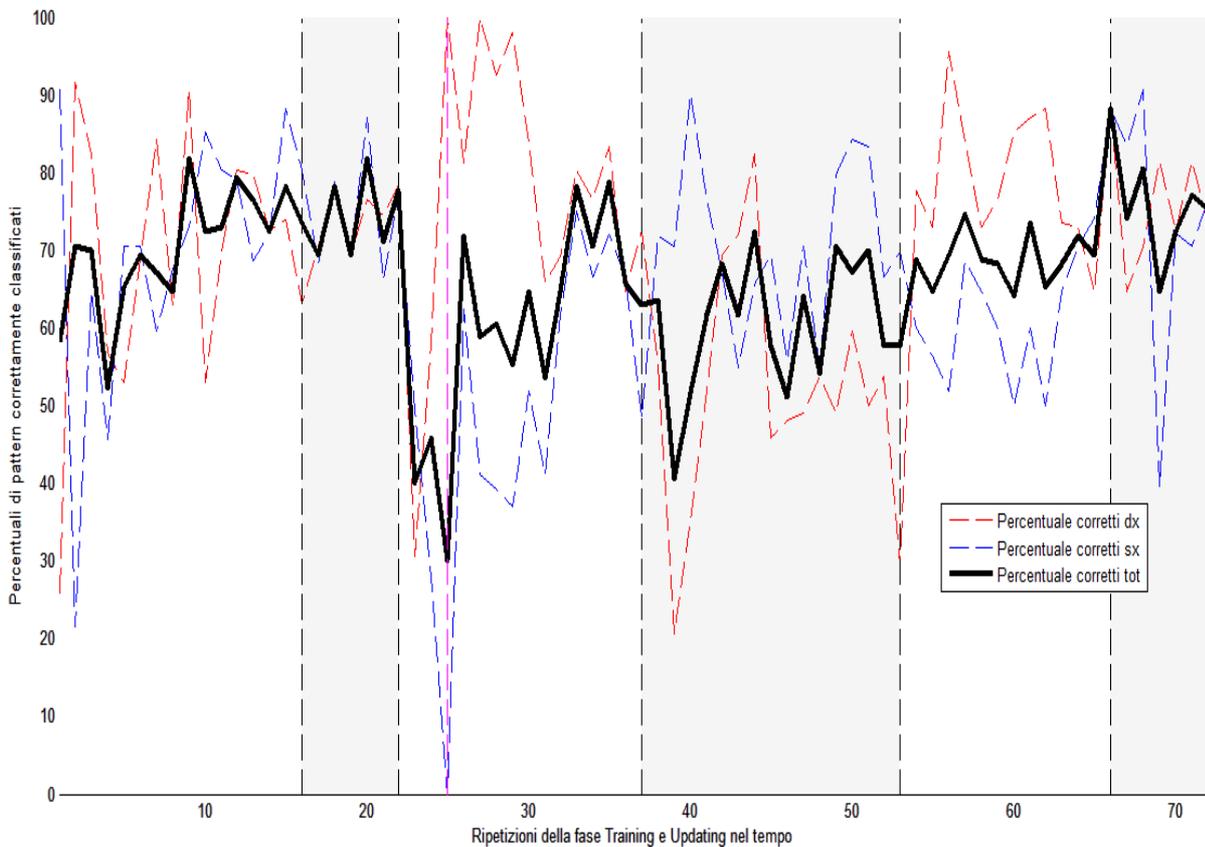
5^a sessione:



6^a sessione:



Performances in fase di Training e Updating



Performances in Classification

	N° di volte in cui il target non è stato raggiunto	Rapporto medio tra tempo impiegato e tempo minimo per raggiungere il target	Percentuale di pattern corretti
Sessione 1	3 su 15	3.82	75.46%
Sessione 2	1 su 15	2.81	74.52%
Sessione 3	4 su 15	5.99	57.83%
Sessione 4	3 su 15	7.73	58.33%
Sessione 5	1 su 15	4.10	66.61%
Sessione 6	0 su 15	2.50	74.22%

Sorgenti ICA associabili a ERD/ERS (sessione migliore)

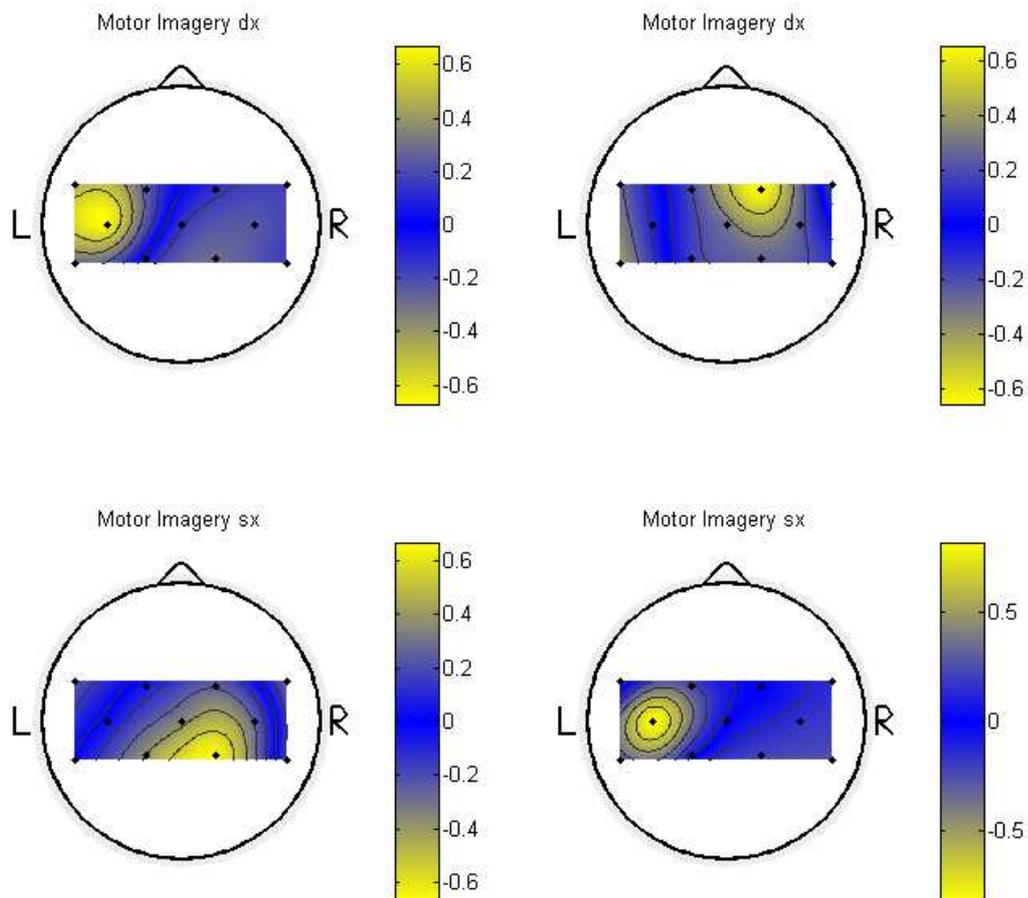


Figura 31. In figura le sorgenti identificate dal metodo ICA associabili (secondo l'autrice) a fenomeni di ERD ed ERS legati all'immaginazione motoria. L'ICA è stata portata a termine utilizzando i dati della sessione migliore per il soggetto MR (sessione 2). Per ulteriori dettagli sulla disposizione si veda la didascalia della **Figura 27**.

Commento generale

Anche se il soggetto MR, come il soggetto DB, non aveva mai avuto esperienze BCI antecedenti la sperimentazione, ha presentato da subito risultati notevoli (percentuale media $>70\%$ già nella prima sessione, con punte sopra l'80%). Addirittura, già durante la prima sessione il soggetto avrebbe avuto diritto a passare anticipatamente a *Classification*, perché la media delle percentuali di pattern corretti delle ultime 6 volte superava il 70%. Poiché però quella era per il soggetto la prima sessione in assoluto, si è richiesto comunque di completarla con le 16 ripetizioni di *Training e Updating*. Anche nella seconda sessione la persona ha confermato i risultati (Figura 32), potendo così accedere a *Classification* subito dopo le prime 6 ripetizioni di *Training e Updating*.

Durante la terza e la quarta sessione si può notare un calo delle performances. È giusto tuttavia riportare anche che durante queste due sessioni, svolte all'interno della stessa giornata, l'ambiente in cui si è svolta la sperimentazione fosse un po' più rumoroso. Inoltre il soggetto, dopo l'iniziale insuccesso della terza sessione (si è dovuto ripetere il *Training* dopo poco), si era un po' innervosito e deconcentrato. In effetti, durante la quinta e la sesta sessione la persona ha nuovamente riportato percentuali di pattern correttamente classificati elevate, considerando la sua iniziale inesperienza, e in linea con quelle delle prime due sessioni (Figura 32).

Le performances raggiunte dal soggetto nelle fasi di *Classification* sono coerenti con quelle raggiunte mediamente all'interno della relativa sessione.

Osservando la Figura 32, le performances per esteso durante *Training e Updating* i risultati di *Classification*, non si può dire che nel corso della sperimentazione si sia evidenziato un trend positivo. Probabilmente, anche in questo caso sono necessarie più sessioni di addestramento per vedere un'ulteriore evoluzione. Ad ogni modo, il soggetto ha riportato in media percentuali di pattern correttamente classificati davvero notevoli considerando l'iniziale inesperienza.

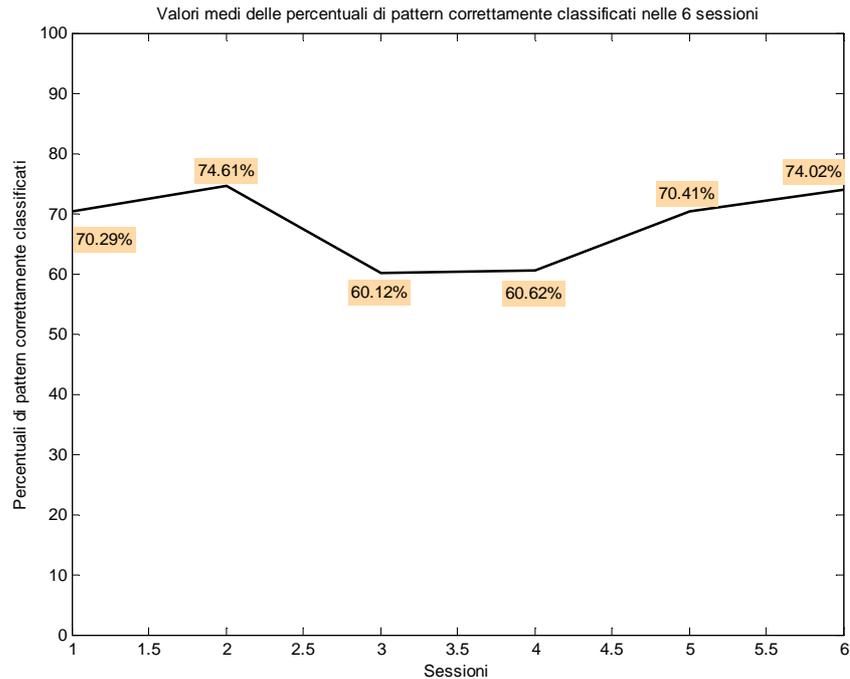


Figura 32. Valori medi delle percentuali di pattern corretti nelle 6 sessioni per il soggetto MR

Chiedendo alla persona maggiori informazioni circa la strategia da lei utilizzata, essa ha rivelato di aver individuato da subito un binomio di configurazioni mentali che sembravano funzionare, e di aver dunque continuato con quella strategia fino alla fine. Il soggetto ha inoltre aggiunto di essersi concentrato a fondo sull'esperienza cinestetica (cercava di "sentire la fatica" dell'atto motorio immaginato), e di essersi aiutato a raggiungere la concentrazione aggiungendo dettagli "non motori" (uno sfondo, una situazione, una condizione atmosferica immaginata) a ogni stato mentale.

Per quanto riguarda i risultati dell'analisi ICA della sessione migliore (sessione 2), le sorgenti trovate mostrate in Figura 31 potrebbero effettivamente essere correlate ai fenomeni di ERD controlaterale (parte sx della figura) ed ERS ipsilaterale (parte dx della figura), associati all'immaginazione del movimento delle mani.

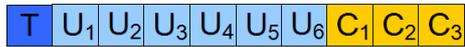
3.4 Soggetto VM

Timeline delle sessioni di addestramento

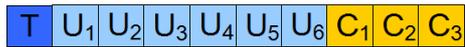
1^a sessione:



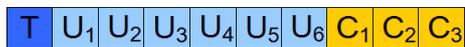
2^a sessione:



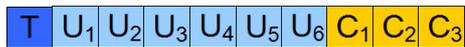
3^a sessione:



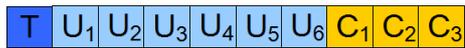
4^a sessione:



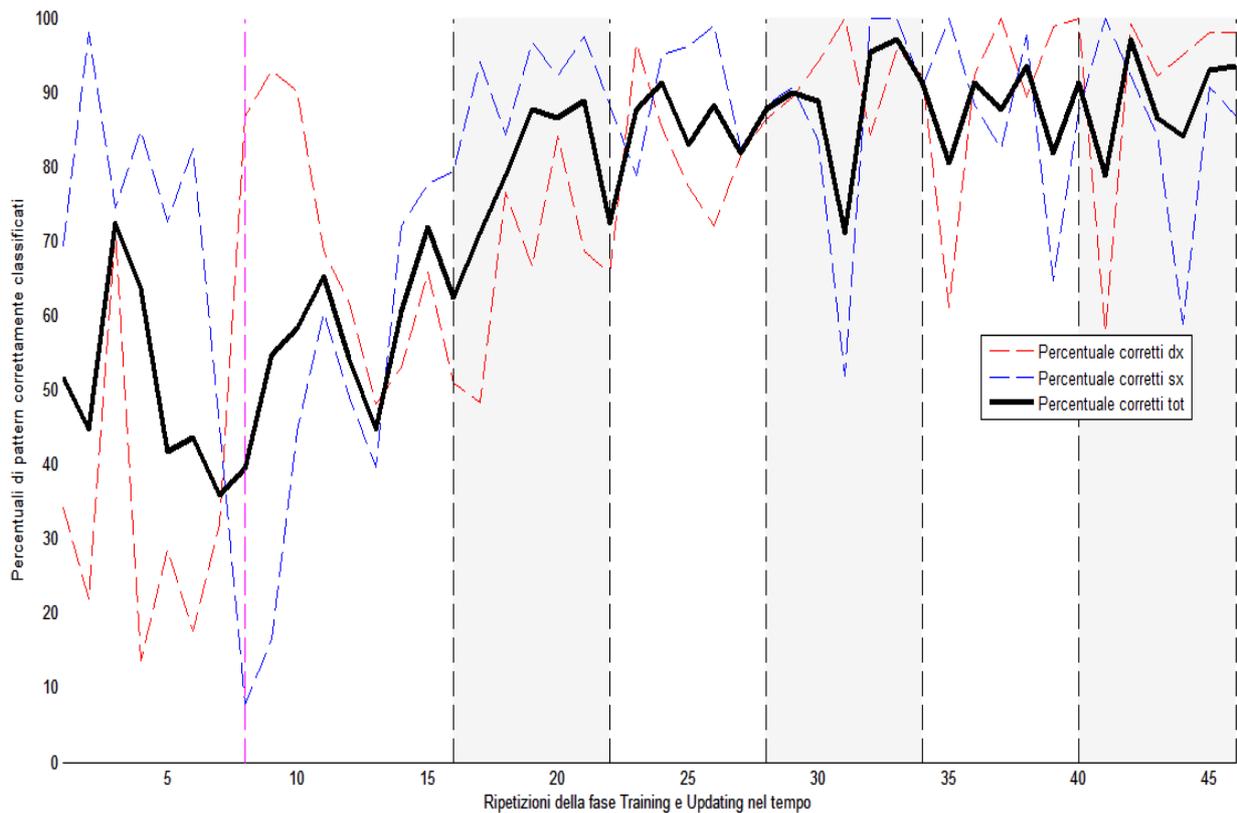
5^a sessione:



6^a sessione:



Performances in fase di Training e Updating



Performances in Classification

	N° di volte in cui il target non è stato raggiunto	Rapporto medio tra tempo impiegato e tempo minimo per raggiungere il target	Percentuale di pattern corretti
Sessione 1	0 su 10	2.83	68.34%
Sessione 2	0 su 15	1.46	89.10%
Sessione 3	0 su 15	1.32	90.74%
Sessione 4	0 su 15	1.52	84.95%
Sessione 5	0 su 15	1.20	96.53%
Sessione 6	0 su 15	1.35	91.08%

Sorgenti ICA associabili a ERD/ERS (sessione migliore)

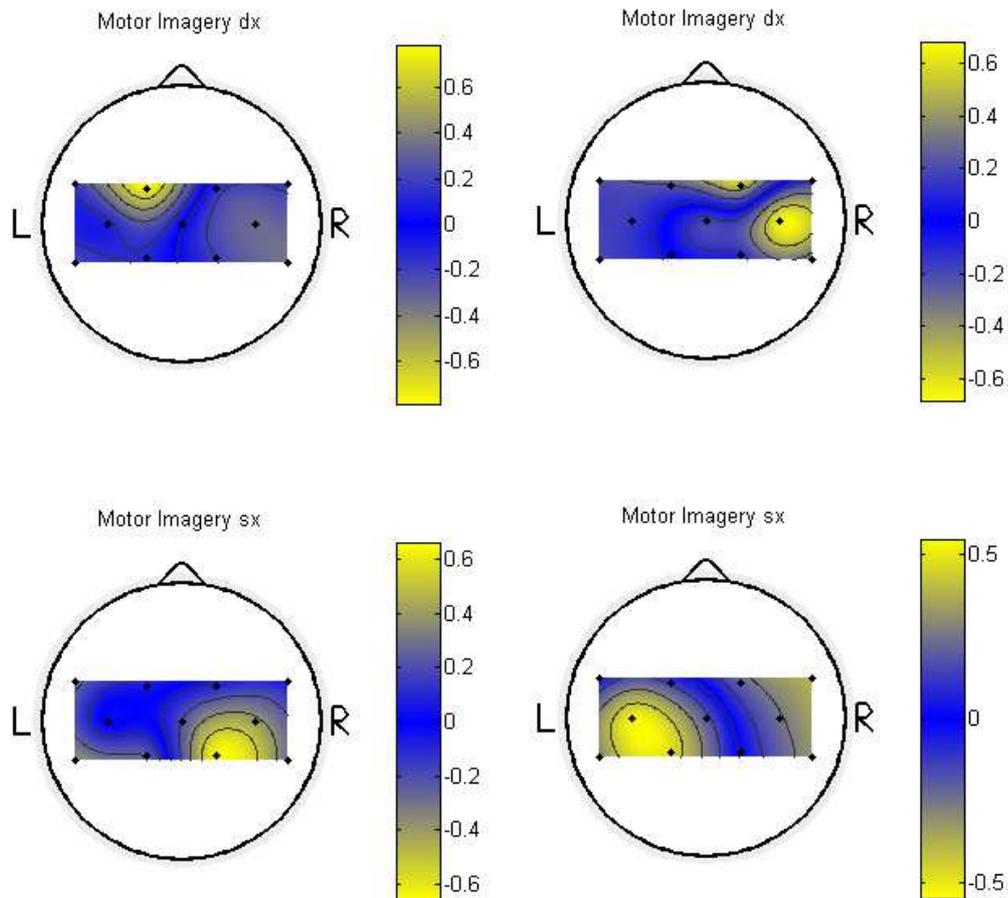


Figura 33 In figura le sorgenti identificate dal metodo ICA associabili (secondo l'autrice) a fenomeni di ERD ed ERS legati all'immaginazione motoria. L'ICA è stata portata a termine utilizzando i dati della sessione migliore per il soggetto VM (sessione 4). Per ulteriori dettagli sulla disposizione si veda la didascalia della **Figura 27**.

Commento generale

Il soggetto VM è quello che, all'inizio della sperimentazione, aveva alle spalle la maggiore esperienza in termini di training su immaginazione motoria (461 minuti), da diversi sistemi BCI.

Nonostante le precedenti esperienze, il soggetto non ha identificato da subito la strategia per lui migliore. In effetti, durante la prima sessione è stato necessario ripetere il *Training* una volta per via di percentuali di pattern correttamente classificati inizialmente troppo basse. Nella seconda parte della prima sessione, dopo aver cambiato strategia, il soggetto ha mostrato invece un primo trend positivo, che gli ha permesso di avere accesso a *Classification*.

A partire dalla seconda sessione in poi, la persona ha identificato una strategia d'immaginazione motoria solida e ripetibile, che le ha permesso di mantenere nel tempo in modo stabile percentuali elevate di pattern correttamente classificati (mediamente sopra l'85% dalla terza sessione in poi, con punte del 96-97% nella quarta e nell'ultima sessione).

Anche le performances ottenute nelle fasi di *Classification* sono stabili: il target è stato raggiunto ogni volta, e dalla seconda sessione in poi anche i rapporti medi tra il tempo impiegato e il tempo minimo per raggiungere il target sono piuttosto ridotti (<1.6). Nella sessione di *Classification* più favorevole, inoltre, il soggetto ha presentato mediamente una percentuale di pattern correttamente classificati del 96.53%.

Le buone performances ottenute da questo soggetto sono senz'altro anche dovute dalla precedente esperienza su altri sistemi BCI basati su immaginazione motoria. Inoltre, il soggetto ha rivelato di aver cercato più di tutto di concentrarsi su esperienze cinestetiche legate all'immaginazione motoria. Per fare questo, la persona ha richiamato alla mente l'immaginazione motoria di movimenti delle dita legati all'esecuzione di note al pianoforte. Tali movimenti erano ben noti e richiamabili dal soggetto con una certa precisione, ed erano fortemente legati all'esperienza cinestetica più che a una semplice visualizzazione.

In effetti, anche dall'analisi ICA della sessione migliore (sessione 4), sono state rilevate sorgenti che potrebbero essere correlate all'ERD controlaterale (parte sinistra della Figura 33) e ERS ipsilaterale (parte destra della Figura 33), associati all'immaginazione motoria del movimento delle mani.

Le performances ottenute dal soggetto VM dimostrano come il sistema implementato possa lavorare bene, nel momento in cui il soggetto impara come controllarlo. Probabilmente, in una persona paralizzata da tempo sarà difficile trovare subito movimenti immaginari richiamabili con precisione. Ad ogni modo, dopo il training necessario, grazie a questi risultati ora sappiamo che il sistema può potenzialmente funzionare.

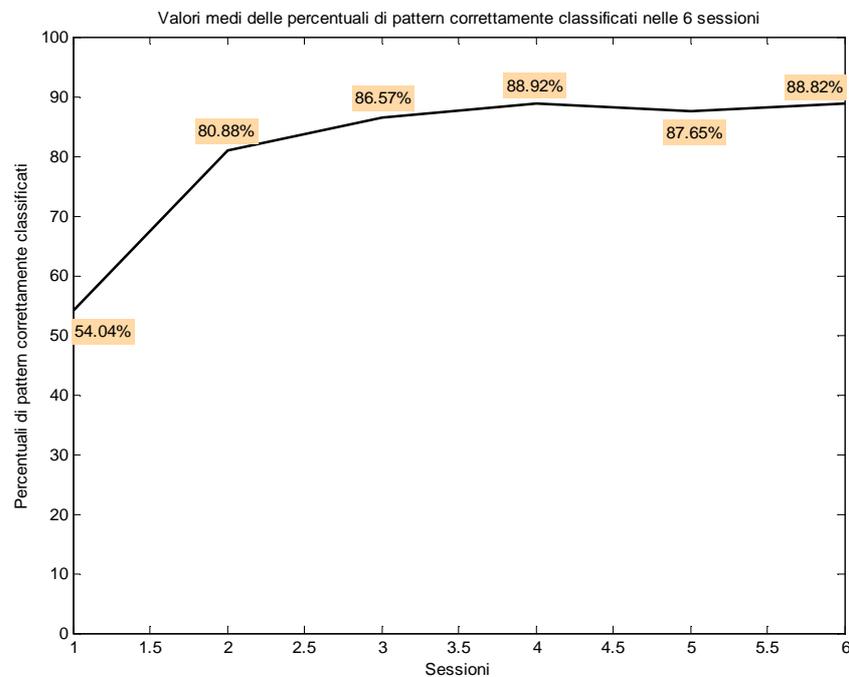


Figura 34. Valori medi delle percentuali di pattern corretti nelle 6 sessioni per il soggetto VM

3.5 Performances del sistema

Evoluzione della separabilità del training set

Come visibile dalle *timeline* delle sessioni di addestramento dei soggetti presentate ai paragrafi precedenti, sebbene siano state 6 le sessioni di addestramento per ogni soggetto, in realtà il numero totale di ripetizioni della fase di *Training* è stata di 32. Alle 24 (6 sessioni x 4 soggetti) fasi di *Training* all'inizio di ogni sessione se ne aggiungono infatti altre 8 derivanti dalla necessità, a volte, di ripetere il *Training* per via di performance di classificazione troppo basse (spiegazione al paragrafo 2.2). Ciò significa che la seguente descrizione riguarda un totale di **32 grafici** sull'andamento del numero di misclassificazioni all'interno del training set nel tempo.

Ciò che è risultato in generale da queste 32 evoluzioni è che:

- da **26 su 32** grafici (**81.25%**) è emerso un andamento decrescente del numero di misclassificazioni all'interno del training set nel tempo (andamento tipico in Figura 35)
- in **5 su 32** grafici (**15.63%**) il numero di misclassificazioni è rimasto circa costante nel tempo. Tutti questi 5 andamenti sono relativi a casi in cui è stato poi chiesto di ripetere il *Training* per via di percentuali di pattern correttamente classificati troppo basse (andamento tipico in Figura 36)
- solo in **1 caso su 32** è emerso un lieve aumento del numero di misclassificazioni nel tempo, nella parte finale (andamento in Figura 37)
- in **20 su 32** casi (**62.5%**), oltre all'andamento nettamente decrescente ad un certo punto il numero di misclassificazioni si è anche azzerato (andamento tipico in Figura 38)

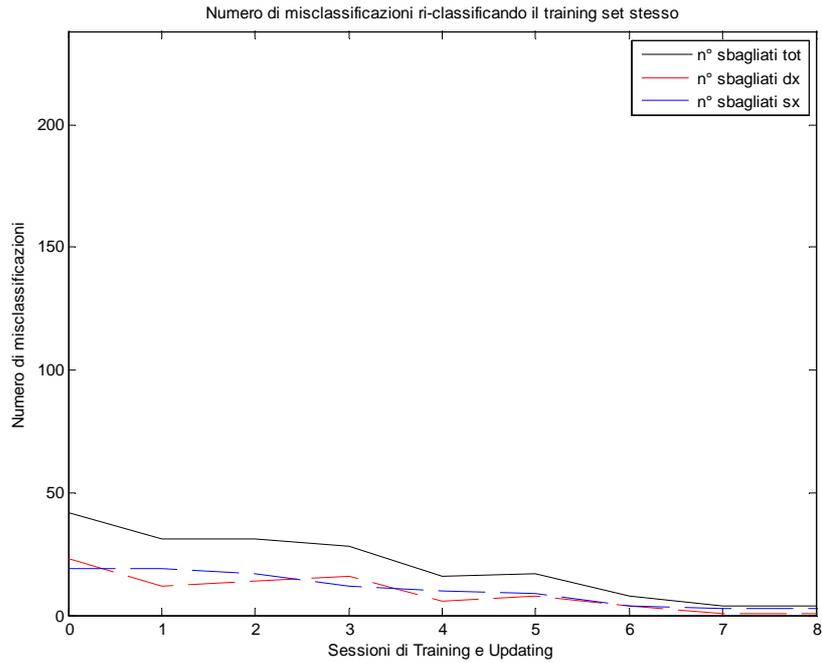


Figura 35. Uno dei 26 grafici con andamento decrescente del numero di misclassificazioni nel training set. Il particolare grafico è quello relativo al soggetto VM, sessione 1 prima del reset con nuova fase di Training

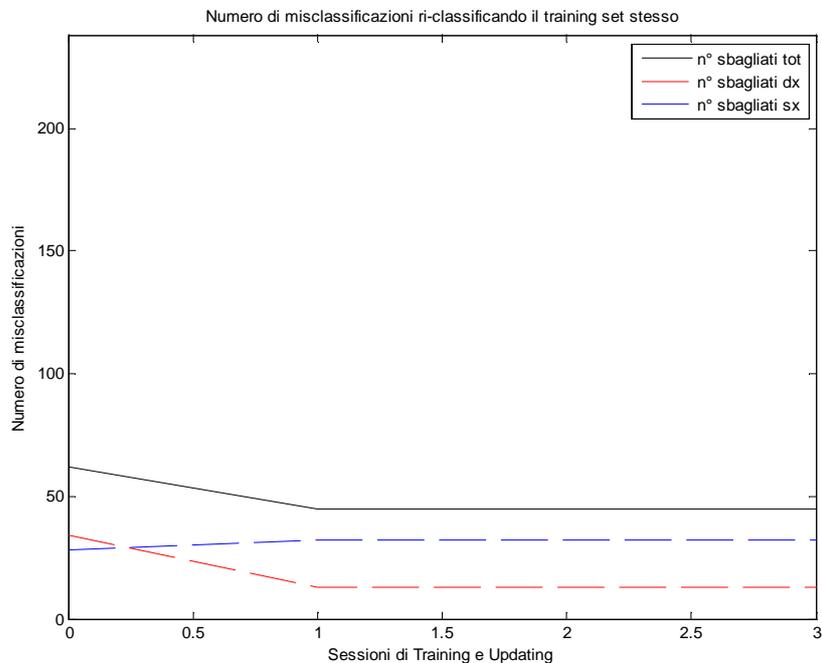


Figura 36. Uno dei 5 grafici in cui il numero di misclassificazioni rimane circa costante. Il particolare grafico è relativo al Soggetto DB, sessione 1 prima di ripetere il Training

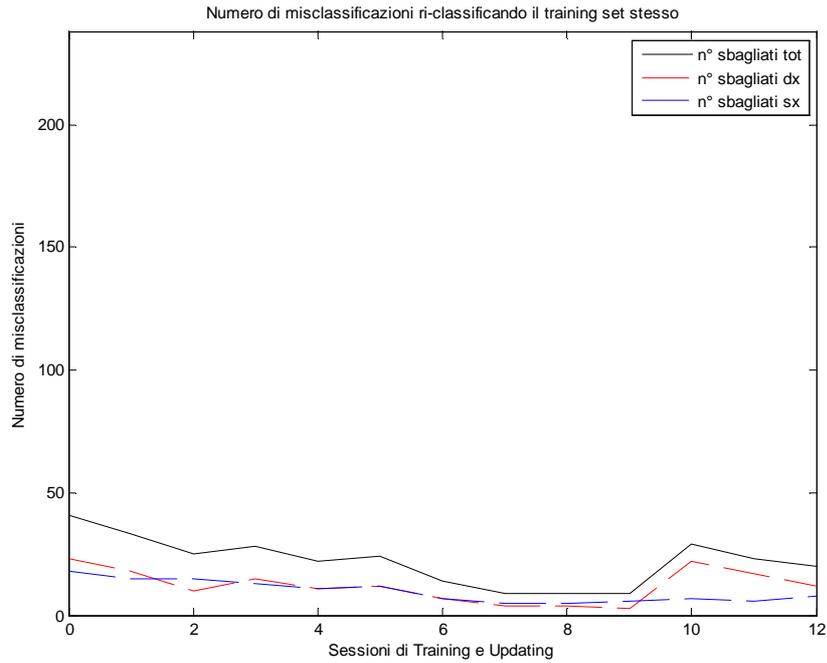


Figura 37 L'unico caso in cui il numero di misclassificazioni presenta un lieve aumento dopo 9 ripetizioni della fase Training e Updating. Il particolare grafico fa riferimento al Soggetto DB, Sessione 6 dopo aver anche ripetuto il Training per la seconda volta.

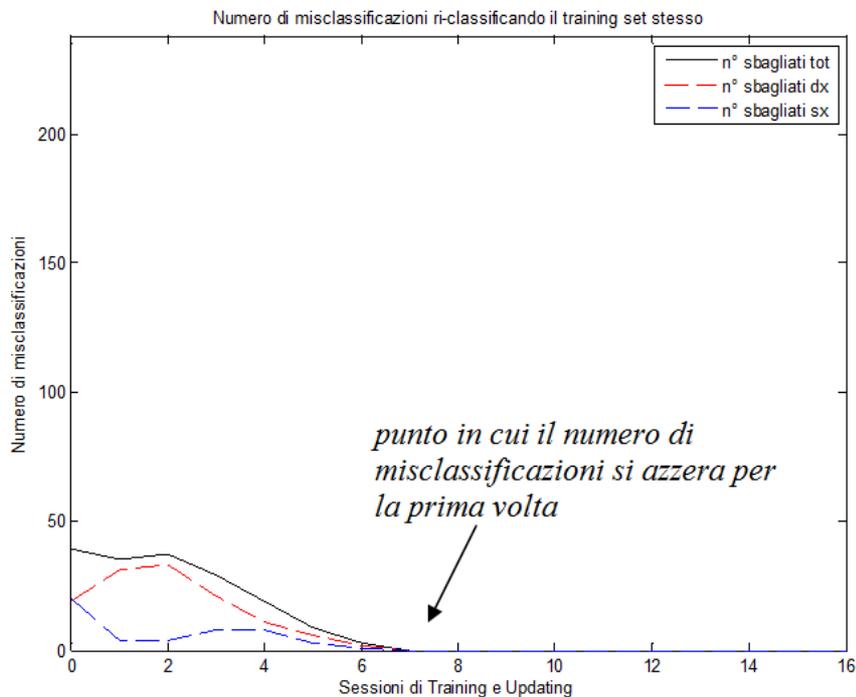


Figura 38 Uno dei 20 casi in cui il numero di misclassificazioni è arrivato ad azzerarsi. Il particolare grafico fa riferimento al soggetto MR, Sessione 1. In figura è evidenziato anche il punto in cui il numero iniziale di misclassificazioni si azzerava.

I 20 su 32 casi (**62.5%**) in cui, oltre ad avere andamento decrescente, il numero di misclassificazioni arriva ad azzerarsi, sono stati ulteriormente analizzati.

In particolare, si è indagata l'esistenza di una relazione tra la rapidità di azzeramento del numero di misclassificazioni e le performances del soggetto. Per farlo si è plottato, per ognuno dei 20 casi, il numero di ripetizioni di Training e Updating necessarie a far azzerare la prima volta le misclassificazioni (Figura 38, Figura 39) in funzione della percentuale media di pattern correttamente classificati in quel particolare caso.

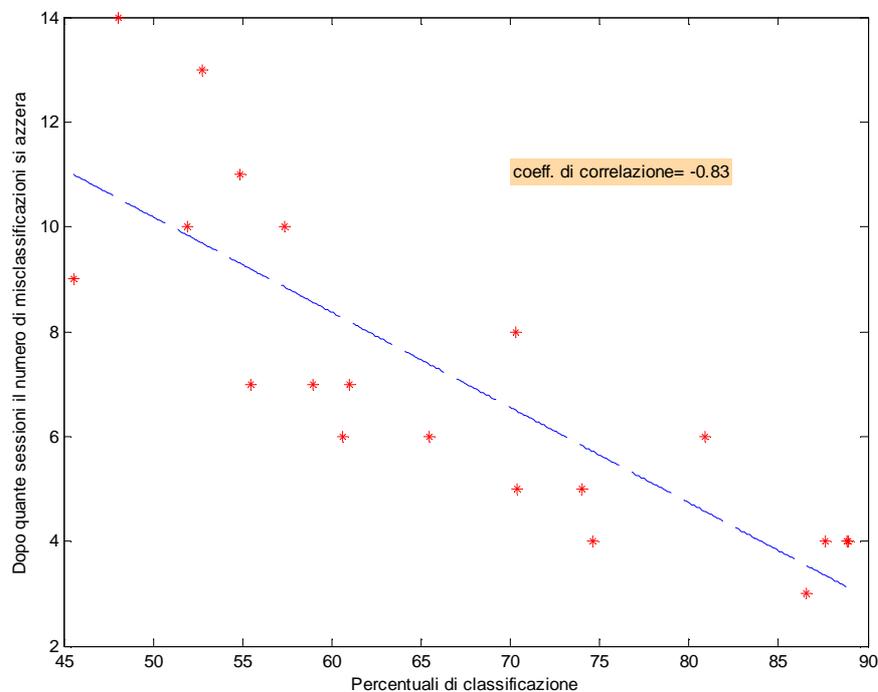


Figura 39. Numero di ripetizioni di Training e Updating necessarie per azzerare l'errore di misclassificazione in funzione delle percentuali medie di pattern correttamente classificati in quel particolare caso. I dati presentano una correlazione negativa, con coefficiente di correlazione $r=-0.83$

Commento generale

Dai dati presentati nella precedente sezione è possibile asserire che la modalità di aggiornamento del filtro CSP + classificatore SVM implementata (spiegazione al paragrafo 2.2) favorisce effettivamente il

miglioramento nel tempo della qualità dei dati all'interno del training set.

In effetti, come si è visto, in 26 casi su 32 (81.25%) il numero di misclassificazioni all'interno del training set mostra nel tempo un trend negativo. Non solo, anche i 5 casi su 32 in cui il numero di misclassificazioni rimane circa costante possono essere guardati positivamente per due motivi:

1. la “qualità” dei dati nel training set rimane sì circa costante, ma almeno non peggiora
2. in tutti e 5 questi casi si è richiesto di ripetere poi il *Training*, per via di percentuali di pattern correttamente classificati troppo basse

Dunque, anche se il trend non è sempre nettamente negativo, almeno la modalità di aggiornamento implementata sembra mediamente assicurare un non-incremento del numero di misclassificazioni anche in casi sfavorevoli, in cui il soggetto non è ancora abbastanza addestrato. In questo senso il sistema sembra essere abbastanza stabile.

Solo 1 caso su 32 (Figura 37) ha mostrato un andamento ambiguo, per via del lieve aumento finale del numero di misclassificazioni.

Un altro aspetto confortante è l'andamento mostrato in Figura 39. Il numero di step necessari all'azzeramento delle misclassificazioni mostra infatti in queste 20 prove una buona correlazione negativa con la percentuale media di pattern correttamente classificati (coeff. di correlazione=-0.83). Ciò significa che più il soggetto si addestra, più le sue performances migliorano, più in teoria ci si può aspettare di raggiungere un training set “pulito” in pochi step.

In conclusione, la modalità di aggiornamento presentata sembra mostrare, almeno sui dati a disposizione, oltre a buona stabilità quando le performances del soggetto non sono ancora buone, anche una buona risposta quando queste invece migliorano. In particolare, più il soggetto incrementa le sue performances, più rapidamente il training set migliora.

3.6 Discussione generale

In quest'ultima parte del capitolo "Risultati e Discussione" si tenterà di contestualizzare il presente lavoro di tesi, confrontando il sistema implementato e le performances ottenute con i risultati riscontrati in letteratura. Seguirà una breve discussione su quali miglioramenti possano essere apportati al sistema, prima di trarre le conclusioni nell'ultima parte di questo lavoro.

Confronto con la letteratura

Per poter contestualizzare il presente lavoro di tesi, sono stati ricercati in letteratura lavori aventi qualche punto in comune con il sistema qui descritto, in modo da poter fare un confronto e ragionare su dei possibili miglioramenti. In particolare, si farà riferimento in questa sezione ai lavori di Guger et al. [63] e di Ramoser et al. [72], aggiungendo anche contributi ed idee da altri documenti. Entrambi gli studi si riferiscono a sistemi BCI EEG-based, e la strategia di controllo utilizzata in ambo i casi è l'immaginazione motoria della mano destra vs mano sinistra.

Nel lavoro di Guger et al. [63] è stato realizzato e testato un sistema BCI in grado di processare in real-time i dati acquisiti, mediante filtro CSP e classificatore lineare. In questo lavoro, il sistema è stato provato su tre soggetti, di età compresa tra i 17 e i 26 anni, pagati per l'esperimento. Tutti e tre i soggetti avevano già partecipato in precedenza ad esperimenti BCI che includessero l'immaginazione motoria della mano destra vs sinistra, e avevano rispettivamente un'esperienza pregressa di 23, 5 e 7 sessioni (ogni sessione composta da 160 trial da 8s l'uno). Durante l'esperimento, i segnali cerebrali sono stati acquisiti da 27 elettrodi concentrati sull'area della corteccia motoria/sensoriale primaria. I segnali, analogamente al sistema qui descritto, erano poi filtrati nella banda 8-30Hz, mentre il riferimento usato era quello auricolare. I segnali acquisiti e così pre-processati servivano per stimare un filtro CSP. Come in questo lavoro di tesi, l'obiettivo di Guger et al. [63] era quello di misurare i progressi dei soggetti in termini di accuratezza di classificazione, nel corso di 6-7

sessioni da 160-200 trial l'una, concentrate nel giro di tre giorni. La particolarità di questo sistema era che solo alcune sessioni (la seconda e dalla quarta in poi) prevedevano un feedback per il soggetto, mentre almeno la prima e la terza venivano portate a termine senza feedback. Ancora, il filtro CSP e il classificatore (un classificatore LDA, Linear Discriminant Analysis) non venivano aggiornati sempre di sessione in sessione, ma solamente ogni tanto (Figura 40).

Per costruire il filtro CSP, data la sua elevata sensibilità agli artefatti, si scartavano tramite analisi visiva i trial EEG che ne contenessero. Per calcolare invece i parametri del classificatore, si consideravano in ogni trial solo le porzioni di segnale relative ad un determinato intervallo temporale. In particolare, dopo una cross-validazione 10x10 eseguita offline sulla sessione appena trascorsa, si sceglieva l'intervallo di tempo

lungo 1s a partire dalla presentazione dello stimolo che desse il minore errore di classificazione, e si usavano solo i dati di questo intervallo per costruire il nuovo classificatore. La procedura di calcolo dei parametri del classificatore impiegava in questo modo circa 30 minuti [63].

Nel sistema descritto da Guger et al [63], tutti i soggetti sono riusciti in tre giorni a migliorare l'accuratezza di classificazione. In particolare, il primo soggetto è passato dall'81% al 98%, il secondo dal 50% al 93%, il terzo dal 66% al 91%.

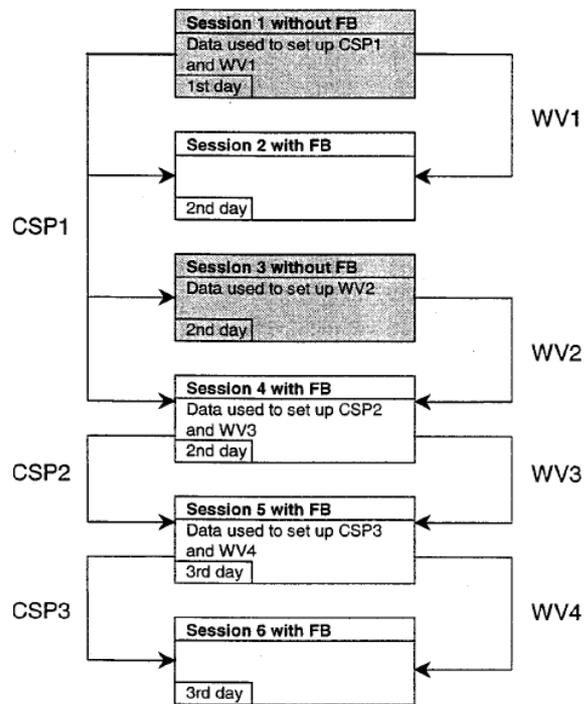


Figura 40 Flowchart delle sessioni dal lavoro di Guger et al. [63], che evidenzia le sessioni con/senza feedback. Lo schema indica anche in che punti vengono calcolati i filtri CSP e stimati i nuovi classificatori (WV, weight vector)

I risultati ottenuti da Guger et al. [63] sono senz'altro notevoli, ma occorre fare alcune osservazioni, ossia:

- tutti i soggetti impiegati avevano già esperienza sui task di immaginazione motoria utilizzati
- il numero di elettrodi utilizzati era elevato (27 elettrodi concentrati nell'area della corteccia motoria/sensoriale primaria)
- ogni volta che si costruisce il filtro CSP veniva fatta un'ispezione visiva dei segnali per escludere quelli contenenti artefatti
- ogni volta che si aggiornava il classificatore la procedura richiedeva circa 30 minuti
- il miglioramento di performances riportato per i soggetti riguardava i risultati migliori, ottenuti in una particolare finestra temporale rispetto all'istante di presentazione dello stimolo

Queste osservazioni ci serviranno tra poco, per un confronto con il sistema descritto nel presente lavoro di tesi.

L'altro lavoro al quale è possibile rapportarsi è quello di Ramoser et al. [72]. In questo studio, l'obiettivo era quello di provare, su tre soggetti, come cambiasse l'accuratezza della classificazione degli stati mentali tramite filtro CSP e classificatore lineare, variando il numero di elettrodi utilizzati e il riferimento. In particolare, sono state testate le configurazioni ear-reference, bipolare, Small Laplacian, Large Laplacian e CAR. Per ognuna di queste configurazioni si sono valutate le performance utilizzando diverse quantità di elettrodi. I soggetti impiegati erano tre studenti, pagati per l'esperimento, di età compresa tra i 20 e i 27 anni. Tutti e tre i soggetti avevano avuto precedenti esperienze in ambito BCI che coinvolgessero l'immaginazione motoria della mano destra e della mano sinistra, e tutti e tre partivano con alle spalle un'esperienza di 10-12 sessioni (ogni sessione 160 trial), con o senza feedback. In questo studio, i soggetti sono stati testati per quattro prove da 40 trial ciascuna (20 trial mano dx, 20 trial mano sx), per un totale di 160 trial. I dati sono stati acquisiti da 56 canali EEG concentrati nella zona della corteccia motoria/sensoriale primaria, per

poi simulare le altre configurazioni (diverso numero di elettrodi e/o diverso montaggio) offline.

A partire dai dati acquisiti, anche in questo caso i filtri CSP sono stati calcolati solo dopo aver escluso tramite analisi visiva i trial contenenti artefatti. Inoltre, anche in questo studio i risultati riportati facevano riferimento alla migliore accuratezza ottenuta in un determinato intervallo temporale dall'istante di presentazione dello stimolo (ad esempio, per i soggetti 1 e 2 la classificazione migliore si otteneva nel segmento 4.5-6s dopo lo stimolo, mentre per il soggetto 3 era selezionato il segmento 3-4.5s [72]). I risultati dello studio di Ramoser et al. [72] studio sono riportati in Figura 41.

Derivation	Channels	S1	S2	S3
		Acc. [%]	Acc. [%]	Acc. [%]
referential	56	92.1±3.3	89.0±4.0	99.7±1.5
referential	18	91.0±3.3	90.4±3.6	95.0±8.3
referential	2	78.8±4.9	80.4±4.6	65.0±10.3
bipolar	34	92.7±2.8	88.2±4.7	97.7±3.9
small Lap.	30	92.3±3.1	89.9±4.4	98.0±3.1
large Lap.	7	91.1±3.0	88.4±5.0	95.0±4.8
large Lap.	2	87.4±3.9	78.6±4.1	93.0±6.3
CAR	56	91.5±3.8	89.4±4.3	98.3±3.7
CAR	18	90.8±3.4	90.8±4.0	95.0±6.1

Figura 41. Risultati del lavoro di Ramoser et al [72]

Dai risultati ottenuti, Ramoser et al. hanno commentato che, anche se il metodo di re-ferenziazione sembrava non avere grande influenza, questo poteva essere dovuto al fatto che nello studio erano stati utilizzati segnali privi di artefatti. Ramoser et al. stessi hanno quindi confermato che in un sistema automatizzato probabilmente un filtro CAR o un Laplaciano si rivelerebbero più adatti, concordando in questo modo con quanto già indicato da McFarland et al. [70]. Un'altra conclusione di Ramoser et al. riguarda il numero di elettrodi: in effetti si nota come, passando da 18 a 56 elettrodi, le performances non migliorino poi tanto. Secondo Ramoser et al, dunque, 18 elettrodi posizionati in prossimità della corteccia motoria/sensoriale primaria

sono sufficienti per una buona discriminazione dei due stati mentali in esame tramite filtraggio CSP e classificatore lineare.

Anche nello studio di Ramoser et al. i risultati ottenuti sono notevoli, tuttavia occorre sempre osservare che:

- i soggetti impiegati avevano tutti precedente esperienza sui task di immaginazione motoria utilizzati nell'esperimento
- i filtri CSP sono stati costruiti escludendo con un'analisi visiva i trial contenenti artefatti
- comunque il numero minimo suggerito di elettrodi da posizionare in prossimità della corteccia motoria/sensoriale primaria è di 18
- le performances indicate facevano riferimento solo all'intervallo temporale che, per ogni soggetto, dava i migliori risultati di classificazione

Dopo aver analizzato questi due lavori, è possibile cercare di contestualizzare il sistema riportato in questo lavoro di tesi.

Due elementi che immediatamente emergono riguardano il numero di elettrodi utilizzati e la modalità di costruzione del filtro CSP: nel presente lavoro di tesi si è fatto infatti uso di soli 11 elettrodi posizionati in prossimità della corteccia motoria/sensoriale primaria (contro i 27 di Guger et al. [63] e i 18 consigliati da Ramoser et al. [72]), e i filtri CSP sono stati costruiti considerando *tutte* le porzioni di segnale registrate, in modo automatico e senza esclusione tramite analisi visiva si quelle contenenti artefatti.

Un altro aspetto che colpisce, soprattutto confrontando il presente lavoro di tesi con lo studio di Guger et al. [63], è la rapidità con cui il classificatore viene aggiornato nel sistema qui descritto. Mentre infatti il nostro sistema ri-calcola filtro CSP e classificatore da uno step all'altro di *Training e Updating* automaticamente e in pochi secondi, il sistema di Guger et al. [63] richiede circa 30 minuti ogni volta per aggiornare il classificatore, più il tempo di ispezione visiva dei segnali per eliminare quelli affetti da artefatti ogni volta che si voglia aggiornare anche il filtro CSP.

Ancora, nel nostro sistema l'aggiornamento viene fatto progressivamente, ogni 10 trial, all'interno della sessione di addestramento. Diversamente, in Guger et al. [63], l'aggiornamento viene fatto solo al termine della sessione di addestramento, e nemmeno ad ogni sessione.

Infine, mentre nel nostro sistema le parti di *Training* senza feedback sono molto limitate (ogni *Training* comprende 14 trial da 10 secondi, ossia poco più di due minuti), in Guger et al. [63] addirittura due intere sessioni da 160 trial sono portate a termine senza feedback. In generale si può dire che il sistema descritto in questo lavoro di tesi sia molto più automatizzato e più "agile" di quello implementato da Guger et al. [63].

Certo, nel nostro sistema 3 soggetti su 4 non hanno evidenziato alcun trend di crescita in termini di performances ottenute, mentre in Guger et al. [63], seppur con le dovute osservazioni (tutti soggetti già addestrati, riportati solo i risultati relativi al segmento temporale migliore, più elettrodi e segnali controllati visivamente), il miglioramento in tre giorni c'è ed è notevole.

Un motivo per cui forse Guger et al. [63] nel loro lavoro potrebbero aver escluso l'aggiornamento continuo del sistema, preferendo un aggiornamento solo saltuario e mirato, potrebbe affondare nel cosiddetto MMLD, *Man-Machine Learning Dilemma*. Come spiegano infatti Pfurtscheller e Neuper in [62], "ci si potrebbe aspettare che in esperimenti BCI in cui al soggetto viene dato il feedback l'accuratezza di classificazione migliori aumentando il numero di sessioni (...), tuttavia non sempre questo è successo" [62]. Questo potrebbe essere spiegato dal cosiddetto MMLD, per cui i due sistemi (uomo e macchina) sono fortemente interdipendenti, ma dovrebbero essere adattati indipendentemente [62]. In un primo momento, durante il training, è la macchina che si deve adattare all'uomo, e nessun feedback può essere dato al soggetto. Dal momento in cui invece si inizia a fornire il feedback, ogni ritorno ricevuto ha come risultato l'adattamento dell'uomo alla macchina tramite condizionamento operante. I pattern del soggetto cominciano infatti a modificarsi in modo da evitare di incorrere in feedback "frustranti", mentre al

contempo si rinforzano i pattern associati a feedback positivi. Ecco allora che, da un lato, in un momento in cui è l'uomo che si sta adattando, cambiare la risposta del sistema può essere controproducente. D'altro canto, il sistema deve comunque essere periodicamente aggiornato, per potersi adattare ai miglioramenti del soggetto. Ciò che Pfurtscheller e Neuper [62] consigliano è di adattare sì il sistema all'uomo, ma magari dopo una o più sessioni.

Che sia forse dunque il MMLD a spiegare il successo del sistema di Guger et al [63] per quanto riguarda il miglioramento delle performances dei tre soggetti in solo tre giorni? In parte forse sì, del resto i buoni risultati ottenuti dall'equipe sono indubbi. Tuttavia, prima di modificare questo aspetto nel nostro sistema nel tentativo di tendere ad un miglioramento, ci sono altre vie che potrebbero prima essere tentate. L'autrice di questa tesi è infatti convinta che sarebbe una buona cosa riuscire a costruire un sistema agile ed automatico, in grado di adattarsi e plasmarsi sul soggetto a mano a mano che questo migliora, e senza bisogno di troppa supervisione da parte di esperti. Un sistema del genere potrebbe infatti essere utilizzato anche a casa da un ipotetico paziente per l'addestramento, cosa invece difficile per il sistema proposto da Guger et al. [63]. Inoltre, su due soggetti (soggetto MR e soggetto VM), già così com'è il sistema ha dato dei risultati interessanti, considerando tra l'altro che il metodo di stima dell'accuratezza di classificazione utilizzato in questo lavoro di tesi è anche leggermente peggiorativo (essendo media pesata delle accuratezze di classificazione delle due classi, in cui pesa maggiormente la classe sfavorita). Inoltre, le performances riportate riguardano mediamente tutte le porzioni di segnale, senza indagare quale segmento temporale a partire dalla presentazione dello stimolo desse il risultato "migliore". Infine, anche considerando il MMLD, il sistema qui presentato ha dimostrato di essere in grado di ridurre, o al limite mantenere costante, il numero di misclassificazioni del training set. Ciò significa che, in teoria, il sistema dovrebbe essere in realtà "andare incontro" al soggetto, senza modificare in modo brusco il feedback. Naturalmente, per poter asserire questo con maggiore

certezza andrebbero condotte più prove. In ogni caso, prima di toccare la modalità di aggiornamento, si suggerisce di tentare di migliorare il sistema in altri modi.

Possibili miglioramenti del sistema

In base a quanto detto nella precedente sezione, un primo esperimento che sicuramente si potrebbe fare è quello di tentare di aumentare inizialmente il numero di elettrodi acquisiti, e vedere se in questo modo le performances migliorano. Sia Guger et al [63] che Ramoser et al [72], infatti, hanno usato più di 11 elettrodi in prossimità della corteccia motoria/sensoriale primaria, suggerendo l'uso di almeno 18 elettrodi.

In un secondo tempo, eventualmente, si potrebbe pensare di ridurre nuovamente il numero di elettrodi per favorire la portabilità, magari eliminando quelli “meno significativi” ai fini degli stati mentali da separare. A tal proposito, Wang et al. [73] hanno proposto un metodo per l'identificazione degli elettrodi più significativi basato proprio su CSP. In particolare, dopo aver filtrato i dati nella banda di interesse (ad esempio, 8-30Hz), si calcola la matrice \mathbf{W} del metodo CSP e, considerati solo il primo e l'ultimo spatial pattern, si va a vedere quali locazioni d'elettrodo abbiano più o meno peso per la discriminazione dei due pattern. Le locazioni con maggiore peso saranno quelle più discriminanti da una configurazione mentale all'altra, ossia quelle da mantenere.

Un altro aspetto da considerare è quello degli artefatti. Data la grande cura mostrata da Guger et al [63] e da Ramoser et al [72] per questo aspetto, al punto da eliminare i trial contenenti artefatti tramite ispezione visiva, forse conviene prestare più attenzione alla questione. Per come è implementato oggi, il sistema non prevede né l'acquisizione della traccia elettrooculografica (che comporterebbe un'ulteriore riduzione di portabilità), né algoritmi di detezione automatica degli artefatti. Le uniche “protezioni” in questo senso sono l'utilizzo del riferimento CAR e il fatto che, a mano a mano che la sessione procede, sempre più matrici di covarianza per ogni classe vengono mediate,

riducendo così teoricamente l'influenza di dati "outlier". E' anche vero che in questo modo, a seguito di uno step particolarmente "ricco di artefatti", la matrice W potrebbe anche subire delle deviazioni che rendono il feedback nella sessione subito successiva destabilizzante. Questo sicuramente peggiorerebbe il discorso del MMLD. Una cosa che si potrebbe dunque fare, in futuro, è quella pensare di mettere a punto una procedura automatica di detezione e rimozione degli artefatti. In questo modo, il sistema rimarrebbe comunque automatico, senza il bisogno del controllo visivo dei segnali da parte di esperti, ma teoricamente migliorerebbe in stabilità.

Dopo aver tentato queste due vie e aver visto come risponde il sistema, si potrebbe anche pensare di cambiare il filtro CSP sostituendolo con metodi più recenti. Come detto all'inizio del capitolo "Materiali e Metodi", in questo lavoro di tesi si è deciso di filtrare nella banda 8-30Hz perché Müller-Gerking et al.[71] asserirono che l'uso di questa larga banda da risultati di classificazione migliori rispetto all'impiego di bande più ristrette. Sebbene questa affermazione rimanga vera se riferita al semplice metodo CSP, rimane comunque un'affermazione fatta nel 1998. Nel frattempo diversi algoritmi, presentati come evoluzioni del CSP, sono stati proposti. Tra questi algoritmi ricordiamo il FWM (Frequency Weighted Method, [82]), il FBCSP (Filter-Bank CSP, [83]) o il SBCSP (Sub-Band CSP) [84]. Tutti questi metodi mirano ad identificare automaticamente, per ciascun canale, le sotto-bande di frequenza più significative per la discriminazione, sempre nell'ottica del metodo CSP. Uno di questi più moderni algoritmi potrebbe essere eventualmente indagato ed implementato per vedere se, ancora, le performances del sistema possono migliorare.

Riassumendo i punti appena discussi, prima di modificare il metodo di aggiornamento così implementato che, comunque, presenta diversi vantaggi, si possono tentare le seguenti vie:

- aumentare inizialmente il numero di elettrodi e, dopo un'analisi esplorativa su ciascun soggetto, eliminare quelli meno significativi per la discriminazione degli stati mentali

- implementare algoritmi di detezione e rimozione automatica degli artefatti
- tentare eventualmente una delle versioni “aggiornate” del metodo CSP, come ad esempio il SBCSP

Conclusioni

In questo lavoro di tesi, un sistema BCI EEG-based fondato sulla modulazione dei ritmi sensorimotori tramite immaginazione motoria è stato progettato e testato. Il cuore del lavoro è consistito naturalmente nello sviluppo del software LabVIEW. Successivamente, l'intero sistema è stato testato su quattro persone.

Dai risultati ottenuti si può vedere come non tutti i soggetti siano riusciti, nell'arco di sei sessioni di addestramento, a imparare come controllare efficacemente il modello di arto superiore mostrato sullo schermo. Inoltre, tre soggetti su quattro non hanno mostrato in questo arco temporale alcun trend di miglioramento. I buoni risultati ottenuti da due soggetti (soggetto MR e soggetto VM), tuttavia, dimostrano che il sistema può effettivamente funzionare, e anche bene. Infine, per come è stato progettato l'aggiornamento dei filtri e del classificatore, il sistema ha dimostrato una buona risposta nel tempo. In particolare, a mano a mano che la sessione procede, la qualità dei dati che fanno parte del training set del classificatore tende sempre a migliorare, o al limite a rimanere costante. Solo in un caso si è notato, verso la fine della sessione, un lieve peggioramento della qualità del training set. Questo effetto potrebbe tuttavia essere un "transitorio", e un numero maggiore di sperimentazioni è senz'altro necessario per trarre una conclusione in merito.

Rapportando questo sistema a lavori presenti in letteratura è emerso come:

- il numero di elettrodi posizionati in prossimità della corteccia motoria/sensoriale primaria in questo lavoro (11) sia ridotto (nel lavoro di Guger et al. [63] se ne usano 27, in quello di Ramoser et al. [72] se ne consigliano almeno 18)

- non si sia forse prestata abbastanza attenzione alla rimozione degli artefatti EEG prima di costruire e aggiornare il filtro CSP
- anche solo in tre giorni di addestramento si possa attendere un miglioramento delle performances dei soggetti (obbiettivo non raggiunto in questo lavoro di tesi per 3 soggetti su 4), e questo potrebbe essere dovuto al cosiddetto MMLD (Man-Machine Learning Dilemma), per cui si sconsiglia di aggiornare troppo spesso il sistema, quando il soggetto sta ancora imparando come controllarlo

Rispetto al lavoro di Guger et al. [63], tuttavia, il sistema qui implementato appare più agile (veloce negli aggiornamenti), automatico (non necessita di supervisione da parte di esperti) e coinvolgente (la maggior parte del tempo di addestramento prevede un feedback per il soggetto). Dunque, prima di modificare la modalità di aggiornamento del sistema, rendendola più “statica” e meno automatizzata, si ritiene si debba tentare il miglioramento delle performances percorrendo dapprima altre vie.

In particolare, i seguenti tentativi possono essere fatti:

- aumentare in un primo momento il numero di elettrodi acquisiti, e vedere se e come le performances dei soggetti variano. In un secondo momento, si può pensare ad una nuova riduzione del numero di elettrodi, ma che sia subject-specific. In particolare, si andranno ad eliminare per ogni soggetto gli elettrodi che, per lui, sono meno significativi ai fini della discriminazione degli stati mentali
- implementare un algoritmo di detezione automatica degli artefatti EEG, in modo da costruire filtri CSP basati solo su segnali “puliti”
- qualora le performances non dovessero ancora essere soddisfacenti, si può pensare di sostituire l’algoritmo CSP con versioni proposte più di recente, che tengono conto anche delle caratteristiche spettrali di ogni canale acquisito. In particolare, si potrebbero tentare gli algoritmi FWM (Frequency Weighted

Method, [82]), FBCSP (Filter-Bank CSP, [83]) o il SBCSP (Sub-Band CSP) [84]

In generale, poi, una sperimentazione più lunga e su un maggior numero di soggetti sarebbe utile per una migliore caratterizzazione del sistema.

Parlando infine degli sviluppi futuri, una volta che il sistema sia stato migliorato ed abbia raggiunto performances soddisfacenti, si può pensare a complicare il modello di arto superiore, sostituendolo con un 2-link e aggiungendo così un ulteriore grado di libertà.

Bibliografia

- [1] J. Wolpaw e E. W. Wolpaw, *Brain-Computer Interfaces: Principles and Practice*. Oxford University Press, 2011.
- [2] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. H. Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson, T. M. Vaughan, e others, «Brain-computer interface technology: a review of the first international meeting», *IEEE transactions on rehabilitation engineering*, vol. 8, n. 2, pagg. 164–173, 2000.
- [3] H. Yuan e B. He, «Brain-computer interfaces using sensorimotor rhythms: current state and future perspectives», *IEEE Trans Biomed Eng*, vol. 61, n. 5, pagg. 1425–1435, mag. 2014.
- [4] S. S. Purkayastha, V. K. Jain, e H. K. Sardana, «Topical Review: A Review of Various Techniques Used for Measuring Brain Activity in Brain Computer Interfaces».
- [5] L. F. Nicolas-Alonso e J. Gomez-Gil, «Brain Computer Interfaces, a Review», *Sensors (Basel)*, vol. 12, n. 2, pagg. 1211–1279, gen. 2012.
- [6] S. Laureys, M. Boly, e G. Tononi, *Functional neuroimaging*. New York, Elsevier, 2009.
- [7] B. He, *Neural Engineering*. Springer Science & Business Media, 2007.
- [8] N. J. Hill, T. N. Lal, M. Schröder, T. Hinterberger, G. Widman, C. E. Elger, B. Schölkopf, e N. Birbaumer, «Classifying event-related desynchronization in EEG, ECoG and MEG signals», in *Pattern Recognition*, Springer, 2006, pagg. 404–413.
- [9] T. Ball, M. Kern, I. Mutschler, A. Aertsen, e A. Schulze-Bonhage, «Signal quality of simultaneously recorded invasive and non-invasive EEG», *Neuroimage*, vol. 46, n. 3, pagg. 708–716, 2009.
- [10] B. Graimann, J. E. Huggins, S. P. Levine, e G. Pfurtscheller, «Toward a direct brain interface based on human subdural recordings and wavelet-packet analysis», *Biomedical Engineering, IEEE Transactions on*, vol. 51, n. 6, pagg. 954–962, 2004.
- [11] T. N. Lal, T. Hinterberger, G. Widman, M. Schröder, J. Hill, W. Rosenstiel, C. Elger, B. Schölkopf, e N. Birbaumer, «Methods towards invasive human brain computer interfaces», 2005.

- [12] E. C. Leuthardt, G. Schalk, J. R. Wolpaw, J. G. Ojemann, e D. W. Moran, «A brain–computer interface using electrocorticographic signals in humans», *Journal of neural engineering*, vol. 1, n. 2, pag. 63, 2004.
- [13] S. Waldert, T. Pistohl, C. Braun, T. Ball, A. Aertsen, e C. Mehring, «A review on directional information in neural signals for brain-machine interfaces», *Journal of Physiology-Paris*, vol. 103, n. 3, pagg. 244–254, 2009.
- [14] B.-K. Min, M. J. Marzelli, e S.-S. Yoo, «Neuroimaging-based approaches in the brain–computer interface», *Trends in Biotechnology*, vol. 28, n. 11, pagg. 552–560, nov. 2010.
- [15] T. N. Lal, M. Schröder, N. J. Hill, H. Preissl, T. Hinterberger, J. Mellinger, M. Bogdan, W. Rosenstiel, T. Hofmann, N. Birbaumer, e others, «A brain computer interface with online feedback based on magnetoencephalography», in *Proceedings of the 22nd international conference on Machine learning*, 2005, pagg. 465–472.
- [16] L. Kauhanen, T. Nykopp, J. Lehtonen, P. Jylanki, J. Heikkonen, P. Rantanen, H. Alaranta, e M. Sams, «EEG and MEG brain-computer interface for tetraplegic patients», *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 14, n. 2, pagg. 190–193, 2006.
- [17] J. Mellinger, G. Schalk, C. Braun, H. Preissl, W. Rosenstiel, N. Birbaumer, e A. Kübler, «An MEG-based brain–computer interface (BCI)», *Neuroimage*, vol. 36, n. 3, pagg. 581–593, 2007.
- [18] S. Ogawa, T.-M. Lee, A. R. Kay, e D. W. Tank, «Brain magnetic resonance imaging with contrast dependent on blood oxygenation», *Proceedings of the National Academy of Sciences*, vol. 87, n. 24, pagg. 9868–9872, 1990.
- [19] N. Weiskopf, K. Mathiak, S. W. Bock, F. Scharnowski, R. Veit, W. Grodd, R. Goebel, e N. Birbaumer, «Principles of a brain-computer interface (BCI) based on real-time functional magnetic resonance imaging (fMRI)», *Biomedical Engineering, IEEE Transactions on*, vol. 51, n. 6, pagg. 966–970, 2004.
- [20] T. Moench, M. Hollmann, R. Grzeschik, C. Mueller, R. Luetzkendorf, S. Baecke, M. Luchtman, D. Wagegg, e J. Bernarding, «Real-time classification of activated brain areas for fMRI-based human-brain-interfaces», in *Medical Imaging*, 2008, pag. 69161R–69161R.

- [21] R. P. Kennan, S. G. Horovitz, A. Maki, Y. Yamashita, H. Koizumi, e J. C. Gore, «Simultaneous recording of event-related auditory oddball response using transcranial near infrared optical topography and surface EEG», *Neuroimage*, vol. 16, n. 3, pagg. 587–592, 2002.
- [22] R. Sitaram, H. Zhang, C. Guan, M. Thulasidas, Y. Hoshi, A. Ishikawa, K. Shimizu, e N. Birbaumer, «Temporal classification of multichannel near-infrared spectroscopy signals of motor imagery for developing a brain–computer interface», *NeuroImage*, vol. 34, n. 4, pagg. 1416–1427, 2007.
- [23] C. M. Sinclair, M. C. Gasper, e A. S. Blum, «Basic electronics in clinical neurophysiology», in *The Clinical Neurophysiology Primer*, Springer, 2007, pagg. 3–18.
- [24] A. B. Usakli, «Improvement of EEG signal acquisition: An electrical aspect for state of the art of front end», *Computational intelligence and neuroscience*, vol. 2010, pag. 12, 2010.
- [25] C. Fonseca, J. S. Cunha, R. E. Martins, V. M. Ferreira, J. M. de Sá, M. A. Barbosa, e A. M. da Silva, «A novel dry active electrode for EEG recording», *IEEE Transactions on Biomedical Engineering*, pagg. 162–165, 2007.
- [26] B. A. Taheri, R. T. Knight, e R. L. Smith, «A dry electrode for EEG recording», *Electroencephalography and clinical neurophysiology*, vol. 90, n. 5, pagg. 376–383, 1994.
- [27] G. H. Klem, H. O. Lüders, H. H. Jasper, e C. Elger, «The ten-twenty electrode system of the International Federation», *Electroencephalogr Clin Neurophysiol*, vol. 52, n. suppl., pag. 3, 1999.
- [28] «Treccani, l'Enciclopedia Italiana». [In linea]. Available at: <http://www.treccani.it/enciclopedia/>. [Consultato: 14-feb-2015].
- [29] M. R. Nuwer, G. Comi, R. Emerson, A. Fuglsang-Frederiksen, J.-M. Guérit, H. Hinrichs, A. Ikeda, F. Jose C Lucas, e P. Rappelsburger, «IFCN standards for digital recording of clinical EEG», *Electroencephalography and clinical Neurophysiology*, vol. 106, n. 3, pagg. 259–261, 1998.
- [30] R. Oostenveld e P. Praamstra, «The five percent electrode system for high-resolution EEG and ERP measurements», *Clinical Neurophysiology*, vol. 112, n. 4, pagg. 713–719, apr. 2001.
- [31] J. Rieger, «EEG signal analysis», 2006.

- [32] F. Aloise, «Sviluppo di un sistema Brain-Computer Interface per il controllo ambientale», *Develop of Brain-Computer Interface system for environmental control*, giu. 2010.
- [33] S. d. Muthukumaraswamy e B. w. Johnson, «Changes in rolandic mu rhythm during observation of a precision grip», *Psychophysiology*, vol. 41, n. 1, pagg. 152–156, 2004.
- [34] L. Braadbaart, J. H. G. Williams, e G. D. Waiter, «Do mirror neuron areas mediate mu rhythm suppression during imitation and action observation?», *Int J Psychophysiol*, vol. 89, n. 1, pagg. 99–105, lug. 2013.
- [35] D. J. McFarland, L. A. Miner, T. M. Vaughan, e J. R. Wolpaw, «Mu and Beta Rhythm Topographies During Motor Imagery and Actual Movements», *Brain Topogr*, vol. 12, n. 3, pagg. 177–186, mar. 2000.
- [36] G. Pfurtscheller, C. Brunner, A. Schlögl, e F. H. Lopes da Silva, «Mu rhythm (de)synchronization and EEG single-trial classification of different motor imagery tasks», *NeuroImage*, vol. 31, n. 1, pagg. 153–159, mag. 2006.
- [37] T. C. Major e J. M. Conrad, «A survey of brain computer interfaces and their applications», in *IEEE SOUTHEASTCON 2014*, 2014, pagg. 1–8.
- [38] T. C. Handy, *Event-related Potentials: A Methods Handbook*. MIT Press, 2005.
- [39] Y. Wang, X. Gao, B. Hong, C. Jia, e S. Gao, «Brain-Computer Interfaces Based on Visual Evoked Potentials», *IEEE Engineering in Medicine and Biology Magazine*, vol. 27, n. 5, pagg. 64–71, set. 2008.
- [40] X. Gao, D. Xu, M. Cheng, e S. Gao, «A BCI-based environmental controller for the motion-disabled», *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, vol. 11, n. 2, pagg. 137–140, 2003.
- [41] J. V. Odom, M. Bach, C. Barber, M. Brigell, M. F. Marmor, A. P. Tormene, e G. E. Holder, «Visual evoked potentials standard (2004)», *Documenta ophthalmologica*, vol. 108, n. 2, pagg. 115–123, 2004.
- [42] M. Middendorf, G. McMillan, G. Calhoun, K. S. Jones, e others, «Brain-computer interfaces based on the steady-state visual-evoked response», *IEEE Transactions on Rehabilitation Engineering*, vol. 8, n. 2, pagg. 211–214, 2000.

- [43] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, e T. M. Vaughan, «Brain–computer interfaces for communication and control», *Clinical neurophysiology*, vol. 113, n. 6, pagg. 767–791, 2002.
- [44] S. T. Morgan, J. C. Hansen, e S. A. Hillyard, «Selective attention to stimulus location modulates the steady-state visual evoked potential», *Proceedings of the National Academy of Sciences*, vol. 93, n. 10, pagg. 4770–4774, 1996.
- [45] Y. Chen, A. K. Seth, J. A. Gally, e G. M. Edelman, «The power of human brain magnetoencephalographic signals can be modulated up or down by changes in an attentive visual task», *Proceedings of the National Academy of Sciences*, vol. 100, n. 6, pagg. 3501–3506, 2003.
- [46] M. M. Müller, S. Andersen, N. J. Trujillo, P. Valdes-Sosa, P. Malinowski, e S. A. Hillyard, «Feature-selective attention enhances color signals in early visual areas of the human brain», *Proceedings of the National Academy of Sciences*, vol. 103, n. 38, pagg. 14250–14254, 2006.
- [47] E. Sutter, «The brain response interface: communication through visually-induced electrical brain responses», gen. 1992.
- [48] Pablo F. Diez, Sandra M. Torres Muller, Vicente A. Mut, Eric Laciari, Enrique Avila, Teodiano Freire Bastos-Filho, e Mario Sarcinelli-Filho, «Commanding a robotic wheelchair with a high-frequency steady-state visual evoked potential based brain–computer interface», dic. 2012.
- [49] C. Mandel, T. Luth, T. Laue, e T. Rofer, «Navigating a smart wheelchair with a brain-computer interface interpreting steady-state visual evoked potentials», 2009.
- [50] G.R. Muller-Putz e G. Pfurtscheller, «Control of an Electrical Prosthesis With an SSVEP-Based BCI», 2007.
- [51] L. A. Farwell e E. Donchin, «Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials», *Electroencephalography and clinical Neurophysiology*, vol. 70, n. 6, pagg. 510–523, 1988.
- [52] A. Furdea, S. Halder, D. J. Krusienski, D. Bross, F. Nijboer, N. Birbaumer, e A. Kübler, «An auditory oddball (P300) spelling system for brain-computer interfaces», *Psychophysiology*, vol. 46, n. 3, pagg. 617–625, 2009.

- [53] J. Polich, P. C. Ellerson, e J. Cohen, «P300, stimulus intensity, modality, and probability», *International Journal of Psychophysiology*, vol. 23, n. 1, pagg. 55–62, 1996.
- [54] D. Ravden e J. Polich, «On P300 measurement stability: habituation, intra-trial block variation, and ultradian rhythms», *Biological psychology*, vol. 51, n. 1, pagg. 59–76, 1999.
- [55] B. Rivet, A. Souloumiac, V. Attina, e G. Gibert, «xDAWN algorithm to enhance evoked potentials: application to brain–computer interface», *Biomedical Engineering, IEEE Transactions on*, vol. 56, n. 8, pagg. 2035–2043, 2009.
- [56] K. Takano, T. Komatsu, N. Hata, Y. Nakajima, e K. Kansaku, «Visual stimuli for the P300 brain–computer interface: a comparison of white/gray and green/blue flicker matrices», *Clinical neurophysiology*, vol. 120, n. 8, pagg. 1562–1566, 2009.
- [57] J. Hill, J. Farquhar, S. Martens, F. Bielemann, e B. Schölkopf, «Effects of stimulus type and of error-correcting code design on BCI speller performance», in *Advances in neural information processing systems*, 2009, pagg. 665–672.
- [58] I. Iturrate, J. M. Antelis, A. Kubler, e J. Minguez, «A Noninvasive Brain-Actuated Wheelchair Based on a P300 Neurophysiological Protocol and Automated Navigation», *IEEE Transactions on Robotics*, vol. 25, n. 3, pagg. 614–627, giu. 2009.
- [59] N. Birbaumer, A. Kübler, N. Ghanayim, T. Hinterberger, J. Perelmouter, J. Kaiser, I. Iversen, B. Kotchoubey, N. Neumann, e H. Flor, «The thought translation device (TTD) for completely paralyzed patients», *IEEE Trans Rehabil Eng*, vol. 8, n. 2, pagg. 190–193, giu. 2000.
- [60] M. Jeannerod, «Mental imagery in the motor context», *Neuropsychologia*, vol. 33, n. 11, pagg. 1419–1432, nov. 1995.
- [61] G. Pfurtscheller e C. Neuper, «Motor imagery activates primary sensorimotor area in humans», *Neuroscience letters*, vol. 239, n. 2, pagg. 65–68, 1997.
- [62] G. Pfurtscheller e C. Neuper, «Motor imagery and direct brain–computer communication», *Proceedings of the IEEE*, vol. 89, n. 7, pagg. 1123–1134, lug. 2001.

- [63] C. Guger, H. Ramoser, e G. Pfurtscheller, «Real-time EEG analysis with subject-specific spatial patterns for a brain-computer interface (BCI)», *IEEE Transactions on Rehabilitation Engineering*, vol. 8, n. 4, pagg. 447–456, dic. 2000.
- [64] G. Pfurtscheller, C. Neuper, G.R. Muller, B Obermaier, G Krausz, A Schlogl, e R Scherer, «Graz-BCI: state of the art and clinical applications», 2003.
- [65] B. Blankertz, F. Losch, M. Krauledat, e G. Dornhege, «The Berlin Brain-Computer Interface: Accurate Performance From First-Session in BCI-Naive Subjects», apr. 2008.
- [66] J.R. Wolpaw, D.J. McFarland, e T.M. Vaughan, «Brain-computer interface research at the Wadsworth Center», 2000.
- [67] K. Choi e A. Cichocki, «Control of a Wheelchair by Motor Imagery in Real Time», in *Intelligent Data Engineering and Automated Learning – IDEAL 2008*, C. Fyfe, D. Kim, S.-Y. Lee, e H. Yin, A c. di Springer Berlin Heidelberg, 2008, pagg. 330–337.
- [68] J. R. Wolpaw e D. J. McFarland, «Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans», *PNAS*, vol. 101, n. 51, pagg. 17849–17854, dic. 2004.
- [69] D. J. McFarland, W. A. Sarnacki, e J. R. Wolpaw, «Electroencephalographic (EEG) control of three-dimensional movement», *J. Neural Eng.*, vol. 7, n. 3, pag. 036007, giu. 2010.
- [70] D. J. McFarland, L. M. McCane, S. V. David, e J. R. Wolpaw, «Spatial filter selection for EEG-based communication», *Electroencephalography and clinical Neurophysiology*, vol. 103, n. 3, pagg. 386–394, 1997.
- [71] J. Müller-Gerking, G. Pfurtscheller, e H. Flyvbjerg, «Designing optimal spatial filters for single-trial EEG classification in a movement task», *Clinical neurophysiology*, vol. 110, n. 5, pagg. 787–798, 1999.
- [72] H. Ramoser, J. Muller-Gerking, e G. Pfurtscheller, «Optimal spatial filtering of single trial EEG during imagined hand movement», *IEEE Transactions on Rehabilitation Engineering*, vol. 8, n. 4, pagg. 441–446, dic. 2000.
- [73] Y. Wang, S. Gao, e X. Gao, «Common Spatial Pattern Method for Channel Selelction in Motor Imagery Based Brain-computer Interface», in

- Engineering in Medicine and Biology Society, 2005. IEEE-EMBS 2005. 27th Annual International Conference of the, 2005, pagg. 5392–5395.*
- [74] Prof. Davide Maltoni, «Visione Artificiale & Riconoscimento - Materiale di Supporto al Corso».
- [75] C. J. C. Burges, «A Tutorial on Support Vector Machines for Pattern Recognition», *Data Mining and Knowledge Discovery*, vol. 2, n. 2, pagg. 121–167, giu. 1998.
- [76] C. Cortes e V. Vapnik, «Support-vector networks», *Mach Learn*, vol. 20, n. 3, pagg. 273–297, set. 1995.
- [77] G. Giusti, *Trattato di medicina legale e scienze affini*. Wolters Kluwer Italia, 2009.
- [78] G. Pfurtscheller, C. Guger, G. Muller, G. Krausz, e C. Neuper, «Brain oscillations control hand orthosis in a tetraplegic», 2000.
- [79] G Mueller-Putz, R Scherer, e C Brunner, «Better than random? A closer look on BCI results», 2008.
- [80] Prof.ssa E. Magosso, «Appunti di Sistemi Neurali LM. Ingegneria Biomedica LM (Cesena)». 2014.
- [81] A. Hyvärinen, J. Karhunen, e E. Oja, *Independent Component Analysis*. John Wiley & Sons, 2004.
- [82] Guangquan Liu, Gan Huang, Jianjun Meng, e Xiangyang Zhu, «A frequency-weighted method combined with Common Spatial Patterns for electroencephalogram classification in brain–computer interface», 2010.
- [83] K. K. Ang, Z. Y. Chin, H. Zhang, e C. Guan, «Filter Bank Common Spatial Pattern (FBCSP) in Brain-Computer Interface», in *IEEE International Joint Conference on Neural Networks, 2008. IJCNN 2008. (IEEE World Congress on Computational Intelligence)*, 2008, pagg. 2390–2397.
- [84] Q. Novi, Cuntai Guan, T.H. Dat, e Ping Xue, «Sub-band Common Spatial Pattern (SBCSP) for Brain-Computer Interface», 2007.