

**UNIVERSITÀ DEGLI STUDI DI ROMA
"TOR VERGATA"**



FACOLTA' DI INGEGNERIA

**DOTTORATO DI RICERCA IN
SISTEMI E TECNOLOGIE PER LO SPAZIO**

XXI ciclo

TESI DI DOTTORATO

***“Analisi dei tempi di calcolo dell’algoritmo FastICA
per applicazioni di Brain-Computer Interface in
tempo reale”***

Stefania Di Giacomo

Relatore: Prof. Gian Carlo Cardarilli

Anno Accademico 2008/2009

INDICE

INTRODUZIONE	4
I. Nuove tecnologie e prospettive uomo-computer	4
II. Possibili applicazioni	6
III. Obiettivi della tesi	6
IV. Struttura della tesi	7
CAP. 1 Neurofisiologia	9
1.1 Neurofisiologia del sistema nervoso centrale	9
1.1.1 L'architettura del sistema nervoso	9
1.1.2 Il neurone	11
1.1.3 La corteccia cerebrale e il corpo calloso	12
1.1.4 Le funzioni dei quattro lobi della corteccia cerebrale	13
1.1.5 La specializzazione delle aree della corteccia cerebrale	14
Bibliografia	
CAP. 2 Sistemi BCI e interpretazione dei segnali EEG	17
2.1 I sistemi BCI (Brain-Computer Interface)	17
2.2 Che cos' è un sistema BCI	17
2.3 L'elettroencefalografia	20
2.3.1 I segnali elettroencefalografici in input	23
2.3.2 L'elettroencefalogramma	24
2.3.3 I potenziali evento-correlati (ERPs)	26
Bibliografia	
CAP.3 Il metodo ICA (Analisi delle Componenti Indipendenti) e l'algoritmo FastICA	29
3.1 Il problema della Blind Source Separation (BSS)	30
3.2 Incorrelazione	30
3.3 Indipendenza	31
3.4 L'Analisi delle Componenti Principali (PCA)	32
3.5 L'Analisi delle Componenti Indipendenti (ICA)	33
3.5.1 Definizione di ICA	33
3.5.2 Il problema del Cocktail Party	34
3.5.3 Un passo preliminare: lo sbiancamento dei dati	36
3.5.4 La massimizzazione della non-gaussianità per la stima delle componenti indipendenti.	37
3.5.5 La curiosità come stimatore per la massimizzazione della non-gaussianità.	38
3.5.6 La negentropia stimatore per la massimizzazione della non-gaussianità.	40
3.5.7 La ricerca delle componenti indipendenti mediante l'algoritmo FastICA	41
Bibliografia	

CAP. 4 Elaborazione e analisi dei dati sperimentali	45
4.1 Descrizione del software realizzato per l'elaborazione dei dati elettroencefalografici.	45
4.2 Valutazione della stabilità della matrice dei pesi: intervalli non sovrapposti	48
4.3 Valutazione della stabilità della matrice dei pesi: analisi di intervalli con overlap	50
4.4 Valutazione della stabilità della matrice dei pesi: analisi di intervalli sovrapposti (offset variabile da 5 a 85 campioni)	54
4.5 Stima dei tempi di esecuzione in funzione del numero di iterazioni	55
4.6 Stima del tempo di calcolo necessario per una singola iterazione (al variare dell'intervallo di tempo elaborato)	56
Bibliografia	
 CAP. 5 Risultati	 59
5.1 Stima della riduzione dei tempi di calcolo	59
5.2 Stima della potenza di elaborazione necessaria per l'implementazione hardware	60
5.3 Verifica della stabilità nell'ordine delle sorgenti calcolate (effetto di trascinamento)	61
 CONCLUSIONI	 64

INTRODUZIONE

I. Nuove tecnologie e prospettive uomo-computer

I nostri giorni ci offrono la possibilità di interagire in modo sempre più complesso con l'ambiente digitale che ci circonda, entrando in contatto con un mondo di informazioni sempre più ricche. Lo sviluppo di nuove e sofisticate interfacce tra il soggetto e i dati virtuali vede un coinvolgimento sempre più attivo e diretto dell'utente che si rispecchia nell'ultima frontiera della ricerca: la connessione tra la mente e la macchina.

Lo studio dell'attività cerebrale umana ha visto un notevole sviluppo negli ultimi quarant'anni grazie alle potenzialità offerte da nuove e sempre più sofisticate tecnologie per la misura dei parametri fisiologici cerebrali e il *brain-imaging*.

Con il termine "*brain imaging*" si indicano tutte le tecniche di analisi sulla struttura e funzionalità del cervello per controllare il suo corretto funzionamento o indagare eventuali condizioni patologiche. Si ottengono così delle immagini "in vivo" e non-invasive che rappresentano un importante strumento per la conoscenza delle funzioni cerebrali, ma anche, e soprattutto, per la prevenzione e la diagnosi delle malattie neurologiche e psichiatriche. Le metodiche maggiormente usate sono la "*single photon emission computerized tomography*" (SPECT), la "*positron emission tomography*" (PET), la "*functional magnetic resonance imaging*" (fMRI) e la "*magnetoencephalography*" (MEG).

Un'alternativa a queste tecnologie è rappresentata dalla semplice misura dell'elettroencefalogramma (EEG) sulla calotta cranica, in maniera completamente non invasiva.

L'EEG può essere considerato lo strumento di analisi più adatto per i sistemi BCI (*Brain Computer Interface*). Offre infatti il vantaggio di una risoluzione temporale assai elevata (fino a 10^{-4} s), che consente di seguire l'evoluzione dei processi nervosi, volti all'analisi di una informazione sensoriale, all'allestimento di una strategia cognitiva o di un programma motorio. Esso inoltre è effettuato con apparecchiature poco ingombranti, non necessita di un impegno elevato in termini di tempo e i suoi costi sono relativamente contenuti rispetto ad altre tecnologie.

I sistemi di *Brain-Computer Interface* sono in generale delle interfacce con le quali il cervello è in grado di interagire direttamente con un computer, mediante canali di comunicazione alternativi rispetto ai nervi periferici e ai muscoli. Intorno a questo nuovo campo della ricerca si sta rivolgendo un interesse a livello mondiale per innumerevoli applicazioni e sembra imminente un uso esteso e commerciale di queste tecnologie. E' già possibile oggi controllare direttamente con la mente protesi articolari, per esempio braccia meccanizzate, semplicemente utilizzando i rilevatori già impiegati per gli elettroencefalogrammi.

La BCI offre quindi straordinarie capacità di comunicazione e autonomia, permettendo a persone diversamente abili di soddisfare le proprie esigenze specifiche mediante la gestione e il controllo delle proprie risorse con il solo uso delle funzioni cerebrali.

Il segnale registrato dai rivelatori viene analizzato mediante un algoritmo che estrae le informazioni necessarie e le traduce in un linguaggio comprensibile alle macchine, permettendo di realizzare un determinato compito.

In altri termini, un dispositivo BCI può rilevare i *pattern* di attivazione del cervello e, ogni volta che l'utente produce la volontaria modifica di questi *pattern*, esso è in grado di rilevarla e di tradurla in un'azione associata ad una volontà dell'utente.

L'attività elettrica cerebrale viene prelevata tramite degli elettrodi di superficie, posizionati direttamente sul cuoio capelluto, che registrano i segnali elettroencefalografici.

La continua fluttuazione della normale attività cerebrale induce tra i vari punti del cuoio capelluto piccole differenze di potenziale elettrico (μV) che vengono amplificate e registrate normalmente per alcuni minuti (in casi particolari fino a 24 ore). Si ottiene in questo modo un tracciato che segna per ciascun elettrodo le variazioni del voltaggio nel tempo.

I potenziali correlati ad eventi (ERPs) sono variazioni di voltaggio registrate che sono correlate a processi sensoriali, motori o cognitivi e che quindi forniscono una visione delle funzioni cerebrali direttamente durante l'esecuzione di compiti.

Gli ERPs possono essere usati per valutare se un cervello sta funzionando normalmente e il modo in cui esso analizza l'informazione.

I potenziali evento-correlati (ERPs) costituiscono delle variazioni nei segnali elettroencefalografici (EEG) che si presentano con un certo ritardo rispetto allo stimolo esterno presentato al soggetto, mentre l'attività cerebrale di fondo rappresenta nel nostro caso la componente di rumore.

L'obiettivo quindi consiste nell'individuare gli ERPs mediante la tecnica più opportuna.

I meccanismi neurali che sono alla base della generazione degli ERPs non sono ancora ben noti e poco si conosce rispetto alla propagazione di tali segnali all'interno della corteccia cerebrale. Il modello assunto considera i dati elettroencefalografici raccolti sulla superficie della calotta cranica come una combinazione lineare dei segnali neuronali originali e il problema fondamentale è risalire a tali componenti semplicemente partendo dall'analisi dei dati registrati.

Tale metodologia prende il nome in generale di *Blind Source Separation* (BSS): l'obiettivo è ottenere la separazione di sorgenti "alla cieca", cioè dall'osservazione dei soli segnali miscelati, non avendo alcun accesso, né alcuna informazione, sulle sorgenti originali o sulla miscelazione.

Il problema della separazione delle sorgenti viene risolto in maniera sorprendentemente efficace dal metodo ICA (*Independent Component Analysis*).

Per poter applicare correttamente il modello base dell'ICA appena visto, è necessario assumere che le componenti che vogliamo stimare siano statisticamente indipendenti e presentino una distribuzione non gaussiana; l'ICA di un vettore consiste in una trasformazione lineare in grado di preservare l'informazione e di ottenere, come risultato, l'indipendenza statistica delle componenti in uscita.

Dobbiamo sottolineare però che nel modello di stima delle componenti indipendenti ci sono alcune ambiguità che non possono essere eliminate.

La prima è l'impossibilità di determinare le varianze, e quindi le energie, delle singole componenti indipendenti.

Il secondo problema riguarda l'impossibilità di determinare l'ordine delle componenti indipendenti individuate di volta in volta.

Vi sono molti algoritmi presentati dalla letteratura statistica che possono eseguire l'ICA. FastICA, scelto in questo lavoro di tesi, è uno degli algoritmi più utilizzati e di semplice implementazione per la ricerca delle componenti indipendenti, e uno dei suoi principali punti di forza è che non fa particolari ipotesi sulla distribuzione delle sorgenti.

II. Possibili applicazioni

Lo sviluppo delle nuove tecnologie per la creazione di interfacce cervello-computer sta interessando sempre più settori della ricerca scientifica, non solo in campo medico e neurofisiologico.

Innanzitutto importanti studi sono rivolti alla ricerca delle metodologie più opportune per migliorare la qualità di vita di soggetti “diversamente abili”.

Numerose patologie degenerative (quali Sclerosi amiotrofica laterale, ictus al tronco cerebrale, lesione al midollo spinale o al cervello, paralisi cerebrale, distrofia muscolare, sclerosi multipla, ecc.) possono compromettere in modo irreversibile e del tutto invalidante il funzionamento dei canali attraverso i quali normalmente il cervello comunica e controlla i comportamenti esterni. Coloro che subiscono i postumi di gravi incidenti stradali oppure le devastanti conseguenze di malattie invalidanti possono perdere completamente il controllo volontario di tutti i muscoli, inclusi i movimenti oculari e la respirazione, e restare completamente “imprigionati” (*locked-in*) nei loro corpi, impossibilitati a comunicare, seppure in possesso di tutte le funzioni cerebrali necessarie per controllare e gestire le esigenze personali. La tecnologia BCI può permettere a molti individui, anche *locked-in*, di migliorare in modo significativo la qualità della vita, interagendo in modo autonomo con il mondo circostante.

L'interesse verso queste nuove tecnologie coinvolge però, come dicevamo, settori molto più ampi della ricerca scientifica internazionale.

Il concetto di “disabilità”, infatti, ha un significato molto più esteso di quello strettamente medico, e riguarda l'interazione che il soggetto ha con l'ambiente circostante e non l'individuo in quanto tale. In questo senso, anche un astronauta nello spazio può essere considerato “disabile”, poiché in quella circostanza diventa difficile per lui compiere anche il più piccolo movimento, come spingere il pulsante di una tastiera. L'utilizzo di interfacce mente-computer può avere quindi interessanti applicazioni spaziali per facilitare la comunicazione degli astronauti e anche per fornire loro una funzione anti-stress, mediante il controllo dell'attenzione e il conseguente miglioramento della concentrazione (*biofeedback*). Inoltre, l'individuazione delle sorgenti di rumore mediante il metodo ICA e la possibilità di una loro rimozione automatica, aumentando in modo significativo l'SNR, rappresenta uno strumento essenziale in esperimenti spaziali come ALTEA.

In ultimo, si sta sviluppando anche un significativo interesse commerciale verso tali tecnologie, per svariate applicazioni nella vita quotidiana e nel mondo della realtà virtuale.

III. Obiettivi della tesi

Questa tesi si è inserita nello sviluppo del progetto di *Brain Computer Interface* italiano svolto dall'Università di Tor Vergata nell'ambito della collaborazione tra il Dipartimento di Neuroscienze e il Dipartimento di Ingegneria Elettronica, finanziato dall'ASI.

L'applicazione del metodo ICA ai dati elettroencefalografici permette di stimare le sorgenti neuronali originarie dei segnali cerebrali e di aumentare l'SNR eliminando le fonti di rumore o selezionando solo le componenti che sono chiaramente legate all'attività cerebrale.

Il lavoro è stato guidato in particolare dalla necessità di raggiungere due obiettivi principali:

1. Verificare la possibilità di un'analisi in tempo reale.
2. Risolvere il problema dell'indeterminazioni delle sorgenti elaborate mediante il metodo ICA, permettendo l'eliminazione automatica delle sorgenti di rumore individuate.

Pertanto si è presentato il problema di rispondere principalmente a due interrogativi:

1. Quanto sono stabili nel tempo i parametri stimati mediante l'algoritmo?
2. Qual è la potenza di elaborazione necessaria per un'eventuale implementazione hardware?

A tale scopo sono stati analizzati i dati elettroencefalografici registrati direttamente sulla calotta cranica mediante un sistema di 59 elettrodi. Per analizzare i dati è stato creato un software in C++ utilizzando la libreria open-source "IT++" per l'algoritmo FastICA.

L'analisi è stata eseguita su un set di dati registrati in base al protocollo P300, variando la durata degli intervalli di tempo elaborati e la matrice di input iniziale. In seguito i dati elaborati sono stati analizzati per ottenere le risposte ai quesiti prefissati.

IV. Struttura della tesi

La tesi è strutturata nel seguente modo:

Capitolo 1: Neurofisiologia. Vengono descritti i meccanismi principali di funzionamento del sistema nervoso, con particolare riferimento alla struttura dell'encefalo, alla formazione degli impulsi nervosi generati dal neurone e alla funzione delle diverse aree della corteccia cerebrale.

Capitolo 2: Sistemi BCI e interpretazione dei segnali EEG. È descritta la struttura generale dei sistemi di *Brain Computer Interface* (BCI), le caratteristiche di un elettroencefalogramma e dei segnali EEG acquisiti e il significato dei potenziali evento-correlati (ERPs).

Capitolo 3: Il metodo ICA (Analisi delle Componenti Indipendenti) e l'algoritmo FastICA. È introdotto il problema generale della *Blind Source Separation* (BSS), sono descritti le basi teoriche fondamentali del metodo di Analisi delle Componenti Indipendenti (ICA) e le caratteristiche principali dell'algoritmo FastICA.

Capitolo 4: Elaborazione e analisi dei dati sperimentali. Viene descritto il software realizzato per l'analisi dei dati sperimentali e le numerose elaborazioni eseguite per la valutazione dei parametri da stimare. Viene valutata la stabilità della matrice dei pesi e sono stimati i tempi di calcolo per l'elaborazione.

Capitolo 5: Risultati. Sono riportati i risultati principali ottenuti in seguito all'analisi dei dati elaborati. È stimata la riduzione dei tempi di calcolo ottenibile

variando la matrice di input dell'algoritmo e la potenza di elaborazione necessaria per l'implementazione hardware; viene verificata infine la stabilità nell'ordine delle sorgenti individuate.

Conclusioni. Sono riportati e discussi i risultati principali della tesi in relazione agli obiettivi prefissati.

CAP. 1 Neurofisiologia

1.1 Neurofisiologia del sistema nervoso centrale [1][2]

Lo studio del sistema nervoso di animali a vari livelli di organizzazione, dai più semplici ai più complessi della scala zoologica, sino all'uomo, ha dimostrato che non vi sono sorprendenti differenze nella loro struttura fondamentale: le cellule nervose sono morfologicamente simili tra loro e anche i meccanismi mediante i quali sono fra loro in comunicazione non differiscono sostanzialmente.

Ciò che cambia, passando dal più semplice al più complesso, è il numero delle cellule nervose, la complessità delle loro interconnessioni e il formarsi di sottoinsiemi variamente integrati.

Si chiama eccitabilità la capacità degli esseri viventi di rispondere agli stimoli dell'ambiente, ed è una caratteristica di tutti gli esseri viventi. L'ambiente può essere esterno o interno all'organismo, ma, in ogni caso, lo stimolo viene percepito, rielaborato, e viene fornita una risposta. [3]

1.1.1 L'architettura del sistema nervoso

Il sistema nervoso è costituito da un centro di "elaborazione dati" e da una periferia che raccoglie informazioni e che reagisce agli stimoli.

Nella figura 1 possiamo osservare lo schema che definisce la struttura del sistema nervoso.




Figura 1 Struttura del sistema nervoso

Il sistema nervoso comprende il sistema nervoso centrale e il sistema periferico. Il primo, formato dall'encefalo e dal midollo spinale, interpreta i segnali che provengono

sia dall'esterno sia dall'interno del corpo, ed elabora risposte. Il sistema nervoso periferico è formato da nervi sensitivi e motori, che trasmettono rispettivamente segnali dagli organi di senso e segnali che controllano muscoli e ghiandole. In particolare, il sistema nervoso somatico agisce sull'attività di muscoli scheletrici, volontari, mentre il sistema autonomo regola le risposte involontarie della muscolatura liscia, di ghiandole e organi. Il sistema autonomo simpatico ha un effetto globale di preparazione dell'organismo a situazioni di stress o di maggiore dispendio energetico; il parasimpatico determina un effetto opposto, determinando un effetto di rilassamento delle funzioni involontarie.

L'encefalo ha un peso medio di 1200-1300 grammi ed è rivestito da membrane dette meningi. Esso elabora le informazioni provenienti dal corpo e dal mondo esterno, innescando processi di risposta che possono essere di tipo chimico, motorio, comportamentale. Presiede a funzioni complesse come l'attenzione, la coscienza, il sonno, la memoria, l'immaginazione, il pensiero e l'abilità creativa.

Le funzioni dell'encefalo sono svolte da un'enorme quantità di cellule nervose, circa 100 miliardi. Esistono diversi tipi di neuroni, che vengono definiti in base alla forma, al tipo di connessioni che essi formano tra loro, all'architettura cellulare e alla composizione biochimica. Il cervello propriamente detto contiene all'incirca la metà dei neuroni complessivamente presenti nell'encefalo e appare diviso in due emisferi, tra loro connessi da un fascio di fibre nervose che prende il nome di corpo calloso. Nell'encefalo umano si riconoscono tre parti fondamentali: il prosencefalo (che comprende cervello, talamo e sistema limbico, in cui è l'ipotalamo); il mesencefalo; il rombencefalo (formato da cervelletto, ponte di Varolio e midollo allungato). In questa sezione di encefalo, si riconoscono le circonvoluzioni del cervello e il corpo calloso, che collega i due emisferi; il talamo, che funge da centro di smistamento degli impulsi nervosi; l'ipotalamo, coinvolto in molti processi omeostatici e nella produzione di alcuni ormoni; inoltre, si distinguono il ponte di Varolio e il midollo allungato, in cui sono localizzati importanti centri di controllo del ritmo sonno-veglia, della respirazione, della pressione sanguigna e del battito cardiaco. Il talamo, il ponte di Varolio e il midollo allungato formano il cosiddetto tronco cerebrale, struttura anatomica di collegamento tra il midollo spinale e la corteccia cerebrale. Il cervelletto, collocato nella porzione inferiore dell'encefalo, ha funzioni di coordinazione dei movimenti e dell'equilibrio.

L'encefalo comprende quattro cavità: due ventricoli laterali, collegati attraverso i forami di Monro a un terzo ventricolo, che comunica con il quarto ventricolo mediante l'acquedotto di Silvio.

La corteccia cerebrale, infine, è il luogo in cui risiedono i corpi cellulari dei neuroni, per questo motivo il suo aspetto è più scuro della restante massa cerebrale ed è detta sostanza grigia, in contrasto con la sostanza bianca, il cui colore è determinato dai fasci di fibre mieliniche.

Nella figura 2 possiamo osservare una rappresentazione dell'encefalo umano.




Figura 2 Encefalo umano

1.1.2 Il neurone

Il neurone è il tipo cellulare che compone, insieme alle cellule gliali, il tessuto nervoso. Grazie alle sue peculiari proprietà fisiologiche è in grado di ricevere, integrare e trasmettere impulsi nervosi.

Nel neurone si possono identificare 4 aree morfologiche: il nucleo (o soma), i dendriti, l'assone e i terminali pre-sinaptici (vedi figura 3). I dendriti rappresentano gli "ingressi" del neurone mentre l'assone è l'uscita. I segnali elettrici trasmessi lungo l'assone (potenziali d'azione o *spikes*) sono impulsivi con un'ampiezza di circa 100 mV e con una durata di circa 1 ms. Il segnale si propaga ad una velocità che varia da 1 a 100 m/s. L'alta velocità di conduzione è ottenuta per mezzo della guaina mielinica.

Infine la sinapsi (o giunzione sinaptica o bottone sinaptico), dal greco "connettere", è una struttura altamente specializzata che consente la comunicazione tra le cellule del tessuto nervoso, i neuroni. Attraverso la trasmissione sinaptica, l'impulso nervoso può viaggiare da un neurone all'altro o da un neurone ad una fibra p.es. muscolare (giunzione neuromuscolare).

Gli impulsi nervosi trasmessi dai neuroni sono impulsi di natura chimica ed elettrica.

Il flusso di cariche elettriche si trasmette poiché la membrana cellulare del neurone, la parte più esterna, subisce una modifica della propria carica elettrica: dalla situazione a riposo, la membrana assume una carica elettrica positiva. Lo spostamento delle cariche positive provoca una reazione a catena e il conseguente spostamento dell'impulso nervoso.

Il neurone a riposo è polarizzato con una ddp di -70 mV (potenziale di membrana a riposo). La concentrazione di ioni negativi è maggiore all'interno del neurone. Se, in conseguenza di ciò che avviene sulle sinapsi, il neurone si depolarizza a valori maggiori di circa -50mV, viene generato un potenziale d'azione. I potenziali d'azione hanno la stessa forma e ampiezza.

Il treno di impulsi viaggia lungo l'assone e raggiunge la regione terminale.

Gli impulsi stimolano il rilascio di neurotrasmettitori (il segnale d'uscita) e questo processo viene chiamato trasmissione sinaptica.

L'ampiezza del segnale d'uscita è determinata dall'ampiezza della depolarizzazione che, a sua volta è determinata dal numero e dalla frequenza degli impulsi.

I neurotrasmettitori sono sostanze chimiche e ormoni, ognuno dei quali contiene un preciso messaggio da trasmettere e possiede un ruolo specifico nella funzione cerebrale e nel comportamento.

Attraverso questo complesso processo chimico ed elettrico, il Sistema Nervoso riceve dai differenti organi di senso milioni di informazioni, le integra e determina quale risposta dovrà essere data dall'organismo.




Figura 3 Schema della struttura di un neurone

1.1.3 La corteccia cerebrale e il corpo calloso

Lo studio della struttura (*anatomia*), della funzione (*fisiologia*) e delle malattie del sistema nervoso sono le Neuroscienze, una disciplina emersa solamente negli ultimi decenni. Proviamo a chiudere le mani a pugno. Ciascun pugno ha pressa poco la grandezza di un emisfero cerebrale, e se uniamo i pugni mettendo in contatto le dita corrispondenti, abbiamo un'idea immediata della struttura simmetrica del nostro cervello. L'emisfero sinistro è più competente del destro riguardo al pensiero e linguaggio logico matematico, il destro è specializzato nel pensiero analogico, nelle azioni spaziali e nel linguaggio musicale ed artistico.

Queste due grandi masse bilaterali sono connesse tra di loro mediante fasci di fibre nervose, le quali formano il corpo calloso. Se tali fasci di fibre vengono tagliati o distrutti (commissurotomia cerebrale), i due emisferi funzionano come entità separate, dando luogo a pensieri distinti, linguaggi distinti e reazioni comportamentali distinte nelle due metà del nostro corpo. Ciascun emisfero elabora informazioni contro laterali. Gli emisferi

non sono simmetrici (sia anatomicamente che funzionalmente). Caratteristica dei due emisferi è che il sinistro controlla i movimenti della parte destra del nostro corpo, mentre il destro controlla quelli della parte sinistra.

La corteccia cerebrale, la sostanza grigia che ricopre gli emisferi, pur avendo uno spessore di soli tre millimetri, è la parte distintiva del cervello umano: è molto più grande e complessa nell'uomo che in qualsiasi altro animale. Le più significative doti del nostro cervello sono realizzate dalla corteccia: è qui che si organizzano le informazioni pervenute, si immagazzinano le esperienze, si comprende il linguaggio, si ascolta la musica e si guardano le immagini. Il nostro stesso pensiero, dunque, ha origine dalla corteccia cerebrale.

1.1.4 Le funzioni dei quattro lobi della corteccia cerebrale

Il tentativo di mettere in relazione “biologia” e comportamento inizia già alla fine del XVIII secolo con Franz Joseph Gall: aree discrete della corteccia cerebrale controllano funzioni specifiche. Il cervello non è un unico organo ma è formato da un insieme di almeno 35 organi a ciascuno dei quali corrisponde una facoltà mentale.

La corteccia è formata da strati di neuroni e da un labirinto di circonvoluzioni, tra cui si distinguono due solchi principali. Questi, a loro volta, permettono di suddividere ciascun emisfero della corteccia in quattro lobi (v. figura 4), frontale, parietale, temporale e occipitale, ognuno dei quali presiede a funzioni specifiche e differenziate. Le convoluzioni cerebrali hanno la funzione di aumentare la superficie della corteccia (evoluzione) e presentano delle regolarità fra individui (solchi e giri si ritrovano simili in tutti gli individui). I lobi frontali sono quelli più sviluppati ed estesi: dirigono gran parte dell'attività del cervello. Sono implicati in ogni forma di elaborazione del pensiero, nei processi decisionali, nella risoluzione dei problemi, nella pianificazione e nella creatività. Presiedono anche al controllo muscolare. I lobi temporali, posti dietro alle tempie, sono responsabili dell'udito, ma sono anche implicati nelle funzioni della memoria e nell'elaborazione delle emozioni. I lobi parietali presiedono alla ricezione e all'elaborazione delle informazioni sensoriali che provengono da tutto il corpo. E' qui che “montiamo” la visione del nostro mondo, unendo le lettere in parole e le parole in frasi, pensieri, concetti. I lobi occipitali, infine, posti nella parte posteriore di ogni emisfero, sono implicati nella visione.

La zona dove i quattro lobi si incontrano è la principale area del cervello dove avviene l'integrazione delle informazioni sensoriali. Si introduce qui un concetto fondamentale nelle Neuroscienze: quello della segregazione funzionale, secondo cui ogni parte del Sistema Nervoso ha una specifica funzione, e solo la corretta integrazione di tutte le parti ne garantisce quindi un adeguato funzionamento.




Figura 4 I quattro lobi della corteccia cerebrale

1.1.5 La specializzazione delle aree della corteccia cerebrale

Ciascuno dei lobi della corteccia cerebrale elabora informazioni specifiche e svolge una funzione diversa. Benché le funzioni specifiche delle diverse aree della corteccia siano ancora oggetto di molte discussioni e indagini, esistono, tuttavia, alcune nozioni relativamente consolidate. Ad esempio, i lobi frontali sono specializzati nell'organizzazione e nel controllo dei movimenti e contengono la corteccia motoria primaria. Le cellule di questi lobi sono organizzate in modo topografico e la loro stimolazione con una debole corrente elettrica può provocare il movimento della parte corrispondente del corpo. I lobi occipitali elaborano le informazioni visive primarie e poi le inviano in avanti, sia al lobo parietale che a quello temporale. I lobi parietali elaborano le informazioni somatosensoriali primarie (cioè quelle provenienti dalla cute, dai muscoli e dalle articolazioni), mentre il lobo temporale elabora le informazioni uditive primarie (provenienti dagli organi dell'udito). La corteccia temporale sembra essere necessaria per il riconoscimento e la classificazione degli oggetti, per la memoria a lungo termine e per alcuni aspetti del linguaggio (controllata a livello della cosiddetta area di Broca). La corteccia parietale sembra deputata alla mediazione della percezione della posizione degli arti, discriminando ad esempio tra diversi oggetti tenuti in mano.

Tuttavia la suddivisione in lobi non è sufficiente a definire tutte le aree funzionali che sono state finora identificate. Sono stati proposti diversi tipi di classificazione, ma la più generalmente accettata è la classificazione secondo Brodmann, che identifica le singole aree con un numero.

Brodmann ha identificato anatomicamente 52 diverse aree della corteccia cerebrale (v. figura 5).

Per molte di queste aree è stata trovata successivamente una specializzazione funzionale.

Il fatto che funzioni di “alto livello” non siano localizzate aumenta la plasticità del cervello: le aree rimaste si riorganizzano. La rappresentazione della conoscenza è distribuita: lesioni localizzate distruggono solo in parte la conoscenza (ad esempio la capacità di riconoscere i volti o di associare odori a oggetti). Nei pazienti “*split brain*”

(soggetti in cui è stato reciso il corpo calloso), ad esempio, ciò che è mostrato all'emisfero destro è riconosciuto ma non è possibile articolare il nome.




Figura 5 Le aree di Brodmann

BIBLIOGRAFIA CAP.1

- [1] Ben Greenstein, *Neuroscienze. Neuroanatomia e neurofisiologia. Testo atlante*, CIC Edizioni Internazionali, Roma 2000.
- [2] Luca Imeri, Mauro Mancia, *Testo atlante di fisiologia umana. Neurofisiologia*, Casa ed. Ambrosiana, Milano 2006.
- [3] Pietro Tonali, *Medicina viva- il sistema nervoso*, Fabbri Editori, Milano 1976.

CAP. 2 Sistemi BCI e interpretazione dei segnali EEG

2.1 I sistemi BCI (*Brain-Computer Interface*)

Il progresso tecnologico raggiunto ai nostri giorni, fornisce alle persone diversamente abili la possibilità di vivere in condizioni di vita decisamente migliori, insegnando loro ad usare dispositivi elettronici che permettono un'interazione con il mondo circostante.

In questo contesto, la BCI (*Brain-Computer Interface*) riveste un ruolo importante per le possibilità di comunicazione che offre ad individui che si trovano nell'impossibilità quasi totale di comunicare con il mondo esterno, senza poter effettuare movimenti di alcun tipo, nemmeno oculari. Il limite di questa tecnologia è la continua necessità di istruire il soggetto sullo stato del sistema attraverso il feedback prodotto da un monitor.[1]

Bisogna sottolineare che le applicazioni della BCI non si limitano soltanto al campo strettamente medico.

Dobbiamo considerare infatti che la definizione "diversamente abile" non riguarda la persona nella sua individualità, ma la relazione che questa è in grado di instaurare con il mondo circostante. Un astronauta nello spazio, ad esempio, risulta "diversamente abile" poiché si trova nella difficoltà di compiere anche i gesti più semplici, con evidenti problemi di movimento e comunicazione con l'ambiente in cui è immerso. Ecco perché la BCI si presenta come una valida opportunità per applicazioni spaziali.[2]

2.2 Che cos' è un sistema BCI

La nostra epoca è caratterizzata da un'interazione sempre più frequente e complessa con l'ambiente digitale che ci circonda. Ogni giorno ci connettiamo con un mondo di informazioni sempre più ricche, e comunichiamo con tale enorme mole di dati virtuali attraverso interfacce in continua evoluzione. Un'evoluzione che porta verso un coinvolgimento sempre più attivo e diretto dell'utente, che si rispecchia nell'ultima frontiera della ricerca: la connessione tra la mente e la macchina. [3]

La BCI (*Brain-Computer Interface*) è un'interfaccia in grado di creare una connessione diretta tra il cervello e un computer. Gli sforzi della ricerca a livello mondiale si stanno indirizzando verso questo nuovo campo di applicazione, tanto che sembra imminente un uso diffuso e commerciale di queste tecnologie. Già da oggi, è possibile controllare direttamente con la propria mente protesi articolari, per esempio braccia meccanizzate, semplicemente utilizzando i rilevatori già impiegati per gli elettroencefalogrammi.[4]

I rilevatori dialogano con un computer attraverso un algoritmo che traduce i segnali registrati in un linguaggio comprensibile alle macchine. [5]

Naturalmente, la BCI rappresenta una promettente opportunità per persone con disabilità motorie, che potranno utilizzare i propri segnali cerebrali per muovere un braccio robotizzato o una neuroprotesi senza dover subire l'impianto di elettrodi nel cervello.

La BCI permette quindi ad una persona diversamente abile di gestire e utilizzare il proprio sistema di controllo in base alle proprie risorse ed esigenze specifiche, fornendo agli utenti canali di comunicazione che non dipendono dai normali canali di uscita del cervello rappresentati dai nervi periferici e muscoli.

In altri termini, un dispositivo BCI può rilevare i *pattern* di attivazione del cervello e, ogniqualevolta l'utente produce la volontaria modifica di questi *pattern*, esso è in grado di rilevarla e di tradurla in un'azione associata ad una volontà dell'utente.[6]

Lo sviluppo di un dispositivo BCI necessita di uno strumento affidabile per la misurazione dell'attività mentale nell'uomo.

Sia procedure invasive, che richiedono l'inserimento di elettrodi nel cervello, che costose e sofisticate tecnologie di *brain imaging* non invasivo possono dare informazioni sui processi cerebrali in corso nel soggetto.

Il termine "*brain imaging*" include tutte le tecniche di analisi del cervello nelle sue componenti strutturali e/o funzionali, sia in rapporto al suo normale funzionamento che a quello patologico. Le immagini ottenute sono "in vivo" e non-invasive e rappresentano quindi uno sviluppo importante, non solo per l'aumento delle conoscenze, ma anche e, soprattutto, per la prevenzione e la diagnosi delle malattie neurologiche e psichiatriche. Le metodiche maggiormente usate sono la "*single photon emission computerized tomography*" (SPECT), la "*positron emission tomography*" (PET), la "*functional magnetic resonance imaging*" (fMRI) e la "*magnetoencephalography*" (MEG).

Un'alternativa a queste tecnologie è rappresentata dalla semplice misura dell'elettroencefalogramma (EEG) sullo scalpo [7], in maniera completamente non invasiva. D'altra parte va osservato come il segnale elettroencefalografico in realtà sia di difficile analisi, in quanto i fenomeni di interesse sono completamente immersi nel segnale EEG di fondo. La sfida è quella di riconoscere lo stato mentale del soggetto fra un insieme discreto di stati possibili, mediante la sola analisi dell'EEG. L'obiettivo di queste ricerche è di generare un dispositivo trasportabile che implementa una interfaccia fra cervello e computer (*Brain Computer Interface*).

La PET, la SPECT e la fMRI consentono di misurare l'attività metabolica del cervello con una elevata risoluzione spaziale (frazioni di centimetro), ma hanno l'inconveniente di un'assai bassa risoluzione temporale (qualche secondo) (Gratton et al., 1991). Diversamente, l'EEG (Matejcek, 1982; Coles, 1989; Nunez, 1991) e la MEG (Romani, 1990) offrono il vantaggio di una risoluzione temporale assai elevata (fino a 10^{-4} s) che consente di seguire l'evoluzione dei processi nervosi, volti all'analisi di una informazione sensoriale, all'allestimento di una strategia cognitiva o di un programma motorio, oltre ad avere apparecchiature meno ingombranti.

Rispetto ai segnali EEG, i segnali MEG presentano alcuni vantaggi:

- ❖ non sono influenzati dalle proprietà dielettriche e resistive dei tessuti;
- ❖ la misura avviene su di una scala che non dipende da un livello di riferimento (il potenziale di riferimento elettrico costituisce invece una notevole limitazione per l'analisi dei segnali EEG).

D'altro canto i limiti della MEG sono rappresentati:

- ❖ dal numero eccessivamente basso di siti di registrazione simultanea che le attuali tecnologie sono in grado di offrire;

- ❖ dal notevole impegno in termini di tempo e strutture sia hardware che software di cui la mappatura topografica delle sorgenti dei campi magnetici necessita (molto maggiori di quelli richiesti da analoghe procedure per i campi elettrici);
- ❖ dall'alto costo delle attuali tecnologie di registrazione e dalla impossibilità di rilevare i campi magnetici correlati alle correnti radiali allo scalpo.

Ciò ha candidato l'EEG ad essere lo strumento di analisi più adatto per i sistemi BCI.

L'EEG viene prelevato mediante una serie di sensori posti sullo scalpo (detti elettrodi) e rappresenta una possibile misura indiretta dell'attività mentale nell'uomo. L'interesse della BCI nell'impiego di dati EEG risiede nel fatto che questi possono essere sottoposti a processamenti che ne estraggano indici quantitativi. Le variazioni nel tempo di tali indici sono utilizzabili come input per algoritmi di decisione in grado di determinare lo stato mentale prodotto dal soggetto. E' evidente che per essere impiegato all'interno di sistemi di BCI, per l'ausilio a persone "diversamente abili", l'EEG deve poter essere sensibile alla immaginazione di atti motori, deve cioè poter variare quantitativamente e in modo affidabile durante un compito immaginativo rispetto ad una situazione di riposo. [8]

I segnali BCI si classificano in base al tipo di attività elettroencefalografica (EEG): generata internamente dal soggetto (endogena) o legata a stimoli esterni a cui l'EEG del soggetto 'reagisce' (esogena o evocata). Un dispositivo BCI basato su attività endogena EEG consente all'utente, dopo un periodo di addestramento, la generazione spontanea di stati mentali usati per il colloquio con esso.

Di fondamentale importanza in un sistema BCI è l'utilizzo del feedback, sia esso usato per permettere al soggetto di imparare a modulare il proprio EEG (endogeno) o semplicemente per somministrare al soggetto gli stimoli e registrarne le reazioni (esogeno).

Viene da sé come questa tipologia di feedback impegni il canale visivo del soggetto impedendogli o comunque rendendone difficile il suo utilizzo per altri scopi.

Volendo schematizzare, come mostrato nella figura 1, la BCI è in generale un'interfaccia che prevede l'acquisizione di segnali cerebrali mediante un sistema di elettrodi e un amplificatore di segnali elettroencefalografici, uno stadio di elaborazione informatica, la visualizzazione di un feedback attraverso un monitor e la realizzazione di un evento desiderato (ad esempio scegliere le lettere sulla tastiera di un computer, far funzionare un dispositivo, ...).[9] [10]




Figura 1 Schema generale di un sistema BCI

2.3 L'elettroencefalografia

L'elettroencefalografia è una tecnica che permette la registrazione dell'attività elettrica superficiale dello scalpo, prodotta da sorgenti correlate all'attività combinata dei singoli neuroni sottostanti.

I primi studi sull'EEG, capaci di dimostrarne l'utilità clinica, risalgono al 1929 e sono dovuti ad Hans Berger.

Nel corso degli anni l'elettroencefalografia è stato uno strumento prezioso in neurologia per la modellizzazione dei processi cerebrali mentre non ha brillato in psichiatria in quanto anche persone con problemi psichici mostrano tracciati EEG sostanzialmente nella norma.

La registrazione del segnale EEG avviene in maniera non invasiva attraverso l'uso di piccoli elettrodi costituiti da placche di Ag rivestite elettroliticamente da AgCl. Tali elettrodi vengono posti sul cuoio capelluto a contatto con la pelle (opportunamente sgrassata).

A volte, per evitare che gli elettrodi si stacchino o per maggiore comodità, vengono sostituiti da una cuffia elasticizzata con elettrodi già posizionati.

Il potenziale rilevato va dai 10 ai 150 μV , per cui, si rende necessario l'impiego di amplificatori di alto guadagno e particolarmente insensibili al rumore (basti pensare che nella pratica clinica, gli elettroencefalografi vengono utilizzati in camere non schermate, quindi soggette a disturbi elettromagnetici di ogni sorta).

In un recente passato (e per alcune applicazioni cliniche tuttora) l'uscita dell'amplificatore veniva applicata ad un elettromagnete che comandava lo spostamento di un pennino sulla carta in movimento a velocità costante. Attualmente il segnale all'uscita dell'amplificatore viene digitalizzato e fornito ad un calcolatore che provvede alla sua registrazione e visualizzazione.

Il sistema di rilevazione consiste in una rete di elettrodi che vengono disposti sul cranio, in accordo allo standard 10-20 o 10-10 stabilito dalla Società Internazionale di Elettroencefalografia. Il nome deriva dal valore percentuale delle distanze che separano i vari elettrodi.

L'elettroencefalografia è una tecnica correntemente impiegata in fisiologia ed in patologia neurologica. La forma delle alterazioni del tracciato e la loro distribuzione contribuiscono, spesso in maniera determinante, al raggiungimento della diagnosi. Un tracciato EEG normale è costituito da un'insieme di ritmi a frequenze differenti nella banda da 0 a 70 Hz. La potenza di ognuno di questi ritmi è funzione dello stato psicologico del soggetto (ad esempio dello stato di vigilanza).

Nella pratica EEG si suole individuare nei tracciati la presenza di determinati tipi di onde, descritte in letteratura e associate ad attività fisiologiche o patologiche. La principale caratteristica che distingue queste onde è la frequenza, per cui si può associare alla comparsa di un tipo di onde nei dati acquisiti un addensamento dello spettro di densità di potenza in una stretta banda intorno alla sua frequenza caratteristica.

Dobbiamo considerare che il cervello è sempre in attività sia durante la veglia, sia durante il sonno e che esiste un'attività elettrica spontanea.

I ritmi rilevabili in un tracciato EEG sono i seguenti:

- onde α : si tratta di onde regolari che occupano la banda 8-12 Hz. Si prelevano bene nella zona del cranio subito sopra i lobi occipitali ed hanno ampiezza attorno ai 50 μ V. Si osservano quando il soggetto è sveglio a occhi chiusi e in stato di riposo muscolare, sensoriale e intellettuale. Nei bambini in genere non è presente. La sua assenza anche in età più avanzata non è indice di patologia, come del resto non lo è l'assenza di qualunque altra onda. In genere l'ampiezza dei vari ritmi aumenta con l'età sino a stabilizzarsi attorno ai 25 anni.
- onde β : occupano la banda 13-30 Hz. Nel caso di forte attività possono raggiungere anche i 35 Hz. Le onde β si suddividono in due classi: quelle di tipo I, di frequenza circa doppia delle onde α , sono simili in particolare alla transizione che subiscono le onde α successivamente all'apertura degli occhi; quelle di tipo II, che compaiono quando vi è intensa attività del sistema nervoso centrale e possono comparire nei soggetti normali in concomitanza con assunzione di droghe (barbiturici e benzodiazepine).
- onde δ : occupano la banda 1-3 Hz. Sono presenti nelle zone parietali e temporali dei bambini, ma possono essere presenti anche negli adulti come originati da forti stress emozionali, oppure in pazienti con disordini metabolici, o con estese lesioni del midollo allungato e/o cervello medio.
- onde θ : occupano la banda 4-7 Hz. Sono presenti nel sonno profondo o se sono in atto gravi patologie organiche del cervello. L'ampiezza di queste onde può variare da meno di 1 μ V a circa 200 μ V.

Nella figura 2 possiamo osservare un esempio di onde α e β .




Figura 2 Esempio di onde α e β

In caso di stimolazione sensoriale o di attività psichica, sul tracciato appaiono bruscamente delle onde rapide; tale fenomeno compare anche ad ogni apertura degli occhi del soggetto in registrazione (reazione d'arresto o α blocking).

Già dal 1929 (osservazioni originali di Hans Berger) si è notato come la chiusura e l'apertura degli occhi provochi, nel tracciato EEG registrabile sopra l'area occipitale dello scalpo, una diminuzione ed un incremento, rispettivamente, delle oscillazioni nella banda di frequenze compresa tra 8 e 12 Hz (banda α). Alcuni decenni dopo (1977) alcuni ricercatori austriaci si accorsero che variazioni delle oscillazioni nella banda α (dette ritmi μ) sono presenti nelle registrazioni EEG prelevate sopra l'area motoria in preparazione ad un movimento volontario nell'uomo. Tale fenomeno, conosciuto come desincronizzazione α , e' anche accompagnato da un incremento dopo la fine del movimento delle oscillazioni EEG nella banda di frequenza da 12-20 Hz (sincronizzazione beta).

Gli incrementi e decrementi delle oscillazioni cerebrali in relazione all'attività motoria eseguita sono quindi candidati per segnalare l'inizio e la fine dell'attività motoria eseguita del soggetto sperimentale. E' stato recentemente provato come l'attività immaginativa del movimento produca una desincronizzazione dell'attività EEG nella banda α , sopra le appropriate aree motorie. Si può affermare, dunque, che l'attività immaginativa ha un suo corrispondente misurabile con l'EEG. Questo ha consentito ad alcuni gruppi di ricerca nel mondo di poter implementare alcune *Brain Computer Interfaces*.

Le principali applicazioni dell'esame EEG si hanno in neurologia e tra esse:

- ❖ Traumatologia: viene verificata la presenza di danni cerebrali subito dopo un trauma. In tali ambiti si cerca l'assenza di segnale EEG in determinate zone, oppure segnali con picchi elevati in zone sofferenti.
- ❖ Epilessia: è una delle poche patologie diagnosticabili con l'esame EEG. Si ha un'attività anomala nella banda 1-50 Hz, che restituisce un segnale sostanzialmente rumoroso. Il cosiddetto "piccolo male" restituisce un segnale con caratteristici *spikes* che si sovrappongono a componenti in bassa frequenza (1-3 Hz.)
- ❖ Tumore: in questa malattia una parte del tessuto sano viene sostituita con un tessuto avente un contenuto di acqua nettamente superiore. Se l'estensione della zona interessata è ampia si nota la presenza anomala di scariche elettriche lente (ritmo). Un altro segnale della presenza di tessuti anomali è l'asimmetria tra i tracciati dell'emisfero destro e sinistro.
- ❖ Monitoraggio: al posto dell'ECG nei casi di interventi a cuore aperto.
- ❖ Ricerca: nello studio del sonno, della risposta a stimoli esterni, nella ricerca di nuove interfacce tra uomo e computer (BCI).

La morfologia di un tracciato EEG è evidentemente dipendente dallo stato psicologico generale del soggetto. Già dall'ispezione visiva è possibile, per esempio, stabilire se i potenziali siano stati raccolti mentre il soggetto teneva gli occhi aperti oppure chiusi e stimare il suo stato di attenzione. Tecniche di analisi dei segnali permettono poi di riconoscere grossolanamente lo stato emotivo, o lo svolgimento di particolari compiti mentali, se questi vengono eseguiti per un intervallo di tempo sufficientemente lungo.

Esiste poi una stretta correlazione tra quelli che in letteratura sono descritti come “ritmi EEG” e le proprietà spettrali del segnale EEG. Si può infatti riscontrare che la densità spettrale di potenza dell'EEG di base si presenta come una successione di picchi, tra i quali il più prominente è quello che occupa una banda intorno ai 10 Hz . Da ciò trae origine il fatto che quando il soggetto è rilassato, i suoi tracciati EEG mostrano un andamento ritmico avente approssimativamente tale frequenza. In opportune condizioni di impegno mentale, il picco α tende ad appiattirsi, permettendo così ad altri ritmi di evidenziarsi nei tracciati.

2.3.1 I segnali elettroencefalografici in input



L'attività elettrica cerebrale è prodotta dai neuroni stessi che attivandosi insieme ad altri (popolazione) producono un campo elettrico abbastanza intenso che si propaga attraverso il cervello e il cranio fino a poter essere captato da sensori (elettrodi) applicati sullo scalpo.

Gli elettrodi sono dei dischi di metallo altamente conduttivo che sono posti in contatto dello scalpo tramite una sostanza conduttrice. La posizione di ogni elettrodo è stabilita da convenzioni internazionali che ne uniformano la denominazione.

Nella figura 3 possiamo vedere il set-up caratteristico per registrazioni EEG.




Figura 3 Set-up per registrazioni EEG

L'attività elettrica cerebrale quindi può essere prelevata in modo non invasivo mediante un sistema di elettrodi posti direttamente a contatto con lo scalpo dell'individuo. Differenti stati cerebrali possono essere indotti direttamente dal soggetto che intende svolgere una determinata azione o in seguito alla presentazione di stimoli esterni, visivi o auditivi.

Bisogna considerare che ciascun individuo deve sottoporsi ad una fase di apprendimento per imparare a utilizzare il sistema di comunicazione e che le caratteristiche di tale comunicazione cambiano da soggetto a soggetto. Ad ogni modo possiamo indicare una procedura generale di interpretazione: una volta acquisiti i segnali elettroencefalografici, devono essere individuate ed estratte le caratteristiche principali e tradotte in tempo reale in un comando che realizzi l'effetto desiderato (il movimento del cursore sul monitor di un computer, la produzione di un determinato suono, l'accensione di un dispositivo, ecc.).

2.3.2 L'elettroencefalogramma

L'elettroencefalogramma (EEG) registra l'attività elettrica cerebrale tramite elettrodi di superficie posizionati sulla testa. La continua fluttuazione della normale attività cerebrale induce tra i vari punti del cuoio capelluto piccole differenze di potenziale elettrico (microvolt) che vengono amplificate e registrate normalmente per alcuni minuti (in casi particolari fino a 24 ore). Si ottiene in questo modo un tracciato che segna per ciascun elettrodo le variazioni del voltaggio nel tempo.

Normalmente gli elettrodi vengono montati secondo uno schema fisso (sistema 10-10 oppure 10-20, v. par. 2.3) su tutte le parti del cuoio capelluto. Poiché ogni elettrodo riflette in prima linea l'attività della parte cerebrale più vicina, l'EEG è in grado di fornire informazioni non solo su attività elettriche anomale, ma anche sulla loro localizzazione.

Essendo di esecuzione facile e non invasivo, l'EEG rappresenta un esame di base in neurologia. Ha il suo valore diagnostico maggiore nella diagnosi delle epilessie, in

quanto l'alterazione della normale attività elettrica nell'epilessia produce tracciati molto caratteristici che possono essere presenti anche in assenza delle crisi epilettiche. Anche nel caso di malattie infiammatorie come meningiti ed encefaliti oppure nelle encefalopatie metaboliche l'EEG è molto utile, perché un tracciato normale esclude questi processi. Altre volte l'EEG può indicare un processo focale come un tumore o un'ischemia cerebrale, nella maggior parte dei casi senza però essere in grado di determinare il tipo di lesione.

Nella figura 4 possiamo osservare un tracciato normale relativo ad un paziente sano, nella figura 5 un tracciato patologico registrato durante una crisi epilettica.




Figura 4 Tracciato normale: attività elettrica regolare e a basso voltaggio.




Figura 5 Tracciato patologico: attività elettrica anomala, ritmica e ad alto voltaggio durante una crisi epilettica.

2.3.3 I potenziali evento-correlati (ERPs)

I potenziali correlati ad eventi (ERPs) sono variazioni di voltaggio registrate dallo scalpo che sono correlate a processi sensoriali, motori o cognitivi e che quindi forniscono una visione delle funzioni cerebrali direttamente durante l'esecuzione di compiti. [11]

Gli ERPs possono essere usati per valutare se un cervello sta funzionando normalmente e come analizza l'informazione.

Nella figura 6 possiamo vedere il set-up caratteristico per registrazioni ERP.

La figura 7 mostra invece la tipica forma d'onda di un ERP.




Figura 6 Set-up per registrazioni ERP




Figura 7 Tipica forma d'onda di un ERP

I potenziali evento-correlati (ERPs) costituiscono delle variazioni nei segnali elettroencefalografici (EEG) che si presentano con un certo ritardo rispetto allo stimolo esterno presentato al soggetto, mentre l'attività cerebrale di fondo rappresenta nel nostro caso la componente di rumore.

L'obiettivo quindi consiste nell'individuare gli ERPs mediante la tecnica più opportuna.

Descriviamo di seguito la procedura per individuare la componente P300. L'utilizzatore viene posto di fronte ad uno schermo in cui è rappresentata una matrice di lettere 6x6 (figura 8). Al soggetto viene richiesto di scegliere una determinata lettera come *target*; quindi le righe e le colonne della matrice lampeggiano in sequenza e la persona deve contare quante volte la lettera che ha scelto lampeggia. Nel momento in cui il soggetto individua la lettera che lampeggia, nel cervello viene prodotto uno stimolo (P300) che può essere estratto mediante un sistema BCI. Questa procedura presenta però dei limiti legati all'attenzione e alle capacità del singolo individuo e inoltre l'ampiezza e il tempo di latenza della componente P300 varia in modo significativo da soggetto a soggetto.



Figura 8 Un paziente durante una registrazione BCI della componente P300. Il paziente osserva una matrice 6x6 e gli viene richiesto di contare quante volte la lettera N lampeggia.

BIBLIOGRAFIA CAP.2

- [1] A. Kübler, N. Neumann, *Brain-computer interfaces-the key for the conscious brain locked into a paralyzed body*, Progress in Brain Research, vol. 150, 2005.
- [2] J.R. Wolpaw, N. Birbaumer, D.J. McFarland, G. Pfurtscheller, *Brain-computer interfaces for communication and control*, Clin. Neurophysiol., vol.113, 2002.
- [3] G. Schalk, D.J. McFarland, T. Hinterberger, N. Birbaumer, J.R. Wolpaw, *BCI2000: A general-purpose brain-computer interface (BCI) system*, IEEE Trans. Biomed. Eng., vil 51, 2004.
- [4] A. Schlögl, C. Keinrath, R. Scherer, G. Pfurtscheller, *Information transfer of an EEG-based brain computer interface*, presented at the 1st Int. IEEE EMBS Conf. Neural Eng., Italy, 2003.
- [5] L. Bianchi, L.R. Quitadamo, G. Gareffa, G.C. Cardarilli, M.G. Marciani, *Performances Evaluation and Optimization of Brain Computer Interface Systems in a Copy Spelling Task*, IEEE Transactions on neural systems and rehabilitation engineering, vol.15, 2007.
- [6] D.J. McFarland, C.W. Anderson, G.R. Müller, A. Schlögl, *BCI meeting 2005-workshop on BCI signal processing: Feature extraction and translation*, IEEE Trans. Neural Syst. Rehabil. Eng., vol.14, 2007.
- [7] McFarland DJ, Mc Cane LM, Wolpaw JR, *EEG-based communication and control: Short-term role of feedback*, IEEE Trans. On Rehabilitation Engineering, 6: 7-11, 1998.
- [8] C. Neuper, G.R. Müller, A. Kübler, N. Birbaumer, G. Pfurtscheller, *Clinical application of an EEG-based brain computer interface: A case study in a patient with severe motor impairment*, Clin. Neuro-physiol., vol. 114, 2003.
- [9] B. Obermaier, G.R. Müller, G. Pfurtscheller, *Virtual keyboard controlled by spontaneous EEG activity*, IEEE Trans. Neural Syst. Rehabil. Eng., vol. 11, 2003.
- [10] G.E. Fabiani, D.J. McFarland, J.R. Wolpaw, G. Pfurtscheller, *Conversation of EEG activity into cursor movement by a brain-computer interface (BCI)*, IEEE Trans. Neural Syst. Rehabil. Eng., vol. 12, 2004.
- [11] Michael Rugg, Michael Coles, *Electrophysiology of Mind, Event-related Brain Potentials and Cognition*, Oxford Psychology series N.25

CAP.3 Il metodo ICA (Analisi delle Componenti Indipendenti) e l'algoritmo FastICA [1]

La *Blind Source Separation* (BSS) costituisce il problema di ottenere la separazione di sorgenti dall'osservazione dei soli segnali miscelati, non avendo alcun accesso, né alcuna informazione, sulle sorgenti originali o sulla miscelazione.

In questo capitolo viene formulato il problema della separazione di sorgenti nei termini di Analisi delle Componenti Indipendenti o *Independent Component Analysis* (ICA). L'ICA di una vettore, consiste in una trasformazione lineare in grado di preservare l'informazione che, come risultato, produce l'indipendenza statistica delle componenti in uscita. Il concetto di ICA può essere visto come una estensione dell'Analisi delle Componenti Principali o PCA.

Il metodo ICA fu introdotto negli anni 80 da Herault e Jutten [2], [3] in un contesto neurofisiologico nel tentativo di ottenere un modello biologico per la codifica del moto attraverso la rilevazione della contrazione muscolare.

Il sistema nervoso umano è, in qualche modo, in grado di rilevare la velocità e la posizione attraverso le informazioni derivate dalla contrazione muscolare; le terminazioni primarie e secondarie, infatti, restituiscono al sistema nervoso centrale una coppia di segnalazioni che contengono l'informazione "miscelata" di posizione reciproca e la velocità reciproca.

Herault e Jutten immaginarono che il modello che legava la frequenza delle stimolazioni sulle terminazioni primarie e secondarie alla velocità e posizione reciproca era un modello di miscelazione lineare. In quest'ottica il sistema nervoso opererebbe una sorta di inversione del modello; fu così messa appunto una struttura neurale per ottenere l'inversione (meglio nota come modello "neurometrico").

Fino alla metà degli anni '90 l'interesse internazionale per il nuovo campo della ricerca era estremamente ridotto in quanto altre tecniche neurali erano tenute in maggior considerazione.

Gli stessi autori del pionieristico lavoro raccontano come la diffidenza internazionale si manifestava principalmente nei commenti scettici di chi non riusciva a capacitarsi di come il modello neurometrico fosse in grado di separare le sorgenti; fu proprio questa iniziale diffidenza ad alimentare l'interesse di tutti coloro che dalla seconda metà degli anni 90 hanno iniziato a dedicarsi alla separazione *blind* di sorgenti con il metodo ICA.

I lavori che segnarono l'inizio di un coinvolgimento più largo sulle tematiche ICA furono quelli di Sejnowsky [4] and Amari. [5]

Accanto ai lavori di Herault e Jutten un altro approccio alla separazione delle sorgenti fu proposto da Comon che nel 1994 presentò [6] un metodo basato su un'estensione della PCA.

Da quel momento in poi un gran numero di lavori sono stati proposti all'interesse internazionale.

3.1 Il problema della *Blind Source Separation* (BSS)[7]

In generale, siano dati m segnali aleatori $s_1(t), s_2(t), \dots, s_m(t)$ indipendenti, osservabili mediante loro combinazioni lineari.

Assumiamo cioè che siano disponibili n sensori ($n \geq m$) che acquisiscono i segnali $x_1(t), x_2(t), \dots, x_n(t)$, con:

$$x(t) = As(t),$$

$$\begin{cases} x(t) = [x_1(t) & x_2(t) & \dots & x_n(t)]^T \\ s(t) = [s_1(t) & s_2(t) & \dots & s_m(t)]^T \end{cases}$$

ed A matrice $n \times m$, detta *mixing matrix*.

Il problema della *blind source separation* (BSS) consiste nella stima dei segnali $s_1(t), s_2(t), \dots, s_m(t)$ (le “sorgenti”) dati solo i segnali $x_1(t), x_2(t), \dots, x_n(t)$, (le “misure”) e l’ipotesi di indipendenza fra $s_1(t), s_2(t), \dots, s_m(t)$.

Se A fosse quadrata e nota (e non singolare), come in generale non accade, il problema sarebbe risolto semplicemente per via algebrica:

$$s(t) = Tx(t), \quad T = A^{-1}$$

Definiamo innanzitutto l’incorrelazione e l’indipendenza statistica.

3.2 Incorrelazione

Per semplicità riduciamo inizialmente il problema a due dimensioni.

Due variabili aleatorie x e y sono incorrelate se la loro varianza è nulla, cioè se si può scrivere:

$$c_{xy} = E\{(x - m_x)(y - m_y)\} = 0$$

dove con m_x e m_y abbiamo indicato i valori medi rispettivamente di x e di y .

Se invece consideriamo un vettore $\bar{x}$ di variabili aleatorie, dobbiamo considerare la matrice di covarianza, così definita:

$$C_x = \begin{pmatrix} c_{x_1 x_1} & \dots & c_{x_1 x_n} \\ & & \\ c_{x_n x_1} & & c_{x_n x_n} \end{pmatrix}$$

La matrice C_x così definita è simmetrica e l'i-esimo elemento sulla diagonale rappresenta la varianza della i-esima variabile aleatoria.

Se inoltre prendiamo in considerazione un vettore $\bar{x}$ di variabili aleatorie tra loro incorrelate, la matrice di covarianza C_x diventa diagonale e sulla diagonale troviamo i valori della varianza delle singole variabili.

3.3 Indipendenza

Consideriamo due variabili aleatorie x e y . Le due variabili si dicono indipendenti se la distribuzione congiunta di x e y , $f_{x,y}$, è pari al prodotto tra le distribuzioni delle singole variabili, f_x e f_y ; deve risultare cioè:

$$f_{x,y}(x, y) = f_x(x) \cdot f_y(y)$$

Si può dimostrare che per due variabili indipendenti vale anche la seguente proprietà:

$$E\{g(x)h(y)\} = E\{g(x)\}E\{h(y)\}$$

dove $g(x)$ e $h(y)$ sono due funzioni integrabili di x e y .

È possibile dimostrare, con semplici passaggi algebrici, che l'indipendenza statistica è una condizione più forte dell'incorrelazione. Considerando $g(x)$ e $h(y)$ come due funzioni lineari di x e y , infatti, possiamo facilmente dedurre, utilizzando l'ultima equazione scritta, che

$$c_{xy} = 0.$$

Solo nel caso in cui le variabili x e y abbiano una distribuzione gaussiana possiamo affermare invece che l'incorrelazione implica l'indipendenza statistica.

3.4 L'Analisi delle Componenti Principali (PCA)

L'Analisi delle Componenti Principali (PCA) permette di individuare e valutare le strutture insite in un set di dati (anche molto complesso), raccogliendo quanta più informazione possibile riguardo al problema in esame. Si effettua quindi un'analisi su dati già presenti.

È una tecnica utilizzata nell'ambito della statistica multivariata per la semplificazione dei dati d'origine.

L'analisi multivariata permette lo studio di database contenenti numerosi dati relativi a ciascun elemento; ad esempio, nel caso di database medici si hanno a disposizione molti dati per ogni paziente. L'approccio di base consiste nel ridurre il numero delle variabili significative attraverso la tecnica dell'Analisi Componenti Principali (PCA). In questo modo si identificheranno le "direzioni" di massima variabilità (autovettori) e le percentuali di varianza ad esse collegate (autovalori). Se necessario si possono effettuare delle rotazioni in modo da ridurre al minimo il numero delle componenti non nulle degli autovettori. Pur ottenendo in questo modo direzioni non indipendenti l'interpretazione dei risultati risulta spesso più semplice.

Lo scopo primario di questa tecnica è la riduzione di un numero più o meno elevato di variabili (rappresentanti altrettante caratteristiche del fenomeno analizzato) in alcune variabili latenti. Ciò avviene tramite una trasformazione lineare delle variabili che proietta quelle originarie in un nuovo sistema cartesiano nel quale le variabili vengono ordinate in ordine decrescente di varianza: pertanto, la variabile con maggiore varianza viene proiettata sul primo asse, la seconda sul secondo asse e così via. La riduzione della complessità avviene limitandosi ad analizzare le principali (per varianza) tra le nuove variabili.

Diversamente da altre trasformazioni (lineari) di variabili praticate nell'ambito della statistica, in questa tecnica sono gli stessi dati che determinano i vettori di trasformazione.

La PCA è una tecnica statistica adoperata in molti ambiti: nell'astronomia, nella medicina, in campo agro-alimentare, ecc... fino anche alla compressione di immagini; questo perché quando ci si trova a semplificare un problema, riducendo la dimensione dello spazio di rappresentazione, si ha allo stesso tempo una perdita dell'informazione contenuta nei dati originali. La PCA consente di controllare egregiamente il compromesso tra la perdita di informazioni e la semplificazione del problema (basta scegliere il numero appropriato di autovettori).

Schematizziamo quindi il problema

Lo scopo della PCA è quello di trovare un gruppo di variabili che presenti minore ridondanza possibile nell'ambito dell'analisi multivariata, effettuando una trasformazione lineare delle variabili iniziali in altre, organizzate in ordine decrescente di importanza ed incorrelate tra loro.

Il processo della PCA consiste in tre steps:

1. creazione della matrice di covarianza
2. estrazioni dei fattori, e cioè delle componenti principali
3. rotazione su una struttura ortogonale

Sia x un vettore aleatorio di ordine n , di cui sono noti k campionamenti $x(1), x(2), \dots, x(k)$, sia m_x il vettore dei valori medi di x e C_x la matrice di covarianza coincidente con la matrice di correlazione se $m_x=0$. Partendo dalla conoscenza di queste statistiche, la PCA consente di trovare nuove variabili y , ricavando un sistema di coordinate ortogonali tale che gli elementi di y , proiezioni di quelli di x in tale sistema ortogonale, risultino incorrelati. Allo stesso tempo si massimizza la varianza delle proiezioni sui nuovi assi, così che il primo asse corrisponda alla direzione di massima varianza, il secondo alla massima varianza nella direzione ortogonale al primo etc.

La soluzione al problema della PCA è data dagli autovettori a lunghezza unitaria della matrice di covarianza C_x , tale per cui:

$$C_x = EDE^T$$

dove D è la matrice diagonale degli autovalori di C_x e le colonne di E sono i rispettivi autovettori. Se alcuni di questi autovalori sono nulli la matrice C_x non è di rango pieno e quindi le rispettive variabili ancora una relazione di dimensione originarie sono linearmente dipendenti. Questo permette di ridurre la dimensionalità del problema a $n - k$ dove k è il numero di autovalori nulli. Tuttavia questo è un caso che si presenta raramente; più spesso capita invece di decidere quali autovalori siano da considerarsi “piccoli” e approssimare C_x in modo da avere dimensione $n - k$.

La PCA ci fornisce quindi uno strumento per capire quali delle variabili in gioco possano essere eliminate dalle analisi successive per il loro scarso contributo alla varianza totale, ovvero all’informazione totale che i dati contengono. La scelta dipende da vari fattori, quali il tipo di dati in esame e l’accuratezza necessaria per le analisi successive.

La PCA non riesce da sola a risolvere in maniera soddisfacente il problema della separazione di sorgenti mischiate perché si basa sull’incorrelazione e non sull’indipendenza; tuttavia essa ricopre un ruolo essenziale nella riduzione del numero di parametri da stimare, soprattutto nel caso in cui abbiamo a che fare con matrici di dati di grosse dimensioni.

3.5 L’Analisi delle Componenti Indipendenti (ICA)

3.5.1 Definizione di ICA

Sia A una matrice rettangolare di elementi reali o complessi, detta matrice di mixing, consideriamo la seguente relazione:

$$x(t) = A s(t);$$

dove i vettori $s(t)$ e $x(t)$ sono variabili aleatorie.

Il problema dell'ICA può essere posto nei termini di separazione di sorgenti: note k realizzazioni del vettore $x(t)$ (segnali osservati o ricevuti), si desidera stimare la matrice A insieme alle corrispondenti realizzazioni $s(t)$.

Le ipotesi fondamentali per effettuare l'ICA sono molto semplici; il vettore $s(t)$:

1. ha tutte le sue componenti statisticamente indipendenti tra loro;
2. le sue componenti hanno distribuzione non Gaussiana.


In generale la natura delle distribuzioni può essere sconosciuta (nel caso fosse nota il problema sarebbe estremamente semplificato).

Nel caso più semplice di matrici quadrate (numero di sorgenti uguale al numero di osservazioni) il problema consiste nella stima della matrice inversa $W=A^{-1}$, dove si ha quindi:

$$s(t)=W x(t).$$

3.5.2 Il problema del *Cocktail Party*

L'esempio classico che illustra il modello dell'analisi delle componenti indipendenti è il così detto *cocktail party problem*; con questa espressione si indica la situazione in cui si vogliono separare le singole voci dei partecipanti ad una festa, a partire dalle diverse registrazioni dei microfoni:



$x(t)$ e $y(t)$ sono vettori di segnali, quindi matrici. A partire da $x(t)$ ci aspettiamo di trovare una stima W della matrice inversa di A tramite cui ricavare i segnali sorgenti o una loro approssimazione $y(t)$:

$$y(t)=Wx(t)$$

Se si considera ogni campione del segnale $x_i(t)$ come la realizzazione di una variabile aleatoria x_i anziché un vero e proprio segnale temporale, possiamo eliminare la dipendenza da t e alleggerire le notazioni successive; stessa cosa vale ovviamente per $s(t)$. Il modello standard dell'ICA è anche detto istantaneo poiché,

come visto, si ipotizza nullo ogni ritardo temporale eventualmente presente nel mescolamento, che assume la forma di una semplice combinazione lineare.

Per poter applicare correttamente il modello base dell'ICA appena visto, è necessario assumere che le componenti che vogliamo stimare siano statisticamente indipendenti e presentino una distribuzione non gaussiana; questa seconda ipotesi è giustificata dal fatto che le statistiche di ordine superiore, di cui fa uso la ICA, sono nulle per variabili gaussiane. Per semplicità consideriamo poi la matrice di mixing quadrata, cioè il numero delle componenti indipendenti uguale a quello dei segnali osservati.

Il metodo dell'analisi delle componenti principali (PCA) consente di trovare le direzioni dei dati a massima varianza, mentre il metodo dell'analisi delle componenti indipendenti (ICA) consente di determinare le componenti temporalmente indipendenti, che possono essere non-ortogonali.

L'indipendenza tra due variabili richiede l'assenza di correlazione sia del secondo ordine sia di ordine superiore. L'indipendenza è quindi una condizione più forte della incorrelazione e, soprattutto, non è soddisfatta dalla decomposizione realizzata mediante l'analisi delle componenti principali (PCA). Sebbene i meccanismi neurali che sono alla base della generazione degli ERPs non siano ancora ben conosciuti, le assunzioni che vengono fatte per poter applicare l'algoritmo dell'analisi delle componenti indipendenti (ICA) agli ERPs sono compatibili con il modello assunto per la generazione di questi segnali.

L'uso della ICA per l'analisi di potenziali ERPs, si basa su tre assunzioni:

1. è lineare la somma a livello degli elettrodi dello scalpo dei potenziali provenienti da diverse aree cerebrali
2. i segnali ERPs sono determinati prevalentemente dalla somma di attivazioni cerebrali provenienti da ristrette aree cerebrali
3. i *time course* di attivazione devono essere prevalentemente indipendenti

Quest'ultima condizione limita la decomposizione alle componenti temporalmente indipendenti.

Ci sono alcune ambiguità nel modello standard di stima delle componenti indipendenti, che non possono essere eliminate.

La prima è l'impossibilità di determinare le varianze, e quindi le energie, delle singole componenti indipendenti. Essendo sia s che A sconosciute, ogni moltiplicazione di una delle sorgenti s_i può essere eliminata dividendo la corrispondente colonna a_i di A per lo scalare α_i :

Quindi conviene fissare l'ampiezza delle componenti indipendenti assumendo che abbiano tutte varianza unitaria: $E\{s_i^2\}=1$. I metodi usati per risolvere il modello dovranno tener conto di ciò riadattando la stima della matrice A . Resta comunque irrisolta l'ambiguità sul segno poiché una componente indipendente può essere moltiplicata per (-1) senza che il modello venga in alcun modo modificato.

Il secondo problema riguarda l'impossibilità di determinare l'ordine delle componenti indipendenti. Questo perché una matrice di permutazione P e la sua inversa possono essere inserite nel modello nel seguente modo: $x = AP^{-1}Ps$. Gli

elementi di P_s sono le variabili originali s_j , ma in un ordine diverso. La matrice AP^{-1} è la nuova matrice di mixing che deve essere ricavata.

3.5.3 Un passo preliminare: lo sbiancamento dei dati

Un vettore di n variabili aleatorie x è bianco se è a media nulla e le sue componenti sono incorrelate a varianza unitaria. In altre parole la matrice di covarianza di x è unitaria e possiamo scrivere quindi:

$$E\{xx^T\} = I$$

Il nostro obiettivo preliminare consiste nello sbiancare i dati a disposizione, nel trasformarli cioè in un nuovo vettore aleatorio z che presenti le caratteristiche esposte.

La trasformazione che cerchiamo è di tipo lineare e si ottiene moltiplicando il nostro vettore aleatorio per un'opportuna matrice V tale che risulti: $z = Vx$.

La ricerca della trasformazione lineare opportuna è strettamente collegata all'analisi delle componenti principali.

Indichiamo con C_x la matrice di covarianza di x ; con $E = (e_1, e_2, \dots, e_n)$ la matrice che ha per colonne gli autovettori a norma unitaria di C_x ; con D la matrice diagonale degli autovalori di C_x .

Si può dimostrare che la matrice V di sbiancamento è data da:

$$V = D^{-\frac{1}{2}} E^T$$

dove E è una matrice ortogonale (soddisfa cioè la proprietà: $EE^T = E^T E = I$) e vale la relazione:

$$C_x = EDE^T$$

Si può verificare, infatti, che la matrice C_z di covarianza di z , è pari alla matrice I di identità e che quindi il nuovo vettore z è bianco:

$$\begin{aligned} C_z = E\{zz^T\} &= V E\{xx^T\} V^T = V C_x V^T = V E D E^T V^T = \\ &= D^{-\frac{1}{2}} E^T E D E^T E D^{-\frac{1}{2}} = D^{-\frac{1}{2}} D D^{-\frac{1}{2}} = I \end{aligned}$$

L'operazione di sbiancamento viene di fatto applicata ai dati che abbiamo a disposizione e fornisce una nuova matrice di mixing A^* da ricercare. Si ha infatti:

$$z = Vx = VAs = A^*s$$

Questa operazione ovviamente non è sufficiente da sola a risolvere il problema della separazione delle sorgenti indipendenti perché, come abbiamo visto, l'incorrelazione è una proprietà meno forte dell'indipendenza, ma risulta comunque molto utile dal momento che la nuova matrice di mixing A^* da ricercare è ortogonale. Infatti dal momento che s è il vettore aleatorio delle sorgenti statisticamente indipendenti, esse risultano anche incorrelate e possiamo scrivere:

$$E\{ss^T\} = I$$

Inoltre, per i passaggi visti in precedenza, possiamo anche considerare:

$$E\{zz^T\} = I$$

E quindi, mettendo insieme tutte le informazioni, risulta:

$$E\{zz^T\} = A^* E\{ss^T\} A^{*T} = \{zz^T\} = A^* I A^{*T} = I$$

Tramite lo sbiancamento dei dati, quindi, abbiamo ridotto la dimensionalità del problema, poiché dobbiamo ricercare la matrice A^* ortogonale e sappiamo che una matrice ortogonale possiede $n(n-1)/2$ gradi di libertà anziché n^2 .

Il motivo per cui una matrice di mixing ortogonale non può essere stimata per variabili gaussiane è collegato al fatto che variabili aleatorie incorrelate a densità di probabilità gaussiana sono necessariamente indipendenti. Quindi, in questo caso, l'informazione sull'indipendenza non porta oltre lo sbiancamento dei dati.

3.5.4 La massimizzazione della non-gaussianità per la stima delle componenti indipendenti. [8]

Come è stato già sottolineato, non è possibile applicare il metodo ICA a variabili che presentino una densità di probabilità gaussiana. Proprio per questo risulta efficace utilizzare tecniche che vadano a ricercare di variabili il meno possibile gaussiane, cioè massimizzare la non-gaussianità.

Ricordiamo innanzitutto che il teorema del limite centrale afferma che la distribuzione di una combinazione lineare di variabili aleatorie indipendenti tende ad una distribuzione gaussiana.

Se consideriamo quindi i dati come una combinazione lineare delle componenti indipendenti,

$$x_i = \sum_{j=1}^n a_{ij} s_j$$

tale combinazione lineare avrà una distribuzione molto più vicina ad una gaussiana rispetto ai segnali di partenza.

Chiamiamo y_j una stima della corrispondente componente indipendente s_j .

Consideriamo y_j come una combinazione lineare delle osservazioni x_i con coefficienti b_i . Possiamo scrivere:

$$y_j = \sum_{i=1}^n b_i x_i = b^T x = b^T A s = r^T s = \sum_{i=1}^n r_i s_i$$

dove abbiamo posto $b^T A = r^T$

Se in particolare il vettore b^T uguaglia una delle righe della matrice inversa di A, allora la combinazione lineare $b^T x$ fornirà una stima della componente indipendente s_j e il vettore r avrà un solo elemento non nullo e uguale a 1.

Dobbiamo considerare che il vettore $y_j = \sum_{i=1}^n r_i s_i$ ha una distribuzione più prossima ad una gaussiana rispetto a ciascuna delle componenti s_i e che tale distribuzione si allontana invece da quella gaussiana quanto più y_j si avvicina ad essere una buona stima della componente s_j .

Quindi, per fare in modo che y_j approssimi bene la componente indipendente s_j cercata, possiamo far variare b e osservare come cambia la distribuzione di y_j , muovendoci nella direzione che ne massimizza la non-gaussianità.

È chiaro che per far questo è necessario stabilire dei buoni stimatori della non-gaussianità. Di seguito parleremo dei due stimatori maggiormente utilizzati: la curtosi e la negentropia.

3.5.5 La curtosi come stimatore per la massimizzazione della non-gaussianità.

La curtosi (o cumulante del quarto ordine) di una variabile aleatoria x è definita nel seguente modo:

$$kurt(x) = E\{x^4\} - 3(E\{x^2\})^2 - 4E\{x^3\}E\{x\} + 12E\{x^3\}(E\{x\})^2 - 6(E\{x\})^4$$

Se in particolare x è a media nulla, risulta più semplicemente:

$$kurt(x) = E\{x^4\} - 3(E\{x^2\})^2$$

Nel caso inoltre x presentasse una funzione di distribuzione di probabilità gaussiana si avrebbe:

$$E\{x^4\} = 3(E\{x^2\})^2 \quad \Rightarrow \quad kurt(x) = 0$$

Il valore della curtosi in generale può essere sia positivo che negativo. Le variabili aleatorie con curtosi negativa e le loro distribuzioni si dicono "subgaussiane", mentre quelle a curtosi positiva e le loro distribuzioni si dicono "supergaussiane". Tipicamente le variabili supergaussiane mostrano una pdf "appuntita" con code "appesantite" (figura 1): ciò significa che tali distribuzioni presentano valori frequenti nella media e lontano dalla media, laddove i valori intermedi sono relativamente meno frequenti. Un tipico esempio di distribuzione supergaussiana è la distribuzione di Laplace. Viceversa le variabili subgaussiane presentano una distribuzione tipicamente "appiattita" intorno alla media, praticamente costante vicino ad essa e relativamente trascurabile a valori lontani.




Figura 6 Esempi di distribuzione per una v.a. continua, a media nulla e varianza unitaria : (a) pdf supergaussiana, (b) pdf gaussiana, (c) pdf subgaussiana.

Massimizzare la non gaussianità significa quindi massimizzare il valore della kurtosis.

La curtosi risulta semplice da calcolare, ma ha il difetto di essere sensibile agli *outliers*, cioè a valori delle osservazioni, probabilmente dovuti a rumore, che si discostano molto dal valore degli altri dati. In pratica i valori che si posizionano sulle code della distribuzione possono influenzare pesantemente il valore della curtosi.

3.5.6 La negentropia stimatore per la massimizzazione della non-gaussianità.

Il concetto di Entropia nasce con la teoria dell'Informazione come misura della lunghezza della codifica necessaria per descrivere un certo dato: più una variabile è causale più la sua entropia è elevata poiché necessita di una codifica più lunga.

Un risultato fondamentale è che variabili gaussiane hanno l'entropia maggiore tra le variabili di uguale varianza. Quindi tale grandezza può essere sfruttata per avere una misura della non-gaussianità.

L'entropia differenziale di una variabile y con funzione di distribuzione $f(y)$ è definita come segue:

$$H(y) = -\int f(y) \log(y) dy$$

In genere però si introduce una versione normalizzata dell'entropia differenziale, per ottenere una misura della non-gaussianità che sia positiva e che risulti nulla nel caso di variabili gaussiane. Tale grandezza prende il nome di negentropia ed è così definita:

$$J(y) = H(y_{\text{gauss}}) - H(y)$$

dove y_{gauss} è un vettore aleatorio gaussiano che ha la stessa matrice di covarianza di y .

Quindi un metodo che consente di stimare la non-gaussianità, in maniera più robusta rispetto alla curtosi, è la misura della negentropia.

La negentropia, infatti, risulta essere un ottimo stimatore della non-gaussianità, tuttavia la sua valutazione secondo definizione è difficoltosa da un punto di vista computazionale, in quanto richiede la stima della densità di probabilità della variabile. Nella pratica quindi si utilizzano delle approssimazioni della negentropia, che permettono calcoli più semplici.

L'approssimazione più comune è la seguente:

$$J(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} kurt(y^4)$$

dove y è una variabile aleatoria a valor medio nullo e varianza unitaria.

Bisogna considerare però che il primo termine della relazione precedente, vale zero nel caso di variabili con distribuzione simmetrica, cosa che approssimativamente accade piuttosto comunemente. Quindi tale

approssimazione riconduce all'uso della curtosi vista in precedenza e per questo si preferisce usare altre funzioni che indichiamo genericamente con $G_i(y)$

Scegliendo opportunamente la funzione G si possono ottenere ottime approssimazioni della negentropia. Tra le più usate troviamo:

$$G(y) = \frac{1}{a} \log(\cosh ay)$$

$$G(y) = -\exp\left(\frac{-y^2}{2}\right)$$

$$G(y) = \frac{y^4}{4}$$

3.5.7 La ricerca delle componenti indipendenti mediante l'algoritmo FastICA

Gli algoritmi tipici dell'ICA utilizzano il centering, la determinazione del rumore bianco (*whitening*) e la riduzione delle dimensioni (*dimensionality reduction*) come stadi di preelaborazione per semplificare e ridurre la complessità del problema riguardante l'algoritmo iterativo in esame.

I processi di *whitening* e riduzione in dimensioni possono essere ottenuti ad esempio con l'analisi delle componenti principali. Il processo del *whitening* assicura inoltre che tutte le dimensioni siano trattate ugualmente a priori prima che venga lanciato l'algoritmo. Gli algoritmi impiegati nell'ICA includono infomax, FastICA e JADE, ma vi sono anche molti altri.

Ricordiamo che in generale il metodo ICA non è in grado di estrarre l'esatto numero delle sorgenti del segnale, l'ordine in cui vengono ricavati i segnali e il segno (positivo o negativo) o il valore scalare delle sorgenti. Il metodo è importante per la separazione dei segnali alla cieca (*blind signal separation*) e può fornire molte applicazioni pratiche.

Vi sono molti algoritmi presentati dalla letteratura statistica che possono eseguire l'ICA.[9] Uno molto utilizzato, che viene incluso nelle applicazioni industriali, è l'algoritmo FastICA, che è stato sviluppato da Aapo Hyvärinen e da Erkki Oja.

Il FastICA è uno degli algoritmi più utilizzati e di semplice implementazione per la ricerca delle componenti indipendenti, ed opera su dati sbiancati. Alla base del FastICA vi è un algoritmo iterativo che cerca le proiezioni di $y_i = w_i^T x$ che massimizzano la non-gaussianità delle componenti, dove x è la matrice dei segnali osservati organizzati per riga e w_i^T è una riga della matrice di *unmixing* W .

Prima di applicare l'algoritmo FastICA quindi dobbiamo sottrarre il valore medio da ciascuno dei nostri segnali ed effettuare lo sbiancamento della matrice dei dati per mezzo della PCA. Questa operazione semplifica la stima della matrice

di *unmixing* in quanto la rende ortogonale con soltanto $n(n-1)/2$ gradi di libertà anziché n^2 . Inoltre in questa fase in cui i dati vengono proiettati nello spazio delle componenti principali possiamo anche decidere di diminuire la dimensionalità di tale spazio, eliminando le componenti che danno un basso contributo alla varianza totale dei dati iniziali.

Indichiamo di seguito le caratteristiche fondamentali dell'algoritmo:

- la convergenza è cubica, rendendo quindi l'algoritmo più veloce rispetto ai classici metodi basati sulla discesa del gradiente, che sono caratterizzati da convergenza lineare.
- l'algoritmo gode di una grande facilità d'uso, anche perché non vi sono troppi parametri da settare.
- FastICA riesce a trovare le componenti indipendenti mediante qualsiasi funzione non lineare g , a differenza di altre tecniche che necessitano di informazioni a priori sulle distribuzioni.
- le componenti indipendenti possono essere stimate una per una, facendo di questo strumento uno strumento importante per l'analisi esplorativa dei dati e riducendo l'onere computazionale.
- l'algoritmo è computazionalmente flessibile e poco esigente in termini di memoria utilizzata.

In pratica, per massimizzare il valore della negentropia, partiamo da qualche valore iniziale del vettore w , calcoliamo la direzione in cui $J(y)$ cresce più rapidamente, sulla base dei campioni $x(1) \dots x(T)$, e successivamente muoviamo il vettore in quella direzione. Questa idea è contenuta nel metodo di discesa del gradiente, il quale calcola la derivata di $J(y) = J(w^T x)$ rispetto a w e muove w stesso nella direzione del gradiente positivo. La procedura da ripetere iterativamente è quindi la seguente:

$$w_i(t) + \alpha \frac{\partial J(y)}{\partial w_i} \rightarrow w_i(t+1)$$

$$\text{con } \frac{w_i}{\|w_i\|} \rightarrow w_i$$

dove α è un parametro di apprendimento e la normalizzazione serve per mantenere la varianza costante e proiettare w sulla sfera di raggio unitario assicurando di lavorare sui dati sbiancati.

La convergenza di un metodo basato sulla discesa del gradiente risulta tuttavia molto lenta e dipende molto dal rate di apprendimento scelto.

Le operazioni da compiere per l'implementazione dell'algoritmo FastICA nel caso di un approccio simmetrico, cioè nel caso si vogliano studiare tutte le componenti contemporaneamente in modo da ridurre la propagazione di eventuali errori tra le componenti, sono le seguenti:

1. Centrare la matrice dei dati x in modo da renderla a media nulla
2. Sbiancare i dati
3. Scegliere il numero di componenti indipendenti da stimare (tale numero m può essere scelto durante lo sbiancamento).

4. Scegliere i valori iniziali, i.e. casualmente, di norma unitaria per w_i $i=1,\dots,m$

5. Per ogni $i=1,\dots,m$ fare il seguente assegnamento:

$$E\{xg(w_i^T x)\} - E\{g'(w_i^T x)\}w_i \rightarrow w_i$$

dove g' è la derivata di g che a sua volta è la derivata della funzione G , e cioè della funzione descritta precedentemente; g' può assumere quindi le seguenti espressioni:

$$G(y) = a(1 - \tanh(ay))$$

$$G(y) = (1 - y^2) \exp\left(\frac{-y^2}{2}\right)$$

$$G(y) = 3y^2$$

6. Eseguire la ortonormalizzazione di Gram-Schmidt della matrice W .

7. In assenza di convergenza tornare al passo 5

Uno dei particolari punti di forza dell'algoritmo FastICA è che non fa particolari ipotesi sulla distribuzione delle sorgenti.

BIBLIOGRAFIA CAP.3

- [1] A. Hyvärinen, E. Oja, *Independent Component Analysis: Algorithms and Applications*, Neural Networks Research Centre Helsinki University of Technology, Finlandia, 2000.
- [2] B.Ans, J.Herauld, C.Jutten, *Adaptive Neural architectures: detection of primitives*. In proc. of COGNITIVA'85, pages 593-597, Paris, France.
- [3] C. Jutten, J. Herald, *Blind separation of sources, part I: an adaptive algorithm based on neurometric architecture*, Signal Processing. Vol 24 pag 1-10, July 1991.
- [4] A. Bell, T. Sejnowski, *An Information-maximisation approach to blind separation and blind deconvolution*, Neural Computation, 7(5):1129-1159, 1995.
- [5] S. Amari, *Natural Gradient Works Efficiently in Learning*. In Neural Computation, vol. 10, pag 251-276, 1998.
- [6] P. Comon, *Independent Component Analysis, A new Concept?*, Signal Processing 36 287-314, 1994.
- [7] S. Amari, A. Cichocki, *A new learning algorithm for blind source separation*, in *Advances in Neural Processing* 8. Cambridge: MIT Press, 1996.
- [8] A.J. Bell and T.J. Sejnowski, *An information-maximization approach to blind deconvolution*, *Neural Comput.*, vol.7, 1995.
- [9] X.Giannakopoulos, J.Karhunen, *Experimental comparison of neural ICA alghoritms*, in Proc. Int. Conf. Artificial Neural Networks, (ICANN')

CAP. 4 Elaborazione e analisi dei dati sperimentali

Questo lavoro di tesi è stato guidato dalla necessità di raggiungere due obiettivi principali:

3. Verificare la possibilità di un'analisi in tempo reale.
4. Risolvere il problema dell'indeterminazioni delle sorgenti elaborate mediante il metodo ICA, permettendo l'eliminazione automatica delle sorgenti di rumore individuate.

Pertanto si è posto il problema di rispondere principalmente a due interrogativi:

3. Quanto sono stabili nel tempo i parametri stimati mediante l'algoritmo?
4. Qual è la potenza di elaborazione necessaria per un'eventuale implementazione hardware?

A tale scopo sono stati analizzati i dati elettroencefalografici registrati direttamente sullo scalpo mediante un sistema di 59 elettrodi. Per analizzare i dati è stato creato un software in C++ utilizzando la libreria open-source "IT++" [1] per l'algoritmo FastICA.

L'analisi è stata eseguita su un set di dati elettroencefalografici reali (in formato ALTEA compatibile) registrati in base al protocollo P300, variando la durata degli intervalli di tempo elaborati e la matrice di input iniziale. In seguito i dati elaborati sono stati analizzati per ottenere le risposte ai quesiti prefissati.

I dati sperimentali analizzati sono stati registrati con un sistema EBNeuro Mizar, secondo lo schema internazionale 10-10 (vedi cap. 3) e con una frequenza di campionamento di 256 Hz [2]. I dati registrati sono, per ogni campione, una sequenza di 59 float (4 bytes) in formato binario.

Il software è stato fatto girare su una macchina con processore Intel Centrino® Duo con memoria RAM di 1.5 GB.

4.1 Descrizione del software realizzato per l'elaborazione dei dati elettroencefalografici.

Il software creato per l'elaborazione dei dati sperimentali è versatile e adattabile a seconda dell'analisi da eseguire e utilizza la libreria IT++.

IT++ è una libreria di funzioni e classi per la matematica, l'analisi dei segnali, l'analisi vocale e le comunicazioni, interamente scritta in C++. Il kernel del package è composto da classi e template per gestire vettori e da matrici e funzioni che operano su di essi ed è simile alle funzioni presenti nel pacchetto scientifico Matlab.[3]

Questa libreria nasce in seno al dipartimento di Teoria dell'Informazione alla Chalmers University of Technology di Gothenburg, in Svezia. È stata usata intensamente all'interno di vari gruppi di ricerca prima di essere rilasciata come prodotto open-source sotto licenza GNU GPL.

IT++ opera su svariate combinazioni di compilatori/sistemi operativi; attualmente è stata testata accuratamente su GNU/Linux, Sun Solaris, Mac OS X, Windows con Cygwin, Windows con Microsoft Visual C++ e .NET. Nel nostro caso è stato utilizzato il compilatore Microsoft Visual C++.

Il software realizzato per l'analisi dati utilizza un'interfaccia a linea di comando (CLI) (dal corrispondente termine inglese command line interface). Questa è la modalità di interazione tra utente ed elaboratore che avviene inviando comandi tramite tastiera e ricevendo risposte alle elaborazioni tramite testo scritto. Tipicamente un'interfaccia di tipo CLI si ottiene per mezzo di un emulatore di terminale (shell) e nel nostro caso è ottenuta tramite il programma "Prompt dei comandi" che richiama l'interfaccia del Sistema Operativo MS-DOS.

Il software fornisce in uscita la stima della matrice dei pesi, il vettore delle componenti indipendenti e il tempo necessario per ogni elaborazione.

È possibile scegliere alcuni parametri (che vengono memorizzati nell'array *argv[]*), per esempio il numero di campioni, il formato dei dati, il nome del file da elaborare ecc.

Analizziamo di seguito i parametri principali del software.

***argv[0]*: Nome del file:** consente di scegliere il nome del file da elaborare.

***argv[1]*: “b” per il formato binario o “t” per il formato testo:** permette di importare correttamente il formato dei dati binario o testo.

```
if(argv[1]== 'b' )    {int binario=1;}
...
if(binario==1)        { file_in= std::fopen(argv[0], "rb");} //lettura binaria
else {file_in= std::fopen(argv[0], "r");} //lettura testo
```

***argv[2]*: Numero di componenti indipendenti:** permette di scegliere il numero di componenti indipendenti da individuare.

```
nrIC = argv[2];
```

***argv[3]* : Numero di secondi da elaborare;**

```
int unita_di_misura=256;
nrCampioni = unita_di_misura * atoi(argv[3]);
```

Tenendo conto che nostri dati sono stati campionati a 256 Hz .

***argv[4]*: Numero di secondi di offset:** consente di selezionare l'intervallo di dati da analizzare saltando il numero di secondi scelti come offset.

```
.
Int secondi_offset = argv[4] * nrIC * unita_di_misura ;
for ( int ijk= 0; ijk < secondi_offset ; ijk ++ )
{
    if(binario==1)
        {byte_letti=fread( &data_float,sizeof(data_float),1,file_in);} //lettura
binaria
        else{fscanf( file_in , "%f", &data_float); } //lettura testo
}
}
```

argv[5]: Numero di campionamenti da saltare: consente di selezionare l'intervallo di dati da analizzare saltando il numero di campioni scelti come offset.

```

int campioni_da_saltare= argv[5];
int letture_vuote_campioni=campioni_da_saltare * nrIC;
for(int ijk=0;ijk<=letture_vuote_campioni;ijk++)
    {
        if(binario==1)
            {byte_letti=fread( &data_float,sizeof(data_float),1,file_in);} //lettura
binaria
            else{fscanf( file_in , "%f", &data_float);    } //lettura testo
    }

```

argv[6]: Eventuale matrice di mixing iniziale: è possibile fornire in ingresso il nome del file di una matrice dei pesi iniziale per l'algoritmo, in sostituzione della matrice di default

```

if (argv[6] != NULL)
{
    mat G = zeros( nrIC, nrIC ); //definisce la matrice di mixing iniziale
    file_mix_in = fopen((argv[6], "r"); //apre il file della matrice

    //carica i dati della matrice iniziale di mixing e li mette nella matrice G
    for ( int i= 0; i< nrIC; i++ )
    {
        for ( int j= 0; j< nrIC; j++ )
        {
            fscanf( file_mix_in , "%f", &data_mixing); //modalità testo
            G(j,i)= data_mixing;
        }
    }
}

```

Una volta recuperati tutti i parametri viene inizializzata una matrice vuota con il comando

```
mat X = zeros( nrIC, nrSamples ); //definisce la matrice di ingresso
```

e successivamente la matrice X (che ha *nrIC* colonne e *nrSamples* righe) viene riempita distinguendo il caso di formato dei dati binari o testo

```

for ( int i= 0; i< nrSamples; i++ )
    {
        for ( int j= 0; j< nrIC; j++ )
        {
            if(binario==1)
            {
                byte_letti=fread( &data_float,sizeof(data_float),1,file_in);
                X(j,i)= data_float;
            }
            else
            {
                fscanf( file_in , "%f", &data_float);
            }
        }
    }

```

```

        }
    }
}
X(j,i)= data_float;

```

Dopo aver inizializzato tutte le variabili e le matrici viene utilizzata la classe `Fast_ICA` che appartiene alla libreria `IT++`.

Ora viene creato l'oggetto `my_fastica` della classe `Fast_ICA`, viene cioè eseguito il costruttore di questa classe con il comando:

```
Fast_ICA my_fastica( X );
```

I costruttori di una classe sono utili per inizializzare le variabili della classe e per allocare aree di memoria.

Di seguito viene richiamato il metodo `set_nrof_independent_components` per settare all'interno della classe il numero di componenti indipendenti da separare (*nrIC*):

```
my_fastica.set_nrof_independent_components(nrIC);
```

Se nei parametri è stata inserita una matrice di mixing iniziale, questa viene caricata all'interno della classe.

```
if (matrice_iniziale==1)
    {my_fastica.set_init_guess(G);
```

A questo punto inizia la vera e propria elaborazione dei dati; la durata dell'elaborazione è calcolata come differenza tra l'istante di inizio (*start*) e l'istante finale (*finish*) e viene fornita nell'output del programma.

```

start = clock();
my_fastica.separate();
finish = clock();
durata_elaborazione= (double)(finish - start) / CLOCKS_PER_SEC;

```

4.2 Valutazione della stabilità della matrice dei pesi: intervalli non sovrapposti

In questo lavoro sono stati analizzati diversi intervalli di tempo ed è stata eseguita un'analisi preliminare per cercare di stabilire per quanto tempo la matrice di mixing possa essere considerata stabile.

Inizialmente sono stati analizzati intervalli di tempo di 1, 3, 5 e 10 minuti.

L'obiettivo è stato quello di valutare la stabilità della matrice dei pesi calcolata mediante l'algoritmo FastICA e fornita in output dal software. La valutazione della stabilità dei pesi è stata eseguita in base ai tempi di calcolo necessari per l'elaborazione dell'algoritmo, forniti dal software.

Consideriamo ad esempio intervalli successivi di 1 minuto di dati sperimentali. Per il primo minuto è stato annotato il tempo di calcolo, dove l'algoritmo iterativo è stato applicato utilizzando una matrice iniziale dei pesi *random* fornita di default.

Per il secondo minuto, oltre alla stima del tempo di elaborazione con matrice di default, si è eseguito l'algoritmo inserendo come matrice iniziale dei pesi la matrice calcolata per il minuto precedente, stimando nuovamente il tempo di elaborazione e sperando in una riduzione dei tempi di calcolo. Infine, come controllo, è stato annotato il tempo di elaborazione dando in ingresso la matrice dei pesi calcolata per il medesimo intervallo.

Il grafico dei tempi di calcolo ottenuti è mostrato nella figura 4.1: in blu sono riportati i dati relativi alla matrice di default, in rosa i dati relativi alla matrice di mixing dell'intervallo precedente.

I grafici nelle figure 4.2, 4.3, 4.4, mostrano invece i risultati ottenuti in modo analogo per intervalli di tempo elaborati di 3, 5 e 10 minuti.




Figura 4.1 Tempi di calcolo relativi all'elaborazione di 1 minuto di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente.




Figura 4.2 Tempi di calcolo relativi all'elaborazione di 3 minuti di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente.




Figura 4.3 Tempi di calcolo relativi all’elaborazione di 5 minuti di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l’intervallo precedente.





Figura 4.4 Tempi di calcolo relativi all’elaborazione di 10 minuti di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l’intervallo precedente.

In tutti e quattro i grafici in realtà si può notare che non c’è un sostanziale vantaggio nell’uso della matrice dei pesi precedentemente calcolata come input per l’algoritmo in sostituzione della matrice fornita di default, e ciò dimostra che la matrice dei pesi non si mantiene stabile per gli intervalli di tempo considerati.

4.3 Valutazione della stabilità della matrice dei pesi: analisi di intervalli con *overlap*

Alla luce di quanto osservato nel precedente paragrafo, si è pensato di eseguire nuove elaborazioni, analizzando intervalli di 3 e 5 minuti in modo simile a quanto descritto nel precedente paragrafo, ma effettuando questa volta una valutazione della stabilità dei pesi utilizzando la matrice di mixing calcolata per un intervallo di tempo precedente parzialmente sovrapposto a quello in esame.

In pratica, se chiamiamo t_1 il primo intervallo di dati elaborato e t_2 il secondo intervallo, t_1 e t_2 risultano sovrapposti per un intervallo di tempo (*overlap*) variabile.



L'intervallo di sovrapposizione è stato di volta in volta variato settando l'offset temporale come parametro nel software per l'elaborazione dei dati.

Analizzare intervalli di tempo parzialmente sovrapposti permette di calcolare la matrice dei pesi su un set di dati che in parte coincide con quello considerato e quindi si può sperare di ridurre i tempi di calcolo, aumentando l'overlap fino a che non si osserva un risultato significativo.

I grafici nelle figure 4.5, 4.6 e 4.7 mostrano i tempi di elaborazione ottenuti per intervalli di tempo di 3 minuti con *overlap* di 60, 120 e 150 secondi. I grafici nelle figure 4.8, 4.9, 4.10 e 4.11 mostrano invece i tempi di elaborazione ottenuti per intervalli di tempo di 5 minuti con *overlap* di 60, 120, 180 e 240 s. In questi grafici, come nei precedenti, in blu sono riportati i dati relativi alla matrice di default, in rosa i dati relativi alla matrice di mixing dell'intervallo precedente parzialmente sovrapposto a quello in esame, e in giallo, come controllo, i dati relativi ai tempi ottenuti con la matrice iniziale calcolata per il medesimo intervallo.

Anche in questo caso possiamo osservare che non c'è un sostanziale vantaggio nell'uso della matrice dei pesi precedentemente calcolata.




Figura 4.5 Tempi di calcolo relativi all'elaborazione di 180 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 60 s.




Figura 4.6 Tempi di calcolo relativi all'elaborazione di 180 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 120 s.




Figura 4.7 Tempi di calcolo relativi all'elaborazione di 180 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 150 s.




Figura 4.8 Tempi di calcolo relativi all'elaborazione di 300 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 60 s.




Figura 4.9 Tempi di calcolo relativi all'elaborazione di 300 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 120 s.




Figura 4.10 Tempi di calcolo relativi all'elaborazione di 300 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 180 s.




Figura 4.11 Tempi di calcolo relativi all'elaborazione di 300 s di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per l'intervallo precedente, con un *overlap* tra i due intervalli di 240 s.

4.4 Valutazione della stabilità della matrice dei pesi: analisi di intervalli sovrapposti (*offset* variabile da 5 a 85 campioni)

Si è deciso quindi di ripetere le elaborazioni indagando il valore minimo di *overlap* che consente di migliorare in modo apprezzabile i tempi di calcolo. Per valutare la stabilità dei pesi questa volta è stata utilizzata la matrice di mixing calcolata per un intervallo di tempo precedente quasi interamente sovrapposto a quello in esame, con un *offset* di pochi campioni.

Nel caso specifico ho analizzato intervalli di tempo di 1 minuto, spostando l'intervallo successivo con un *offset* di 5 campioni, poi di 10 campioni, 15 campioni, 20 campioni, ecc....

Nel grafico delle figure 4.12 e 4.13 possiamo osservare i tempi di elaborazione ottenuti per alcune serie di dati.




Figura 4.12 Tempi di calcolo relativi all'elaborazione di 1 minuto di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per il primo intervallo, con *offset* variabile rispetto al primo intervallo da 5 a 75 campioni.




Figura 4.13 Tempi di calcolo relativi all'elaborazione di 1 minuto di dati: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per il primo intervallo, con *offset* variabile rispetto al primo intervallo di 80 e 85 campioni.

Nella figura 4.12 la linea blu corrisponde ai tempi di calcolo di 1 minuto di dati ottenuti per l'algoritmo con matrice di default.

La seconda serie di dati corrisponde ai tempi di elaborazione sempre di 1 minuto di dati con un *offset* di 5 campioni, utilizzando la matrice calcolata per l'intervallo del primo minuto, quindi quasi interamente sovrapposto a quello in esame.

Le altre serie corrispondono a variazioni dell'*offset* da 10 a 75 campioni, con passo di 5 campioni.

Possiamo osservare come fino ad un *offset* di circa 75 campioni ci sia un'evidente riduzione dei tempi di calcolo.

Le altre serie in figura 4.13 corrispondono a un *offset* di 80 e 85 campioni. Osserviamo che le linee iniziano a sovrapporsi e possiamo affermare quindi che a partire dagli 80 campioni di *offset* non c'è più un vantaggio significativo nell'utilizzo della matrice di mixing già calcolata.

In conclusione la matrice dei pesi può essere considerata stabile per un intervallo di tempo di circa 70 campioni.

4.5 Stima dei tempi di esecuzione in funzione del numero di iterazioni.

A questo punto è stata eseguita una stima dei tempi di esecuzione dell'algoritmo in funzione del numero di iterazioni eseguite, allo scopo di verificare la linearità dei tempi di calcolo dell'algoritmo e poter eseguire una stima per il tempo di calcolo di una singola iterazione.

Per ottenere questi dati l'algoritmo FastICA è stato forzato a eseguire un numero finito di iterazioni.

Nel grafico in figura 4.14 possiamo osservare i tempi di esecuzione: le diverse serie di dati rappresentati corrispondono a diversi intervalli di tempo elaborati (1, 2, 3, 4 e 5 minuti)

In ascissa è riportato il numero di iterazioni eseguite, in ordinata il tempo di elaborazione in secondi. Possiamo osservare la linearità del tempo impiegato in funzione del numero di iterazioni eseguite.




Figura 4.14 Verifica della linearità del tempo di calcolo dell'algoritmo in funzione del numero di iterazioni eseguite, per diversi intervalli di tempo elaborati.

4.6 Stima del tempo di calcolo necessario per una singola iterazione (al variare dell'intervallo di tempo elaborato)

Con i dati precedenti è stato possibile ottenere una stima del tempo medio necessario per compiere una singola iterazione, al variare ovviamente della lunghezza dell'intervallo di tempo elaborato.

Anche in questo caso l'andamento osservato è lineare, come è possibile osservare nella figura 4.15 e per un intervallo di 1 minuto si può stimare un tempo di elaborazione per ogni singola iterazione di circa 0,4 s.




Figura 4.15 Tempo medio necessario per compiere una singola iterazione, al variare dell'intervallo di tempo elaborato.

Di seguito riportiamo i valori medi stimati per una singola iterazione per i diversi intervalli di tempo considerati, indicando con t_i il tempo relativo all'intervallo di tempo di i-minuti.

$$t_1 \sim 0,412s \pm 0,012s$$

$$t_2 \sim 0,818s \pm 0,011s$$

$$t_3 \sim 1,255s \pm 0,011s$$

$$t_4 \sim 1,697s \pm 0,012s$$

$$t_5 \sim 2,091s \pm 0,010s$$

BIBLIOGRAFIA CAP.4

- [1] A.Hyvarinen, *Fast and Robust Fixed-Point Algorithms for Independent Component Analysis*, IEEE Transactions on Neural Networks 10(3):626-634, 1999.
- [2] Malatesta A, Quitadamo LR, Abbafati M, Bianchi L, Marciani MG, Cardarilli GC (2007). *Moving towards a hardware implementation of the independent component analysis for brain computer interfaces*, IEEE BIOCAS 2007, November 27-30, 2007, Montral, Canada.
- [3] The Fast-ICA MATLAB package, <http://www.cis.hut.fi/projects/ica/fastica/1998>.

CAP. 5 Risultati

In riferimento a quanto osservato nelle figure 4.12 e 4.13 del capitolo precedente, la matrice dei pesi può essere considerata stabile per un intervallo di tempo corrispondente a circa 70 campioni.

Volendo tradurre questo risultato in secondi, poiché i dati in esame sono stati campionati con una frequenza di 256 Hz, l'intervallo stimato corrisponde a circa 0,3s.

5.1 Stima della riduzione dei tempi di calcolo.

Mettendo insieme i dati analizzati nel capitolo 4, ho potuto stimare i tempi di inizializzazione dell'algoritmo.

In particolare, i dati riportati nel paragrafo 4.6 sono stati sottratti ai tempi di esecuzione per una iterazione (paragrafo 4.5), ottenendo i tempi di inizializzazione dell'algoritmo.

Nella figura 5.1 possiamo osservare l'andamento lineare del tempo di inizializzazione in funzione dell'intervallo di tempo elaborato.




Figura 5.1 Tempo necessario per l'inizializzazione dell'algoritmo in funzione dell'intervallo di tempo elaborato

Di seguito sono riportati i valori medi stimati di inizializzazione per i diversi intervalli di tempo considerati.

$$t_{1in} \sim 1,4s \pm 0,1s$$

$$t_{2in} \sim 2,8s \pm 0,1s$$

$$t_{3in} \sim 4,2s \pm 0,1s$$

$$t_{4in} \sim 5,5s \pm 0,1s$$

$$t_{5in} \sim 7,0s \pm 0,1s$$

Per 1 minuto di tempo elaborato, quindi, l'inizializzazione dell'algoritmo richiede circa 1,4s.

Il valore stimato è stato sottratto ai valori riportati nel grafico della figura 4.12, ottenendo un nuovo grafico sui tempi di elaborazione, come mostra la figura 5.2.




Figura 5.2 Tempi di calcolo relativi all’elaborazione di 1 minuto di dati, dopo aver sottratto i tempi di inizializzazione: confronto tra i tempi ottenuti con matrice di input di default e con matrice di input calcolata per il primo intervallo, con *offset* variabile rispetto al primo intervallo da 5 a 75 campioni

Utilizzano la matrice di mixing calcolata per l’intervallo precedente in sostituzione della matrice di default, con un *offset* fino a 75 campioni, è possibile calcolare una riduzione dei tempi di calcolo in media di circa il 60%, quindi con un vantaggio significativo.

Inoltre, analizzando i dati della figura 5.2 e considerando una riduzione dei tempi di calcolo di circa il 60%, il tempo medio necessario per l’elaborazione di 1 minuto di dati campionati può essere stimato in ~ 10 s.

5.2 Stima della potenza di elaborazione necessaria per l’implementazione hardware

A questo punto si è cercato di stimare in modo approssimativo la potenza di elaborazione necessaria per un’eventuale implementazione hardware, relativamente all’elaborazione di 1 minuto di dati.

Ho stimato il numero di somme in virgola mobile al secondo (MFLOPS) dell’elaboratore utilizzato in circa 800 MFLOPS. Per ottenere questa stima ho realizzato un piccolo software che esegue un numero molto elevato di somme in virgola mobile, lavorando con lo stesso compilatore e gli stessi parametri del software utilizzato per l’analisi dati.

Ora sappiamo dal paragrafo 5.1 che il tempo medio necessario per l'elaborazione di 1 minuto di dati campionati può essere stimato in ~ 10 s (considerando una riduzione dei tempi di elaborazione del 60%).

Poiché abbiamo verificato una stabilità della matrice dei pesi per un *offset* di circa 70 campioni, il tempo disponibile per l'elaborazione, rendendo possibile l'utilizzo della matrice dei pesi precedentemente calcolata, è di circa 0,3 s.

Mettendo insieme i valori precedenti, possiamo quindi fornire una stima approssimativa della potenza di elaborazione necessaria per l'implementazione hardware in circa 30 GFLOPS.

Per migliorare le prestazioni del sistema e quindi ridurre in modo significativo il numero di FLOPS necessari, possiamo fare inoltre le seguenti considerazioni. Innanzitutto, poiché si stima per l'algoritmo un egual numero di moltiplicazioni e somme, si può pensare di parallelizzare il calcolo. Inoltre dobbiamo considerare che nel caso dei dati analizzati sono stati impiegati 59 canali di acquisizione e ipotizzate 59 sorgenti neuronali originarie; un'eventuale diminuzione del numero n di canali ridurrebbe in modo sensibile la complessità del calcolo, che varia con n^2 .


5.3 Verifica della stabilità nell'ordine delle sorgenti calcolate (effetto di trascinamento)

Un altro problema che riguarda il metodo ICA è l'indeterminazione delle componenti indipendenti all'interno della matrice delle sorgenti stimate: cioè non c'è alcun modo di sapere quale segnale venga ricavato per primo. Quindi elaborando intervallo per intervallo non sappiamo in quale posizione stiamo osservando lo stesso segnale.


La conoscenza del giusto ordine è invece essenziale per la ricostruzione delle componenti indipendenti nel dominio del tempo e quindi allo scopo di un'eliminazione automatica delle sorgenti di rumore individuate.

Nel primo grafico della figura 5.3 possiamo vedere un esempio di segnali elettroencefalografici acquisiti, nel secondo grafico le sorgenti elaborate con il metodo ICA, tra le quali è chiaramente individuabile la componente dovuta ai battiti oculari; nell'ultimo grafico possiamo osservare infine i segnali EEG rielaborati dopo aver eliminato la componente di rumore individuata.

Segnali EEG acquisiti



Sorgenti individuate con ICA



battiti oculari

Segnali EEG "ripuliti"




Figura 5.3 Nel primo grafico è visibile un esempio di segnali elettroencefalografici acquisiti, mentre nel secondo grafico le sorgenti elaborate con il metodo ICA, tra le quali è chiaramente individuabile la componente dovuta ai battiti oculari. Nell'ultimo grafico possiamo osservare infine i segnali EEG rielaborati dopo aver eliminato la componente di rumore.

Nel paragrafo 4.4, analizzando intervalli di dati di 1 minuto, abbiamo osservato che la matrice dei pesi può essere considerata stabile per un intervallo di *offset* pari ad un massimo di 75 campioni.

È stato applicato quindi il metodo ICA a tre intervalli di 1 minuto quasi totalmente sovrapposti, con un *offset* di 70 campioni tra il primo e il secondo intervallo e tra il secondo e il terzo; per il secondo e terzo minuto è stato fornito in input per l'algoritmo la matrice di mixing calcolata per l'intervallo precedente. Alcune componenti indipendenti elaborate sono rappresentate nei grafici in figura 5.4.

Con le sorgenti elaborate è stato possibile verificare un effetto di "trascinamento", cioè è stata verificata la stabilità nell'ordine delle sorgenti calcolate.

Possiamo osservare che è ben riconoscibile il contributo dell'alternata che compare splittato in due sorgenti.

L'ordine delle sorgenti viene mantenuto e questo è un risultato significativo perché rende possibile eliminare in modo automatico le sorgenti di rumore individuate.




Figura 5.4 Verifica dell'effetto di "trascinamento" nell'ordine delle sorgenti individuate con il metodo ICA. Il primo grafico corrisponde all'analisi del primo minuto di dati; il secondo grafico corrisponde all'analisi di un minuto di dati con un offset di 70 campioni rispetto al primo minuto, fornendo in input per l'algoritmo la matrice di mixing calcolata per il primo minuto; il terzo grafico corrisponde all'analisi di un minuto di dati con un offset di 140 campioni rispetto al primo minuto, fornendo in input per l'algoritmo la matrice di mixing calcolata per il secondo intervallo. Possiamo osservare che è ben riconoscibile il contributo dell'alternata che compare splittato in due sorgenti.

CONCLUSIONI

L'*Independent Component Analysis* (ICA) è uno strumento molto potente che può essere utilizzato in diversi modi per elaborare i segnali elettroencefalografici (EEG). Può essere utilizzato per identificare e rimuovere le sorgenti di rumore (ad esempio i movimenti oculari), o per selezionare le componenti relative a determinate attività cerebrali al fine di ottenere precisi comandi in grado di guidare un sistema di *Brain Computer Interface* (BCI). In entrambi i casi l'analisi ICA consente di incrementare notevolmente il rapporto segnale/rumore dei segnali EEG registrati.

Di fatto questa tecnica non viene ancora utilizzata in applicazioni real-time, poiché necessita di una potenza di elaborazione elevata e i pesi della matrice di mixing che vengono calcolati per ricostruire le sorgenti neurali originali, a partire dai dati registrati direttamente sulla calotta cranica del soggetto in esame, variano significativamente nel tempo. È necessario quindi valutare continuamente i pesi in modo che possano essere utilizzati per ricostruire le sorgenti originali in real-time.

L'impatto di tale sistema di interpretazione dei segnali cerebrali su applicazioni reali, che si avvalgono di segnali elettroencefalografici, sarebbe molto importante: un migliore rapporto segnale/rumore porterebbe a sistemi BCI decisamente migliori, per offrire straordinarie capacità di comunicazione e ridare autonomia a persone diversamente abili, permetterebbe di avere più precisi e affidabili sistemi di unità di terapia intensiva e chirurgia, ma anche di ottenere interessanti applicazioni spaziali e industriali.

In questo lavoro abbiamo studiato la potenza di elaborazione necessaria per applicare l'algoritmo FastICA ad un *array* di 59 segnali cerebrali.

Inizialmente è stata verificata la linearità del tempo di elaborazione dell'algoritmo in relazione al numero di iterazioni effettuate.

Analizzando intervalli di dati di un minuto, abbiamo stimato che la matrice di mixing può essere considerata stabile per un intervallo di tempo corrispondente a circa 70 campioni. Volendo tradurre questo risultato in secondi, poiché i dati in esame sono stati campionati con una frequenza di 256 Hz, l'intervallo stimato corrisponde a circa 0,3s.

Prendendo in considerazione un intervallo di dati di un minuto e utilizzando come matrice iniziale di mixing per l'algoritmo la matrice calcolata precedentemente per un intervallo di dati parzialmente sovrapposto a quello in esame, con un offset di 70 campioni, è stato possibile stimare una riduzione del tempo di calcolo di circa il 60%.

Inoltre è stato possibile verificare un effetto di "trascinamento" nelle sorgenti individuate, cioè la stabilità nell'ordine delle sorgenti, superando uno dei più grandi limiti del metodo ICA e rendendo possibile la rimozione automatica delle sorgenti di rumore.

Infine, la potenza di elaborazione necessaria per implementare l'algoritmo FastICA in un dispositivo hardware è stata stimata in circa 30 GFLOPS. Dobbiamo considerare però che nel caso dei dati analizzati sono stati impiegati 59 canali di acquisizione e ipotizzate 59 sorgenti neurali originarie; un'eventuale diminuzione del numero n di canali ridurrebbe in modo sensibile la complessità del calcolo, che varia con n^2 .