



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ & ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ

Διπλωματική Εργασία

Διεπαφές εγκεφάλου-υπολογιστή για εφαρμογές κίνησης μέσω εικόνων



Φοιτητής: Ιωάννης Βουζουνεράκης
ΑΜ: 18387259

Επιβλέπουσα Καθηγήτρια:
Ραγκούση Μαρία

ΑΘΗΝΑ-ΑΙΓΑΛΕΩ, ΦΕΒΡΟΥΑΡΙΟΣ 2024



UNIVERSITY OF WEST ATTICA
FACULTY OF ENGINEERING
DEPARTMENT OF ELECTRICAL & ELECTRONICS ENGINEERING

Diploma Thesis

Brain-Computer Interfaces for motor imagery applications



Student: Ioannis Vouzounerakis
Registration Number: 18387259

Supervisor
Rangoussi Maria

ATHENS-EGALEO, FEBRUARY 2024

Η Διπλωματική Εργασία έγινε αποδεκτή και βαθμολογήθηκε από την εξής τριμελή επιτροπή:

Μαρία Ραγκούση καθηγήτρια	Σάββας Βασιλειάδης καθηγητής	Σωτηρία Γαλατά επ. καθηγήτρια
(Υπογραφή)	(Υπογραφή)	(Υπογραφή)

Copyright © Με επιφύλαξη παντός δικαιώματος. All rights reserved.

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ και Ιωάννης Βουζουνεράκης,
Ιανουάριος 2024**

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τους συγγραφείς.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον/την συγγραφέα του και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις θέσεις του επιβλέποντος, της επιτροπής εξέτασης ή τις επίσημες θέσεις του Τμήματος και του Ιδρύματος.

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο κάτωθι υπογεγραμμένος Βουζουνεράκης Ιωάννης του Βασιλείου, με αριθμό μητρώου 18387259 φοιτητής του Πανεπιστημίου Δυτικής Αττικής, της Σχολής ΜΗΧΑΝΙΚΩΝ, του Τμήματος ΗΛΕΚΤΡΟΛΟΓΩΝ ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΜΗΧΑΝΙΚΩΝ,

δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου.

Ο Δηλών



Ιωάννης Βουζουνεράκης

Ευχαριστίες

Με την ολοκλήρωση της διπλωματικής εργασίας μου, θα ήθελα να εκφράσω την ευγνωμοσύνη μου σε όλους όσους συνέβαλλαν στην ολοκλήρωση της.

Ευχαριστώ θερμά την επιβλέπουσα καθηγήτριά μου, κυρία Μαρία Ραγκούση για την εμπιστοσύνη, την υποστήριξη και την καθοδήγηση που μου έδειξε από την αρχή, μέχρι το τέλος της διπλωματικής μου εργασίας.

Επιπλέον, θα ήθελα να ευχαριστήσω όλους τους φίλους και συμφοιτητές μου, για τις υπέροχες στιγμές που μου χάρισαν σε όλη την διάρκεια των σπουδών μου.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένειά μου για την υποστήριξη, την συμπαράσταση, την αγάπη που μου έδωσαν όλα αυτά τα χρόνια και συνεχίζουν να μου δίνουν.

Περίληψη

Αντικείμενο της διπλωματικής εργασίας είναι η ανάπτυξη ενός συστήματος διαπεφής εγκεφάλου-υπολογιστή. Σκοπός τέτοιων συστημάτων είναι να δοθεί ευκαιρία σε άτομα με σοβαρή παράλυση ένας διαφορετικός τρόπος επικοινωνίας που δεν εξαρτάται από τα νεύρα και τους μύες. Η εργασία επικεντρώνεται σε συστήματα διεπαφών εγκεφάλου υπολογιστή χρήση μη επεμβατικών μεθόδων, χρησιμοποιώντας την τεχνική της κινητικής φαντασίωσης (MI). Η εργασία εστιάζει γύρω από τα βασικά βήματα πραγματοποίησης ενός τέτοιου συστήματος για προβλήματα ταξινόμησης δύο κλάσεων. Ο χαμηλός λόγος σήματος προς θόρυβο και η πολυπλοκότητα των εγκεφαλικών σημάτων αποτελούν μια βασική πρόκληση για την αποτελεσματική μετάφραση της εγκεφαλικής δραστηριότητας. Το σύστημα που αναπτύχθηκε είναι βασισμένο στην εφαρμογή της μεθόδου των Κοινών Χωρικών Προτύπων (CSP) για την εξαγωγή χαρακτηριστικών, συνδυάζοντας τη Ανάλυση Γραμμικής Διάκρισης (LDA) και τις Μηχανές Διανυσματικής Υποστήριξης (SVM) για την ταξινόμηση των σημάτων κινητικής φαντασίωσης. Το σύνολο των δεδομένων που χρησιμοποιήθηκε για την δημιουργία του συστήματος είναι από τον τέταρτο διαγωνισμό διεπαφών εγκεφάλου υπολογιστή. Τελικός στόχος είναι η σύγκριση των δύο αλγορίθμων ταξινόμησης.

Λέξεις – κλειδιά

Διεπαφές Εγκεφάλου-Υπολογιστή (ΔΕΥ), Κινητική Φαντασίωση, Κοινά Χωρικά Πρότυπα, Ανάλυση Γραμμικής Διάκρισης, Μηχανές Διανυσματικής Υποστήριξης

Abstract

The subject of this thesis is the development of a brain-computer interface system. The purpose of such systems is to provide individuals with severe paralysis an alternative way of communication that does not rely on nerves and muscles. The thesis focuses on non-invasive brain-computer interface systems using the technique of motor imagery (MI). It centers around the basic steps of implementing such a system for two-class classification problems. The low signal to noise ratio and the complexity of the brain signals pose a significant challenge for the effective translation of brain activity. The developed system is based on the application of the Common Spatial Patterns (CSP) method for feature extraction, combining Linear Discriminant Analysis (LDA) and Support Vector Machines (SVM) for the classification of motor imagery signals. The dataset used for the development of the system is from the fourth brain-computer interface competition. The goal is to compare the two classification algorithms.

Keywords

Brain-Computer interface (BCI), Motor Imagery (MI), Common Spatial Patterns (CSP), Linear Discriminant Analysis (LDA), Support Vector machines (SVM)

Περιεχόμενα

Κατάλογος Πινάκων.....	10
Κατάλογος Εικόνων.....	11
ΕΙΣΑΓΩΓΗ.....	13
ΚΕΦΑΛΑΙΟ 1: Ο ανθρώπινος εγκέφαλος – σύντομη επισκόπηση	15
1.1 Εισαγωγή.....	15
1.2 Δομή εγκεφάλου	15
1.2.1 Πρόσθιος εγκέφαλος.....	16
1.2.2 Διάμεσος εγκέφαλος.....	19
1.2.3 Οπίσθιος εγκέφαλος	19
1.3 Επισκόπηση εγκεφαλικών κυττάρων	20
1.3.1 Ομάδες-Τύποι νευρώνων.....	22
1.3.2 Μετάδοση πληροφορίας νευρώνων.....	22
1.4 Εγκεφαλικά δυναμικά	22
1.4.1 Δυναμικό ηρεμίας	22
1.4.2 Δυναμικό ενέργειας ή δράσης νευρικού κυττάρου.....	23
1.5 Εγκεφαλικοί ρυθμοί	24
ΚΕΦΑΛΑΙΟ 2: Επισκόπηση διεπαφών εγκεφάλου-υπολογιστή	28
2.1 Διεπαφές Εγκεφάλου-Υπολογιστή (Brain computer interface, BCI)	28
2.2 Εφαρμογές Διεπαφών Εγκεφάλου-Υπολογιστή	29
2.2.1 Ιατρικές εφαρμογές διεπαφών εγκεφάλου-υπολογιστή.....	29
2.2.2 Μη ιατρικές εφαρμογές διεπαφών εγκεφάλου-υπολογιστή.....	29
2.3 Τεχνικές λήψεων εγκεφαλικού σήματος BCI.....	30
2.3.1 Επεμβατικές τεχνικές BCI.....	30
2.3.2 Μερικώς επεμβατικές τεχνικές BCI.....	31
2.3.3 Μη επεμβατικές τεχνικές BCI.....	31
2.4 Το Ηλεκτροεγκεφαλογράφημα (electroencephalogram, EEG)	32
2.4.1 Διατάξεις Ηλεκτροεγκεφαλογραφίας	33
2.5 Πρότυπα εγκεφαλικής δραστηριότητας σχεδιασμού BCI	33
2.5.1 Event-Related Desynchronization or Synchronization (ERD/ERS)	34
2.5.2 Δυναμικά σχετιζόμενα με συμβάντα (Event-related Potentials, ERPs).....	34
2.5.3 Προκλητά δυναμικά σταθερής κατάστασης (SSEP).....	35
2.6 Κινητική φαντασίωση (Motor imagery)	35
ΚΕΦΑΛΑΙΟ 3: Συστήματα διεπαφών εγκεφάλου-υπολογιστή	36
3.1 Βασική δομή διεπαφών εγκεφάλου υπολογιστή	36
3.2 Καταγραφή εγκεφαλικής δραστηριότητας	36
3.3 Προ-επεξεργασία σήματος.....	37
3.4 Εξαγωγή χαρακτηριστικών.....	40
3.4.1 Χρονική Αναπαράσταση.....	41
3.4.2 Αναπαράσταση στο πεδίο της συχνότητας.....	43
3.4.3 Χρονο-συχνοτική αναπαράσταση	45
3.4.4 Χωρική αναπαράσταση.....	46
3.5 Ταξινόμηση	48
3.5.1 Ανάλυση Γραμμικής Διάκρισης (Linear Discriminant Analysis, LDA)	50
3.5.2 Μηχανές Διανυσματικής Υποστήριξης (Support Vector Machines, SVM).....	52
3.6 Αξιολόγηση συστήματος	60
3.6.1 Δείκτες Αξιολόγησης συστήματος	60

3.6.2 Μέθοδος Hold-out	61
3.6.3 Πίνακας σύγχυσης.....	62
3.6.4 Τεχνική k-fold Cross-validation	63
ΚΕΦΑΛΑΙΟ 4: Ανάπτυξη συστήματος αναγνώρισης προτύπων BCI με τεχνική motor imagery	65
4.1 Η πρόκληση και ο σκοπός	65
4.2 Μεθοδολογία	68
4.2.1 Προ-επεξεργασία δεδομένων	68
4.2.2 Εξαγωγή χαρακτηριστικών.....	71
4.2.3 Ταξινόμηση δεδομένων	74
ΚΕΦΑΛΑΙΟ 5: Συμπεράσματα	84
ΒΙΒΛΙΟΓΡΑΦΙΑ	86
ΠΑΡΑΡΤΗΜΑ Ι	93

Κατάλογος Πινάκων

Πίνακας 1.1: Κατανομή εγκεφαλικών ρυθμών κατά συχνότητα ζώνης κύματος.	24
Πίνακας 3.1: Παραμετρικές και μη παραμετρικές μέθοδοι εκτίμησης πυκνότητας φασματικής ισχύος.....	45
Πίνακας 3.2: Επισκόπηση των κοινών συναρτήσεων πυρήνα SVM: Σύνοψη των τυπικών πυρήνων SVM και των μαθηματικών τους μοντέλων.	54
Πίνακας 4.1: Οι δύο κατηγορίες κινητικής φαντασίωσης των ατόμων	67
Πίνακας 4.2: Αποτελέσματα LDA με δεδομένα εκπαίδευσης το 50% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	75
Πίνακας 4.3: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 50% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	76
Πίνακας 4.4: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 70% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	76
Πίνακας 4.5: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 70% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	77
Πίνακας 4.6: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 80% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	77
Πίνακας 4.7 Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 80% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	77
Πίνακας 4.8: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 100% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	77
Πίνακας 4.9 Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 100% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.....	77
Πίνακας 4.10: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 50% των δεδομένων και έλεγχο με το υπόλοιπο 50% των δεδομένων (50% hold-out)	79
Πίνακας 4.11: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 50% των δεδομένων και έλεγχο με το υπόλοιπο 50% των δεδομένων (50% hold-out)	79
Πίνακας 4.12: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 70% των δεδομένων και έλεγχο με το υπόλοιπο 30% των δεδομένων (30% hold-out)	79
Πίνακας 4.13: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 70% των δεδομένων και έλεγχο με το υπόλοιπο 30% των δεδομένων (30% hold-out)	80
Πίνακας 4.14: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 80% των δεδομένων και έλεγχο με το υπόλοιπο 20% των δεδομένων (20% hold-out)	80

Πίνακας 4.15: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 80% των δεδομένων και έλεγχο με το υπόλοιπο 20% των δεδομένων (20% hold-out)	80
Πίνακας 4.16: Συγκριτικός Πίνακας Αποτελεσμάτων Αλγορίθμων (1η φάση, 2η φάση).....	81

Κατάλογος Εικόνων

Εικόνα 1.1: Μήνιγγες του Εγκεφάλου	16
Εικόνα 1.2: Χάρτης λοβών εξωτερικής στοιβάδας του εγκεφαλικού φλοιού σε πλάγια προβολή εγκεφάλου.....	18
Εικόνα 1.3: α. β Χάρτης μετωπιαίου και βρεγματικού λοβού.	19
Εικόνα 1.4: Πρόσθιος-Οπίσθιος και Έσχατος εγκέφαλος.....	20
Εικόνα 1.5: Σχηματικό διάγραμμα ενός τυπικού νευρικού κυττάρου.....	21
Εικόνα 1.6: Δυναμικό ηρεμίας & ενέργειας νευρικού κυττάρου	24
Εικόνα 1.7: Δείγμα εγκεφαλικού ρυθμού άλφα διάρκειας 1 sec.....	25
Εικόνα 1.8: Δείγμα εγκεφαλικού ρυθμού βήτα διάρκειας 1 sec.	25
Εικόνα 1.9: Δείγμα εγκεφαλικού ρυθμού γάμα διάρκειας 1 sec.	26
Εικόνα 1.10: Δείγμα εγκεφαλικού ρυθμού δέλτα διάρκειας 1 sec.....	26
Εικόνα 1.11: Δείγμα εγκεφαλικού ρυθμού θήτα διάρκειας 1 sec.	27
Εικόνα 2.1: Διεπαφές εγκεφάλου-υπολογιστή για τον έλεγχο των κινήσεων και των ενεργειών ενός avatar στο διαδικτυακό παιχνίδι World of Warcraft από την Blizzard Entertainment, Inc. (Πηγή: BCI Integration: Application Interfaces IntechOpen)	28
Εικόνα 2.2: Σημεία καταγραφής σήματος για τις τεχνικές ΔΕΥ	32
Εικόνα 2.3: Διάταξη ηλεκτροδίων του διεθνούς συστήματος 10-20 (A) και 10-10 (B) για καταγραφή ηλεκτροεγκεφαλογραφίας. Οι περιττοί αριθμοί ηλεκτροδίων βρίσκονται στο αριστερό ημισφαίριο, οι ζυγοί αριθμοί ηλεκτροδίων στο δεξί ημισφαίριο. Τα γράμματα αντιστοιχούν στους λοβούς-F(rontal), T(emporal), P(arietal) και O(ccipital). Τέλος το γράμμα C σημαίνει κέντρο	33
Εικόνα 3.1: Βασική δομή ενός BCI συστήματος.....	36
Εικόνα 3.2: Τα τέσσερα κοινά φίλτρα (α) Χαμηλοπερατό φίλτρο, (β) Υψιπερατό φίλτρο, (γ) Ζωνοπερατό φίλτρο. (δ) Ζωνοφρακτικό.....	38
Εικόνα 3.3 : Δείγμα Δυαδική ταξινόμησης	49

Εικόνα 3.4: Δείγμα πολυκατηγορικής ταξινόμησης	49
Εικόνα 3.5: Παράδειγμα συσταδοποίησης, σημεία δεδομένων ομαδοποιούνται σε τρεις ομάδες	50
Εικόνα 3.6: Πιθανά όρια απόφασης για τον διαχωρισμό των κλάσεων.....	53
Εικόνα 3.7: Βέλτιστο όριο απόφασης για τον διαχωρισμό των κλάσεων.....	53
Εικόνα 3.8: Περιπτώσεις μεγάλου και μικρού περιθωρίου.....	53
Εικόνα 3.9: Αρχιτεκτονική δικτύου Perceptron.....	57
Εικόνα 3.10: Βασική αρχιτεκτονική ενός νευρωνικού δικτύου τύπου Multilayer Perceptron (MLP) με ένα στρώμα εισόδου (ροζ), δύο κρυφά στρώματα (γαλάζια) και δύο κόμβους στο στρώμα εξόδου (κίτρινα).....	58
Εικόνα 3.11: Παράδειγμα φίλτρων για CNN	60
Εικόνα 3.12: Παράδειγμα εφαρμογής συνέλιξης.....	60
Εικόνα 3.13: Μέθοδος Hold-out για την αξιολόγηση μοντέλου.....	62
Εικόνα 3.14: Πίνακας σύγκρισης δυαδικής ταξινόμησης.....	63
Εικόνα 3.15: Τεχνική k-fold cross-validation για $k = 4$	64
Εικόνα 4.1 Ακολουθία οπτικών ερεθισμάτων σε συνεδρία του πρώτου συνόλου δεδομένων του 4 ^{ου} διαγωνισμού BCI.....	66
Εικόνα 4.2: Δομή μεθοδολογίας υλοποίησης πειράματος.....	68
Εικόνα 4.3 Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C3 για το Άτομο e.....	70
Εικόνα 4.4: Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C4 για το Άτομο e.....	70
Εικόνα 4.5: Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C4 για το Άτομο e.....	71
Εικόνα 4.6 : Μέση τιμή Λογαριθμικής διακύμανσης κάθε καναλιού ατόμου d.....	72
Εικόνα 4.7 : Μέση τιμή λογαριθμικής διακύμανσης χρήση των 6 φίλτρων του αλγορίθμου CSP για το άτομο d.....	73
Εικόνα 4.8 : Διάγραμμα διασποράς συναρτήσεως πρώτου και τελευταίου στοιχείου.....	74
Εικόνα 4.9 : Διάγραμμα διασποράς συναρτήσεως πρώτου και τελευταίου στοιχείου χρήση αλγορίθμου CSP για το άτομο d.....	74

ΕΙΣΑΓΩΓΗ

Η δυνατότητα άμεσης επικοινωνίας μεταξύ ανθρώπινου εγκεφάλου και υπολογιστή και η ανάπτυξη μηχανισμών ελέγχου αποτελούσε θέμα επιστημονικής φαντασίας για πάρα πολλά χρόνια. Τα τελευταία χρόνια λόγω της ραγδαίας ανάπτυξης της επιστήμης και της τεχνολογίας, η ιδέα αυτή έχει υλοποιηθεί και αναπτύσσεται με πολύ γρήγορους ρυθμούς. Ένα σύστημα διεπαφής εγκεφάλου-υπολογιστή έχει σκοπό την αναγνώριση της πρόθεσης του χρήστη, βάση της εγκεφαλικής δραστηριότητας να κάνει μία ενέργεια. Με τη χρήση επεμβατικών ή μη επεμβατικών μεθόδων, ένα τέτοιο σύστημα είναι ικανό για την επεξεργασία εγκεφαλικών σημάτων, την αναγνώριση κοινών μοτίβων των σημάτων και την κατάλληλη ταξινόμησή τους, για τον αποτελεσματικό «νοητικό» έλεγχο και λειτουργία μιας εξωτερικής διάταξης από τον άνθρωπο – όχι μέσω δράσης αλλά μέσω σκέψης. Οι διεπαφές ανθρώπινου εγκεφάλου-υπολογιστή χρησιμοποιούνται σε διάφορους τομείς, όπως στην ασφάλεια και ταυτοποίηση, στα βιντεοπαιχνίδια, το νευρομάρκετινγκ και στην διαφήμιση. Παρόλα αυτά, ο τομέας που χρησιμοποιούνται περισσότερο είναι η ιατρική, καθώς στοχεύουν στην βελτίωση της ζωής και την επίλυση προβλημάτων που αντιμετωπίζουν καθημερινά άτομα που πάσχουν από κάποια αναπηρία, όπως στην αποκατάσταση ατόμων με νευρομυικές διαταραχές και τραυματισμό σπονδυλικής στήλης. Ωστόσο η ανάπτυξη συστημάτων BCI με τη χρήση εγκεφαλικών σημάτων περιλαμβάνει πολλές προκλήσεις. Ο εγκέφαλος είναι αρκετά πολύπλοκος και έχει μη γραμμική δυναμική συμπεριφορά, με αποτέλεσμα να υπάρχουν προκλήσεις στην εξαγωγή χαρακτηριστικών μεγεθών από τα ηλεκτροεγκεφαλογραφικά σήματα και στην ταξινόμησή τους. Επίσης οι εφαρμογές τέτοιων συστημάτων περιλαμβάνουν πολλές μεταβλητές που πρέπει να ληφθούν υπόψη. Εξαιτίας αυτών των λόγων, τέτοια συστήματα είναι ακόμα υπό επιστημονική διερεύνηση σε ερευνητικά εργαστήρια.

Η παρούσα εργασία εστιάζει στο πρόβλημα της χρήσης της τεχνολογίας BCI για την αποτελεσματική μετάφραση των σημάτων κινητικής φαντασίωσης με χρήση μη επεμβατικών τεχνικών. Αυτή η διεπαφή αποτελεί πρόκληση καθώς τα εγκεφαλικά σήματα λαμβάνονται από το τριχωτό της κεφαλής, ως αποτέλεσμα η δραστηριότητα που συλλέγεται περιλαμβάνει ένα μεγάλο μέρος του εγκεφάλου δηλαδή περιλαμβάνονται και άλλες δραστηριότητες του οργανισμού, επομένως τα δεδομένα σε θόρυβο.

Η εργασία που εκπονήθηκε δομείται σε πέντε κεφάλαια. Αρχικά στο πρώτο κεφάλαιο γίνεται αναφορά στον εγκέφαλο για την κατανόηση βασικών όρων της ανατομίας του, με έμφαση στην φυσιολογία του εγκεφάλου. Στο δεύτερο κεφάλαιο γίνεται εισαγωγή στο ζήτημα των διεπαφών

εγκεφάλου-υπολογιστή (BCI). Πιο συγκεκριμένα δίνεται ο ορισμός του BCI, των εφαρμογών καθώς και των διαφόρων τεχνικών που υπάρχουν για την υλοποίηση συστήματος BCI. Στο τρίτο κεφάλαιο περιγράφεται η βασική δομή ενός BCI συστήματος, αναλύεται ο σκοπός και ο ρόλος κάθε βήματος για την επεξεργασία του ηλεκτροεγκεφαλογραφικού σήματος και την επιτυχή ταξινόμηση των δεδομένων. Στο τέταρτο κεφάλαιο παρουσιάζεται και αναλύεται η πειραματική διαδικασία που ακολουθήθηκε, οι στόχοι, τα βήματα εκτέλεσης των εργασιών και τα αποτελέσματα που λήφθηκαν. Στο τελευταίο κεφάλαιο αναφέρονται τα συμπεράσματα σχετικά με τις διεπαφές εγκεφάλου υπολογιστή.

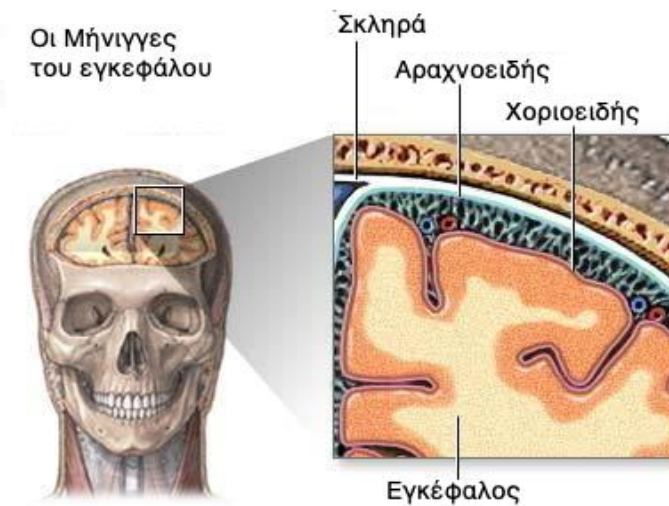
ΚΕΦΑΛΑΙΟ 1: Ο ανθρώπινος εγκέφαλος – σύντομη επισκόπηση

1.1 Εισαγωγή

Το ανθρώπινο Κεντρικό Νευρικό Σύστημα (ΚΝΣ) αποτελείται από τον νωτιαίο μυελό και τον εγκέφαλο. Ο εγκέφαλος είναι ένας ηλεκτροχημικός υπολογιστής, είναι όργανο που αποτελεί το σπουδαιότερο, μεγαλύτερο και πολυπλοκότερο τμήμα του ΚΝΣ. Έχει μόλις το 2% του ανθρώπινου βάρους και απορροφά το 20% της ενέργειας του σώματος. Αποτελεί την πηγή της συνείδησης, της σκέψης, της κρίσης, της μνήμης, της λογικής και του συναισθήματος και είναι υπεύθυνος για όλες τις λειτουργίες του ανθρώπινου σώματος. Μέσω των κεντρομόλων νεύρων, ο εγκέφαλος λαμβάνει αισθητικά ερεθίσματα τα οποία εγγράφονται ως αισθήσεις. Τα ερεθίσματα προέρχονται από το περιβάλλον και καταγράφονται μέσω των αισθητηρίων οργάνων των πέντε αισθήσεων του ανθρώπου: την όραση, την οσμή, την αφή, την γεύση και την ακοή. Τα φυγόκεντρα νεύρα, αντίστροφα, μεταβιβάζουν από τον εγκέφαλο προς άλλα όργανα του ανθρώπου, π.χ. τα άκρα, τα μάτια, κλπ., κινητικές εντολές για την εκτέλεση κινητικών δραστηριοτήτων. Επίσης σημαντική λειτουργία στον εγκέφαλο έχουν τα αντανακλαστικά κέντρα τα οποία είναι υπεύθυνα για τη διατήρηση του αυτόματου ελέγχου των δραστηριοτήτων του σώματος. Ο εγκέφαλος δέχεται, αποκωδικοποιεί και μεταβιβάζει ερεθίσματα και πληροφορίες μέσω των νεύρων, λειτουργώντας ως ένα κέντρο ρύθμισης και συντονισμού των δράσεων του οργανισμού για την επιβίωσή του.

1.2 Δομή εγκεφάλου

Ο εγκέφαλος βρίσκεται εντός του εγκεφαλικού κρανίου και περιβάλλεται από τρεις προστατευτικούς υμένες που ονομάζονται μήνιγγες του εγκεφάλου. Από έξω προς τα μέσα είναι η σκληρή, η αραχνοειδής και η χοριοειδής μήνιγγα. Η σκληρή μήνιγγα είναι η πρώτη από τις τρεις, βρίσκεται αμέσως κάτω από το κρανίο και περιέχει αρτηρίες και φλέβες οι οποίες τρέφουν τα οστά του κρανίου. Επίσης δημιουργεί αναδιπλώσεις: υπάρχουν ειδικές αναδιπλώσεις που ονομάζονται δρέπανο και σκηνίδιο. Το δρέπανο χωρίζει το αριστερό από το δεξί ημισφαίριο του εγκεφάλου ενώ το σκηνίδιο διαχωρίζει τα ημισφαίρια από την παρεγκεφαλίδα. Η αραχνοειδής μήνιγγα βρίσκεται ανάμεσα στις δύο άλλες μεμβράνες. Αποτελείται από λεπτό συνδετικό ιστό, ονομάζεται έτσι λόγω των αναδιπλώσεων που είναι παρόμοιες με ιστό αράχνης. Η χοριοειδής μήνιγγα περιβάλλει την επιφάνεια του εγκεφάλου και παρακολουθεί όλες τις αυλακώσεις του. Περιέχει αιμοφόρα αγγεία και αρτηρίες που θρέφουν τον εγκέφαλο.



Εικόνα 1.1: Μήνιγγες του Εγκεφάλου

(Πηγή: [Βασικές Γνώσεις Ανατομίας του Εγκεφάλου \(pediatric-neurosurgery.com\)](http://www.pediatric-neurosurgery.com))

Το εγκεφαλονωτιαίο υγρό είναι ένα διαυγές, άχρωμο σωματικό υγρό που βρίσκεται μέσα στον ιστό που περιβάλλει τον εγκέφαλο και το νωτιαίο μυελό. Καταλαμβάνει χώρο ανάμεσα στην αραχνοειδή και χοριοειδή μεμβράνη, επίσης βρίσκεται σε όλες τις κοιλίες τις κύστες, τις αυλακώσεις εγκεφάλου. Η κύρια χρήση του εγκεφαλονωτιαίου υγρού είναι να δρα ως αποσβεστήρας κραδασμών και απομονωτής από το εξωτερικό περιβάλλον παρέχοντας μία ανοσολογική προστασία στον εγκέφαλο.

Τα κύρια μέρη του ίδιου του εγκεφάλου είναι:

- Πρόσθιος εγκέφαλος
- Διάμεσος εγκέφαλος
- Μέσος εγκέφαλος
- Έσχατος εγκέφαλος
- Οπίσθιος εγκέφαλος


1.2.1 Πρόσθιος εγκέφαλος

Ο πρόσθιος εγκέφαλος περιλαμβάνει τις δύο πλάγιες κοιλίες του εγκεφάλου, τα εγκεφαλικά ημισφαίρια που αποτελούνται από τον εγκεφαλικό φλοιό και τους συνδέσμους των ημισφαιρίων. Ο εγκεφαλικός φλοιός είναι ένα εξωτερικό κέλυφος φαιάς ουσίας που καλύπτει τις εμμύελες ίνες της λευκής ουσίας. Η φαιά ουσία αποτελείται κυρίως από τα κυτταρικά σώματα των νευρών και βρίσκεται κυρίως στον εγκεφαλικό φλοιό, στους πυρήνες και στα βασικά γάγγλια. Από την άλλη, η λευκή ουσία καλύπτει περιοχές με συσσωρευμένους νευρώνες, γνωστοί ως υποφλοιϊκοί

πυρήνες. Η λευκή ουσία αποτελείται από νευρίτες, οι οποίοι δημιουργούν νευρικές οδούς με πολλές ίνες που μεταφέρουν πληροφορίες εντός των ημισφαιρίων, προς τα έξω, και συνδέουν διάφορες περιοχές του εγκεφάλου, καθώς και τμήματα του εγκεφάλου με το νωτιαίο μυελό. Επιπλέον, οι δύο εγκεφαλικοί φλοιοί συνδέονται μέσω του μεγάλου δέσμης νευρικών ινών, γνωστού ως μεσολόβιο. Τα εγκεφαλικά ημισφαίρια χωρίζονται σε αριστερό και δεξί ημισφαίριο. αποτελούν το μεγαλύτερο μέρος του εγκεφάλου. Κάθε ημισφαίριο ελέγχει την αντίθετη πλευρά του σώματος. Τα εγκεφαλικά ημισφαίρια περιέχουν στην επιφάνεια τους προεξοχές και αυλακώσεις "ρωγμές" που ονομάζονται έλικες και αύλακες. Οι μεγαλύτερες αύλακες διαιρούν τον εγκεφαλικό φλοιό σε αριστερό και δεξί ημισφαίριο. Κάθε ημισφαίριο έχει τέσσερις λοβούς: τον Μετωπιαίο, Βρεγματικό, Ινιακό, και Κροταφικό λοβό.

- **Κροταφικός λοβός:** Βρίσκεται κάτω από τον μετωπιαίο λοβό, χρησιμεύει για την ακοή και την όσφρηση. Έχει ρόλο στην αναγνώριση προσώπων και την αντίληψη της ομιλίας. Επίσης στον κροταφικό λοβό βρίσκεται ο ιππόκαμπος, εκεί βρίσκεται η έδρα της μνήμης και των φανταστικών εικόνων στα όνειρα. Σε περίπτωση βλάβης σε περιοχή του κροταφικού λοβού παρουσιάζονται προβλήματα που σχετίζονται με την αναγνώριση προσώπων, κατανόηση λέξεων, επιλεκτική προσοχή, αύξηση ή μείωση της σεξουαλικότητας, επιθετική συμπεριφορά, επίμονη ομιλία (μετά από βλάβη στο δεξιό κροταφικό λοβό), οσφρητικές και οπτικές ψευδαισθήσεις, συναισθήματα δέους και πανικού. Τα συνοδά κινητικά φαινόμενα περιλαμβάνουν παράξενους μορφασμούς, κινήσεις μάσησης κ.ά.
- **Ινιακός λοβός:** Βρίσκεται στο πίσω μέρος του εγκεφάλου. Είναι υπεύθυνος για την οπτική αντίληψη, συμπεριλαμβανομένου χρώματος της μορφής την επεξεργασία σχήματος, καθώς εκεί βρίσκεται ο οπτικός φλοιός, σε περίπτωση δυσλειτουργίας του ινιακού λοβού υπάρχει πιθανότητα τύφλωσης, αχρωματοψίας, δημιουργία παραισθήσεων και δυσκολία αντίληψης των κινήσεων.
- **Βρεγματικός λοβός:** Εντοπίζεται πάνω από τον κροταφικό και πίσω από τον μετωπιαίο λοβό. Ευθύνεται για την αντίληψη των αισθητήριων ερεθισμάτων από το σώμα καθώς περιλαμβάνει την αισθητική περιοχή που μπορεί να παρατηρηθεί στην Εικόνα 1.3. Επιπλέον συνεισφέρει στην επεξεργασία και αντίληψη των συναισθημάτων (άγχος, φόβος κ.α.). Βοηθάει στην αναγνώριση των μεγεθών, των σχημάτων, και την απόσταση των αντικειμένων. προσφέρει χωρική αλλά και οπτική αντίληψη. Δυσλειτουργία στον βρεγματικό λοβό μπορεί να προκαλέσει αδυναμία αναγνώρισης του περιβάλλοντα χώρου, διαταραχή στην αίσθηση και την αντίληψη, καθώς και διαταραχές στην ομιλία.


- **Μετωπιαίος λοβός:** Βρίσκεται στο μπροστινό μέρος του εγκεφάλου, ελέγχει το συνειδητό και το συναίσθημα. Ελέγχει την κρίση του ατόμου για ότι συμβαίνει στις καθημερινές δραστηριότητες, την γνώση του νοήματος των λέξεων που επιλέγει, την κίνηση των μυών στο σώμα και την έκφραση του λόγου. Ο μετωπιαίος φλοιός περιλαμβάνει τον προ-κινητικό φλοιό, τον πρωτεύοντα κινητικό φλοιό και τον συμπληρωματικό κινητικό φλοιό, οι οποίοι είναι μέρη του κινητικού φλοιού.



Εικόνα 1.2: Χάρτης λοβών εξωτερικής στοιβάδας του εγκεφαλικού φλοιού σε πλάγια προβολή εγκεφάλου. (Πηγή: [Βασικές Γνώσεις Ανατομίας του Εγκεφάλου \(pediatric-neurosurgery.com\)](http://www.pediatric-neurosurgery.com))

Ο κινητικός φλοιός όπως έχει αναφέρθηκε ελέγχει την κινητική λειτουργία του σώματος και βρίσκεται στον μετωπιαίο λοβό. Ο κινητικός φλοιός περιλαμβάνει τον προκινητικό φλοιό τον πρωτεύοντα κινητικό φλοιό και την συμπληρωματική κινητική περιοχή. Κύρια λειτουργία του κινητικού φλοιού είναι να δημιουργεί σήματα για να κατευθύνει την κίνηση του σώματος μέσω ηλεκτρικής διέγερσης. Η ηλεκτρική διέγερση ανάλογα την περιοχή του κινητικού φλοιού επιφέρει κινήσεις συγκεκριμένων μερών του σώματος.

Ο πρωτεύων κινητικός φλοιός συμβάλλει στη δημιουργία νευρικών ερεθισμάτων που διαμέσου του νωτιαίου μυελού ελέγχουν την εκτέλεση της κίνησης. Ο προκινητικός φλοιός βρίσκεται μπροστά από τον πρωτεύοντα κινητικό φλοιό. Η κύρια λειτουργία του είναι να κάνει την προετοιμασία και τον προγραμματισμό της κίνησης καθώς και για τις συντονισμένες δράσεις μυϊκών ομάδων. Η συμπληρωματική κινητική περιοχή του κινητικού φλοιού εμπλέκεται στον έλεγχο της κίνησης, στην σταθεροποίηση και τον συντονισμό της στάσης του σώματος. Στην παρακάτω εικόνα 1.3 παρατίθεται χάρτης σώματος κινητικού φλοιού και τις αισθητικής περιοχής. Παρατηρείται ότι κάθε περιοχή του εγκεφάλου ελέγχει συγκεκριμένη περιοχή στο σώμα.



Εικόνα 1.3: α. β Χάρτης μετωπιαίου και βρεγματικού λοβού.

(Πηγή: [9. NEYPIKO SYSTHMA \(ebooks.edu.gr\)](http://9.NEYPIKO.SYSTHMA(ebooks.edu.gr)))

1.2.2 Διάμεσος εγκέφαλος


Ο διάμεσος εγκέφαλος απαρτίζεται από δύο θαλάμους και τον υποθάλαμο. Οι θάλαμοι περιλαμβάνουν φαιά ουσία και αποτελούν κέντρο υποδοχής πληροφοριών από την περιφέρεια με κατεύθυνση προς τον εγκεφαλικό φλοιό των ημισφαιρίων, αλλά συνεισφέρουν και στη μετάδοση πληροφορίας από τα εγκεφαλικά ημισφαίρια προς την περιφέρεια. Ο υποθάλαμος αποτελεί βασικό όργανο ρύθμισης ζωτικών λειτουργιών, όπως η σίτιση, η διασφάλιση της ομοιόστασης, η ρύθμιση του κερκάρδιου ρυθμού, η ρύθμιση της θερμοκρασίας του ανθρώπινου σώματος, η αναπαραγωγή και ο μεταβολισμός.

1.2.3 Οπίσθιος εγκέφαλος

Ο οπίσθιος εγκέφαλος αποτελείται από την παρεγκεφαλίδα, την γέφυρα, και την τέταρτη κοιλία του εγκεφάλου (Εικόνα 1.4). Η παρεγκεφαλίδα εντοπίζεται κάτω από τον ινιακό λοβό, στο πίσω μέρος του εγκεφάλου. Αντιπροσωπεύει το 10% συνολικού βάρους και περιέχει το 80% όλων των νευρώνων του εγκεφάλου. Αποτελεί σημαντικό κέντρο ελέγχου συντονισμού κινήσεων και ελέγχου της στάσης και ισορροπίας του σώματος, συντονίζει τις κινήσεις των ματιών και

συμβάλλει σε κάποιες μορφές κινητικής εκμάθησης που απαιτούν εξάσκηση και τελειοποίηση. Λόγω της στενής σχέσης που έχει η παρεγκεφαλίδα με την κίνηση, διαταραχές σε αυτή μπορούν να προκαλέσουν έλλειψη μυϊκού ελέγχου καθώς και δυσκολίες συντονισμού στην κινητικότητα του σώματος αλλά και των ματιών. Επίσης άτομα με πρόβλημα στην παρεγκεφαλίδα ενδέχεται να έχουν δυσκολία στην ομιλία. Η γέφυρα είναι το μεσαίο τμήμα που συνδέει τον προμήκη με τον μέσο εγκέφαλο και τοποθετείται μπροστά από την παρεγκεφαλίδα, είναι πιο παχύς από το υπόλοιπο στέλεχος διότι περιέχει πολλούς πυρήνες και ίνες και αναδύονται πολλά εγκεφαλικά νεύρα. Ο μέσος εγκέφαλος συνδέει την γέφυρα με τον πρόσθιο εγκέφαλο.

Το εγκεφαλικό στέλεχος τοποθετείται πάνω από τον νωτιαίο μυελό, αποτελείται από τον μέσο εγκέφαλο, την γέφυρα και τον προμήκη μυελό που περιγράφεται παρακάτω. Η μεταφορά ερεθισμάτων μεταξύ νωτιαίου μυελού, παρεγκεφαλίδας, εγκεφαλικών ημισφαιρίων και διάμεσο εγκέφαλο επιτυγχάνεται μέσω νευρικών ινών δια μέσου του εγκεφαλικού στελέχους.



Εικόνα 1.4: Πρόσθιος-Οπίσθιος και Έσχατος εγκέφαλος.

(Πηγή: [latest \(440x299\) \(nocookie.net\)](https://www.nocookie.net/latest/440x299))

1.3 Επισκόπηση εγκεφαλικών κυττάρων

Ο ανθρώπινος εγκέφαλος περιέχει περίπου 100 δισεκατομμύρια νευρώνες, και 10 φορές περισσότερα νευρογλοιακά κύτταρα. Είναι η κύρια μονάδα του κεντρικού νευρικού συστήματος. Κάθε νευρώνας επικοινωνεί με χιλιάδες άλλους, με αποτέλεσμα να αποτελεί ένα ιδιαίτερα

περίπλοκο ζήτημα το πως ακριβώς λειτουργεί το νευρικό σύστημα. Οι νευρώνες εξειδικεύονται στην λήψη αλλά και αποστολή ηλεκτρικών σημάτων κατά μήκος της μεμβράνης.

Οι νευρώνες αποτελούνται από (Εικόνα 1.5):


- Το κυτταρικό σώμα
- Τους Δενδρίτες
- Το Νευροάξονα
- Τις Νευραξονικές απολήξεις.

Κυτταρικό σώμα: Αποτελεί το κυρίως μέρος του νευρώνα, είναι το μέρος που περιλαμβάνει τον πυρήνα του κυττάρου.

Δενδρίτες: Είναι διακλαδωμένες κυτταρικές προεξοχές που ξεκινούν από το κυτταρικό σώμα. Κάθε νευρώνας περιλαμβάνει πολλές διακλαδώσεις. Αποτελούν την είσοδο του νευρώνα για τη λήψη σήματος από άλλα νευρικά κύτταρα.

Νευροάξονας: Αποτελεί μέρος από το κυτταρικό σώμα και εμφανίζεται ως μια προεξοχή προς την έξοδο του νευρώνα. Ένας νευροάξονας μπορεί να έχει μήκος πάνω από ένα μέτρο. Ο νευροάξονας μεταφέρει τα ηλεκτρικά νευρικά σήματα στον νευρώνα. Επιπλέον μπορεί να διακλαδίζεται με αποτέλεσμα να πραγματοποιείται επικοινωνία με άλλους νευρώνες.

Νευραξονικές απολήξεις: Αποτελούν το σημείο που τελειώνει ο νευροάξονας. Στόχος τους είναι η ταχεία μετατροπή του ηλεκτρικού σήματος σε χημικό σήμα για την μετάδοση του σήματος.



Εικόνα 1.5: Σχηματικό διάγραμμα ενός τυπικού νευρικού κυττάρου

(Πηγή: [Νευρώνας - Βικιπαίδεια \(wikipedia.org\)](https://el.wikipedia.org/wiki/Νευρώνας))

1.3.1 Ομάδες-Τύποι νευρώνων

Με βάση την λειτουργία τους οι νευρώνες ταξινομούνται σε τρεις ομάδες: τους απαγωγούς, τους προσαγωγούς και τους διάμεσους νευρώνες.

- Οι απαγωγοί νευρώνες έχουν στόχο την μεταφορά της πληροφορίας από το νευρικό σύστημα προς τα δραστικά κύτταρα (μυς, αδένες) ή σε άλλους νευρώνες.
- Οι προσαγωγοί νευρώνες έχουν σκοπό τη λήψη και την αποστολή πληροφορίας από τους περιφερειακούς αισθητήρες του σώματος στο κεντρικό νευρικό σύστημα όπου και η πληροφορία καταλαμβάνει συνειδητό επίπεδο.
- Οι διάμεσοι νευρώνες τοποθετούνται μέσα στο κεντρικό νευρικό σύστημα, στόχος τους είναι η ανάλυση της πληροφορίας που παρέχουν οι προσαγωγοί νευρώνες και η μετάδοση της στους απαγωγούς νευρώνες.

1.3.2 Μετάδοση πληροφορίας νευρώνων

Η διάδοση της πληροφορίας μεταξύ νευρώνων επιτυγχάνεται μέσω των συνάψεων. Οι συνάψεις αποτελούν σημείο ένωσης δύο ή περισσότερων νευρώνων. Οι νευροαξονικές απολήξεις του νευρώνα που μεταδίδει το ερέθισμα (προσυναπτικός νευρώνας) βρίσκονται κοντά σε δενδρίτες νευρώνα που δέχεται το ερέθισμα (μετασυναπτικός νευρώνας). Το ερέθισμα που λαμβάνεται μπορεί να είναι ηλεκτρικό ή χημικό σήμα και μεταβάλλει την λειτουργία των νευρώνων καθώς μεταδίδεται. Οι χημικές συνάψεις αποτελούν την πλειοψηφία, είναι πιο αργές, αλλά ακριβέστερες σε σχέση με τις ηλεκτρικές.

1.4 Εγκεφαλικά δυναμικά


Ο ανθρώπινος εγκέφαλος μπορεί να θεωρηθεί σαν μία μπαταρία: τα ηλεκτρικά δυναμικά στον εγκέφαλο μεταβάλλονται συνεχώς και ανάλογα την εκάστοτε εγκεφαλική δραστηριότητα. Η καταγραφή των εγκεφαλικών δυναμικών συναρτήσει του χρόνου αποδίδει κυματομορφές. Η λήψη των ηλεκτρικών εγκεφαλικών σημάτων και κατά συνέπεια οι χαρακτηριστικές και τα μοτίβα των κυματομορφών επιτρέπουν στην διάγνωση μιας κατάστασης του εγκεφάλου ή στην περεταίρω συσχέτισης της συγκεκριμένης κατάστασης με άλλη γενικότερα γνωστή κατάσταση του εγκεφάλου (διάγνωση).

1.4.1 Δυναμικό ηρεμίας

Εγκεφαλικό δυναμικό ηρεμίας ονομάζεται το δυναμικό του νευρώνα όταν αυτός δεν δέχεται κάποιο ερέθισμα ή όταν δέχεται ερέθισμα αλλά με ένταση μικρότερη από μία οριακή τιμή. Το εγκεφαλικό δυναμικό ηρεμίας επέρχεται όταν υπάρχει μεγάλο αριθμό συγκέντρωσης ιόντων νατρίου (Na^+) στην εξωτερική επιφάνεια της κυτταρικής μεμβράνης του νευρώνα, ενώ στην εσωτερική επιφάνεια υπάρχει μεγάλος αριθμός συγκέντρωσης ιόντων καλίου (K^+) και αρνητικών ιόντων χλωρίου (Cl^-). Η μεμβράνη διατηρεί αυτή την άνιση κατανομή ιόντων με την βοήθεια μηχανισμού ενεργητικής μεταφοράς μεταξύ των δύο επιφανειών της, ο οποίος ονομάζεται «αντλία νατρίου-καλίου». Για κάθε τρία ιόντων νατρίου που απομακρύνει από το εσωτερικό του κυττάρου μεταφέρει ταυτόχρονα στο εσωτερικό δύο ιόντα καλίου, με αποτέλεσμα η εσωτερική επιφάνεια της μεμβράνης να είναι ηλεκτροαρνητικά φορτισμένη σε σχέση με την εξωτερική. Η διαφορά αυτή δημιουργεί ηλεκτρικό δυναμικό, το δυναμικό ηρεμίας, που είναι ίσο με -70 mV .

1.4.2 Δυναμικό ενέργειας ή δράσης νευρικού κυττάρου

Δυναμικό ενέργειας ονομάζεται το δυναμικό στο οποίο ο νευρώνας δέχεται κάποιο ερέθισμα ενός νευρικού κυττάρου σε κάποιο σημείο. Το δυναμικό ενέργειας ενός νευρώνα αποκαλείται και νευρική ώση. Όπως έχει ήδη αναφερθεί, το νευρικό κύτταρο είναι ήδη πολωμένο αρνητικά (-70 mV δυναμικό ηρεμίας). Όταν το κύτταρο δέχεται ερέθισμα, αυτό έχει ως αποτέλεσμα να μεταβάλλεται το δυναμικό της μεμβράνης του. Το δυναμικό στην μεμβράνη μπορεί να μειωθεί (Εκπόλωση) ή να αυξηθεί (Υπερπόλωση). Για να μεταδοθεί το ερέθισμα στους άλλους νευρώνες θα πρέπει η ηλεκτρική δραστηριότητα, δηλαδή το δυναμικό της μεμβράνης, να ξεπεράσει το κατώφλι δυναμικού (ουδός) το οποίο είναι περίπου στα -55 mV . Στην περίπτωση που το δυναμικό της μεμβράνης δεν ξεπεράσει το κατώφλι τάσης, θα προκύψουν υποκατώφλιες εκπολώσεις και τότε θα ακολουθήσει η επαναπόλωση, δηλαδή το δυναμικό θα τείνει να επιστρέψει στην ηρεμία και θα παραμείνει περιορισμένο στο σημείο του κυττάρου, στο οποίο εμφανίστηκε το ερέθισμα.



Εικόνα 1.6: Δυναμικό ηρεμίας & ενέργειας νευρικού κυττάρου

([Δυναμικό ενέργειας - Βικιπαίδεια \(wikipedia.org\)](https://el.wikipedia.org/wiki/Δυναμικό_ενέργειας))

1.5 Εγκεφαλικοί ρυθμοί


Οι εγκεφαλικοί ρυθμοί αποτελούν εναλλασσόμενες ηλεκτρικές τάσεις στον εγκέφαλο, οι οποίες μεταβάλλονται την ημέρα αλλά και τη νύχτα, κατά την διάρκεια των καθημερινών εργασιών. Τα νευρικά κύτταρα εκπέμπουν ηλεκτρικά σήματα που ονομάζονται και μοτίβα εγκεφαλικών κυμάτων. Τα μοτίβα συνδέονται με διάφορες καταστάσεις δραστηριότητας του εγκεφαλικού φλοιού όπως η μάθηση, η σκέψη, η χαλάρωση, ή η κίνηση. Υπάρχουν πέντε (5) εγκεφαλικοί ρυθμοί οι οποίοι χωρίζονται βάσει της συχνότητας που κυριαρχεί στις αντίστοιχες κυματομορφές. Οι συχνότητες κυμαίνονται από 0.5 Hz έως 100 Hz, και τμηματικά χωρίζονται σε ρυθμούς **δέλτα**, **θήτα**, **άλφα**, **βήτα**, και **γάμα** ή αλλιώς **δ**, **θ**, **α**, **β**, **γ** αντίστοιχα (βλ. Πίνακα 1.1).

Πίνακας 1.1: Κατανομή εγκεφαλικών ρυθμών κατά συχνότητα ζώνης κύματος.

Όνομα εγκεφαλικού ρυθμού	Συχνότητα κύματος ζώνης (Hz)
Δέλτα (δ)	0,5-4
Θήτα (θ)	5-7
Άλφα (α)	8-12

Βήτα (β)	13-30
Γάμα (γ)	>30


• **Ρυθμός α:** Ήταν ο πρώτος που ανακαλύφθηκε από τον Γερμανό ψυχίατρο Χανς Μπέργκερ. Ο ρυθμός άλφα περιλαμβάνει συχνότητες μεταξύ 8 Hz και 12 Hz (Εικόνα 1.7). Η δραστηριότητα του ρυθμού άλφα παράγεται στις βρεγματικές και ινιακές περιοχές του εγκεφάλου και συνδέεται με την κατάσταση εγκεφαλικής χαλάρωσης, π.χ. όταν το άτομο βρίσκεται σε ηρεμία ή έχει κλειστά τα μάτια. Στην περίπτωση ύπνου ή σκέψης, τα κύματα άλφα εξαφανίζονται.



Εικόνα 1.7: Δείγμα εγκεφαλικού ρυθμού άλφα διάρκειας 1 sec.

(Πηγή: [Electroencephalography - Wikipedia](#))


• **Ρυθμός β:** Είναι ο δεύτερος ρυθμός που μελετήθηκε και περιλαμβάνει της συχνότητες 13 Hz έως 30 Hz (Εικόνα 1.8). Ο ρυθμός βήτα εμφανίζεται σε περιπτώσεις που το άτομο είναι σε κατάσταση πλήρους συνείδησης και σε εγρήγορση, όπως συμβαίνει στη λήψη αποφάσεων ή όταν υπάρχει συναίσθημα άγχους και φόβου. Ο ρυθμός βήτα εμφανίζεται στην μετωπική περιοχή.



Εικόνα 1.8: Δείγμα εγκεφαλικού ρυθμού βήτα διάρκειας 1 sec.

(Πηγή: [Electroencephalography - Wikipedia](#))


• **Ρυθμός γ:** Περιλαμβάνει συχνότητες άνω των 30 Hz (Εικόνα 1.9). Ο ρυθμός γάμα εμφανίζεται κυρίως στην μάθηση και στην επεξεργασία πληροφορίας. Επιπλέον σχετίζεται με την ανώτερη πνευματική λειτουργία όπως η αντίληψη και η συνείδηση.



Εικόνα 1.9: Δείγμα εγκεφαλικού ρυθμού γάμα διάρκειας 1 sec.

(Πηγή: [Electroencephalography - Wikipedia](#))


• **Ρυθμός δ:** Περιλαμβάνει σε συχνότητες 0,5 Hz έως 4 Hz (Εικόνα 1.10). Τα κύματα δέλτα έχουν την χαμηλότερη συχνότητα από τα εγκεφαλικά κύματα που έχουν μετρηθεί στον άνθρωπο. Τα κύματα αυτά είναι διαδεδομένα όταν τα άτομα βρίσκονται σε κατάσταση χαλάρωσης και αποκατάστασης, δηλαδή σε επουλωτικό ύπνο, και κυριαρχούν στην παιδική ηλικία.



Εικόνα 1.10: Δείγμα εγκεφαλικού ρυθμού δέλτα διάρκειας 1 sec.

(Πηγή: [Electroencephalography - Wikipedia](#))

• **Ρυθμός θ:** Περιλαμβάνει συχνότητες 5 Hz έως 7 Hz (Εικόνα 1.11). Τα κύματα θήτα εντοπίζονται σε παιδιά αλλά και σε άτομα που βιώνουν καταστάσεις συναισθηματικής πίεσης ή βαθιάς σωματικής χαλάρωσης. Μπορούν επίσης να εμφανιστούν όταν το άτομο βρίσκεται σε κατάσταση διαλογισμού.



Εικόνα 1.11: Δείγμα εγκεφαλικού ρυθμού θήτα διάρκειας 1 sec.

(Πηγή: [Electroencephalography - Wikipedia](#))

ΚΕΦΑΛΑΙΟ 2: Επισκόπηση διεπαφών εγκεφάλου-υπολογιστή

2.1 Διεπαφές Εγκεφάλου-Υπολογιστή (Brain computer interface, BCI)

Οι Διεπαφές Εγκεφάλου-Υπολογιστή (Brain computer interface, BCI) ή αλλιώς διεπαφές εγκεφάλου-μηχανής είναι ειδικά ηλεκτρονικά συστήματα τα οποία επιτρέπουν την άμεση αλληλεπίδραση του ανθρώπου με εξωτερικές διατάξεις μέσω του εγκεφάλου. Ο έλεγχος των εξωτερικών διατάξεων μπορεί να πραγματοποιηθεί χωρίς να βασίζεται στο περιφερειακό νευρικό σύστημα και τους μύες του σώματος αλλά μέσω ειδικών μεθόδων καταγραφής εγκεφαλικής δραστηριότητας σε πραγματικό χρόνο.



Εικόνα 2.1: Διεπαφές εγκεφάλου-υπολογιστή για τον έλεγχο των κινήσεων και των ενεργειών ενός avatar στο διαδικτυακό παιχνίδι World of Warcraft από την Blizzard Entertainment, Inc.

(Πηγή: [BCI Integration: Application Interfaces | IntechOpen](#))

Σκοπός των BCI είναι η αναγνώριση πρόθεσης του χρήστη μέσω των ηλεκτροφυσιολογικών ή άλλων ειδών σημάτων του εγκεφάλου. Τα ηλεκτροφυσιολογικά σήματα μπορούν να καταγραφούν πάνω στο τριχωτό της κεφαλής, κάτω από το τριχωτό της κεφαλής ή μέσα στον εγκέφαλο. Διαφορετικοί τύποι φυσιολογικών σημάτων μπορούν να καταγραφούν με διαφορετικά μέσα (όπως μαγνητικούς αισθητήρες, κ.α.) Έτσι σε πραγματικό χρόνο τα εγκεφαλικά σήματα μεταφράζονται σε εξόδους, δηλαδή εντολές που πραγματοποιούν τις επιθυμίες του ατόμου.

Παράδειγμα χρήσης BCI φαίνεται στην εικόνα 2.1 όπου ο χρήστης εκτελεί έλεγχο κινήσεων avatar σε διαδικτυακό παιχνίδι.

2.2 Εφαρμογές Διεπαφών Εγκεφάλου-Υπολογιστή

Το BCI μπορεί να χρησιμοποιηθεί για διαφορετικούς σκοπούς, οπότε ο στόχος της εφαρμογής αντικατοπτρίζεται στον σχεδιασμό του αντίστοιχου συστήματος BCI. Οι εφαρμογές BCI μπορούν να χωριστούν σε δύο κατηγορίες:

- η πρώτη κατηγορία επικεντρώνεται κυρίως στην επεξεργασία της εγκεφαλικής δραστηριότητας μέσω ηλεκτροδίων για τον έλεγχο κάποιου εξωτερικού συστήματος, ενώ
- η δεύτερη κατηγορία επικεντρώνονται στην αναγνώριση της νοητικής και συναισθηματικής κατάστασης του ατόμου ώστε να συμπεριφερθεί κατάλληλα και ανάλογα με το περιβάλλον. Για παράδειγμα, μια τέτοια εφαρμογή θα μπορούσε να αναλύει τα εγκεφαλικά σήματα για να καταλάβει αν το άτομο έχει άγχος ή είναι «χαλαρό». Στη συνέχεια, η εφαρμογή θα μπορούσε να προσαρμόσει το περιβάλλον του ατόμου ή να παρέχει ανάδραση για να βοηθήσει το άτομο να χαλαρώσει.

Γενικότερα, το BCI επικεντρώνεται τόσο σε ιατρικές εφαρμογές όσο και σε μη ιατρικές εφαρμογές.

2.2.1 Ιατρικές εφαρμογές διεπαφών εγκεφάλου-υπολογιστή

Όπως έχει αναφερθεί και παραπάνω το μεγαλύτερο μέρος της έρευνας μέσω των BCI έχει επικεντρωθεί σε ιατρικές εφαρμογές. Πολλές έρευνες BCI στοχεύουν στην αποκατάσταση ή αντικατάσταση της λειτουργίας του κεντρικού νευρικού συστήματος (ΚΝΣ) του ασθενούς ή τραυματία, που έχει χαθεί λόγω ατυχήματος ή ασθένειας. Άλλες εφαρμογές επικεντρώνονται στην διάγνωση κάποιου προβλήματος, στην θεραπεία και στην κινητική αποκατάσταση. Άλλα BCI είναι πιο στενά στοχευμένα σε βιολογικούς σκοπούς. Χρησιμοποιούνται επίσης σε τομείς έρευνας συναισθηματικής κατάστασης του ατόμου, καθώς τα συναισθήματα ενός ατόμου μπορούν να παρατηρηθούν μέσω συστημάτων BCI. Περαιτέρω, υπάρχει και η δυνατότητα αλλαγής του περιβάλλοντος ανάλογα με τα συναισθήματα που διαπιστώνει το BCI ότι βιώνει το άτομο, για την βελτίωση των συναισθημάτων του. Επιπλέον οι βιοϊατρικές τεχνολογίες μπορούν να ελαχιστοποιήσουν παρατεταμένες περιόδους ασθένειας, παρέχουν επίβλεψη και προστασία ενδυναμώνοντας άτομα με κινητικές δυσκολίες.

2.2.2 Μη ιατρικές εφαρμογές διεπαφών εγκεφάλου-υπολογιστή

Οι περισσότερες από τις μη ιατρικές εφαρμογές του BCI αποτελούν ψυχαγωγικές εφαρμογές και εφαρμογές αναγνώρισης της συναισθηματικής κατάστασης (συναισθηματική υπολογιστική – affective computing). Στις ψυχαγωγικές εφαρμογές έμφαση δίνεται στα βιντεοπαιχνίδια, σε πολλές περιπτώσεις τα δεδομένα από την ανάλυση του ηλεκτροεγκεφαλογραφήματος βοηθούν τα παιχνίδια να γίνουν πιο ελκυστικά παρακολουθώντας το επίπεδο του ενθουσιασμού κάθε παίκτη, και προσαρμόζοντας δυναμικά τη δυσκολία του παιχνιδιού ανάλογα.

Το BCI βρίσκει εφαρμογές και στην βιομηχανική ρομποτική, αυξάνοντας την ασφάλεια των εργαζομένων, κρατώντας τους μακριά από απαιτητικές θέσεις εργασίας που είναι επικίνδυνες. Επιπλέον με την ερμηνεία των ηλεκτροεγκεφαλογραφημάτων μπορεί να ανιχνευτεί πότε ένα άτομο είναι πολύ κουρασμένο ή άρρωστο για να χειριστεί ένα μηχάνημα και μπορεί να λάβει τις απαραίτητες προφυλάξεις για την αποφυγή τραυματισμού, όπως για παράδειγμα τον τερματισμό λειτουργίας ενός μηχανήματος.

Επίσης εφαρμογές BCI μπορούν να βοηθήσουν και στις μεταφορές, παρακολουθώντας και αξιολογώντας την επίδοση αλλά και την βελτίωση της επίδοσης των οδηγών οχημάτων, από αυτοκίνητα μέχρι αεροπλάνα (ενδιαφέρον και για τις αεροπορικές εταιρίες). Παρόλα αυτά, λάθη τέτοιων συστημάτων μπορεί να είναι μοιραία, οδηγώντας σε απώλειες ανθρώπινων ζωών. Οι μη ιατρικές εφαρμογές αντιμετωπίζουν, όμως, μεγάλη δυσκολία ως προς τη σωστή λειτουργία τους, και μεγάλη πρόκληση, καθώς πρέπει να είναι ταυτόχρονα και ασφαλείς αλλά και αρεστές από τους χρήστες για να είναι εμπορικά επιτυχημένες.

2.3 Τεχνικές λήψεων εγκεφαλικού σήματος BCI

Η εγκεφαλική δραστηριότητα μπορεί να ερευνηθεί χρήση διαφορετικών τεχνικών. Ένας κύριος διαχωρισμός των διαφορετικών τεχνικών BCI μπορεί να γίνει βάση της επεμβατικότητας. Οι τεχνικές BCI μπορούν να χωριστούν στις **επεμβατικές**, τις **ημι-επεμβατικές** και τις **μη επεμβατικές**.

2.3.1 Επεμβατικές τεχνικές BCI

Οι επεμβατικές τεχνικές ΔΕΥ απαιτούν χειρουργική επέμβαση για την τοποθέτηση εξαρτημάτων στον εγκέφαλο. Αυτά τα εξαρτήματα είναι συνήθως μικροτσιπ ή εμφύτευση ηλεκτροδίων, ως αποτέλεσμα να παρέχεται η δυνατότητα καταγραφής δραστηριότητας μεμονωμένων νευρώνων. Στόχος των διεπαφών αυτών είναι η αποκατάσταση κάποιας λειτουργίας σε άτομα με σοβαρή παράλυση, για την καλύτερη ποιότητα ζωής. Η συγκεκριμένη τεχνική είναι αξιόπιστη καθώς τα σήματα λαμβάνονται από επίπεδα κάτω από το κρανίο, προσφέροντας καλύτερη αναλογία

σήματος προς θόρυβο και κατ' επέκταση καλύτερο εντοπισμό της εγκεφαλικής δραστηριότητας, παρόλα αυτά η χειρουργική επέμβαση τοποθέτησης/σύνδεσής τους μπορεί να αποτελέσει η ίδια ένα κίνδυνο για την ανθρώπινη ζωή. Μετά την χειρουργική επέμβαση, υπάρχει πιθανότητα να δημιουργηθούν ουλές ιστού προκαλώντας εξασθένηση των εγκεφαλικών σημάτων. Επιπλέον χρειάζεται μεγάλη ανθρώπινη προσπάθεια και ανθρώπινες δεξιότητες οι οποίες συνεπάγονται με μεγαλύτερο κόστος για την επίτευξη της επιθυμητής αποτελεσματικότητας.

2.3.2 Μερικώς επεμβατικές τεχνικές BCI

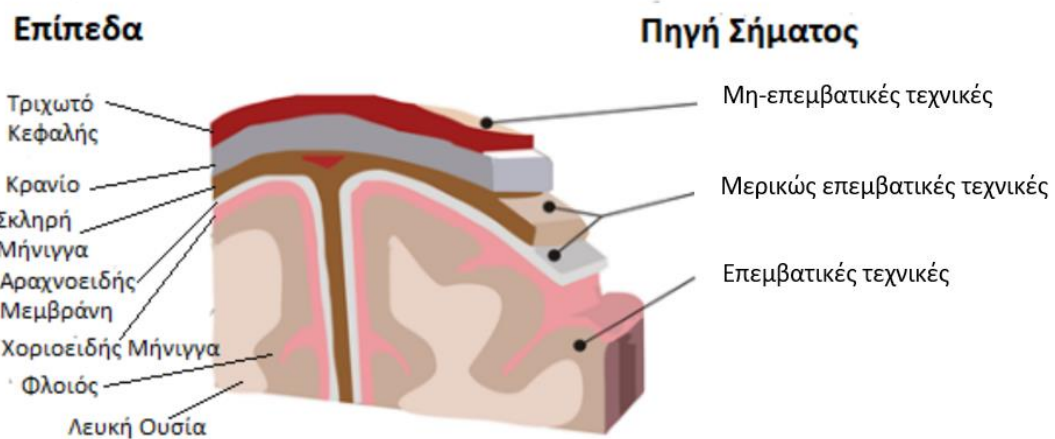
Οι μερικώς επεμβατικές τεχνικές περιλαμβάνουν τοποθέτηση εξαρτημάτων εντός του κρανίου, αλλά δεν διεισδύουν τόσο βαθιά όσο οι επεμβατικές τεχνικές ΔΕΥ. Απαιτούν χειρουργική επέμβαση όπως και οι επεμβατικές, βέβαια. Παρόλα αυτά τα εγκεφαλικά σήματα που λαμβάνονται είναι καλύτερης ποιότητας από τις μη επεμβατικές τεχνικές, ο κίνδυνος της χειρουργικής επέμβασης είναι μικρότερος από τις επεμβατικές τεχνικές. Η ηλεκτροκορτικογραφία, παραδείγματος χάριν, αποτελεί μερικώς επεμβατική τεχνική η οποία κάνει λήψη σήματος μέσω ηλεκτροδίων που τοποθετούνται στην εκτεθειμένη επιφάνεια του εγκεφάλου για την μέτρηση της ηλεκτρικής δραστηριότητας του εγκεφαλικού φλοιού.

2.3.3 Μη επεμβατικές τεχνικές BCI

Οι μη επεμβατικές τεχνικές αποτελούν την πλειονότητα των δημοσιευμένων ερευνητικών εργασιών ΔΕΥ. Οι αισθητήρες των μη επεμβατικών τεχνικών τοποθετούνται στο τριχωτό της κεφαλής για την μέτρηση των εγκεφαλικών δυναμικών. Στις μη επεμβατικές τεχνικές, οι μέθοδοι καταγραφής της εγκεφαλικής δραστηριότητας περιλαμβάνουν:τα

- τη Μαγνητοεγκεφαλογραφία (MEG) όπου οι αισθητήρες καταγράφουν τα μαγνητικά πεδία που παράγονται από τα ηλεκτροσήματα στον εγκέφαλο,
- τη λειτουργική απεικόνιση μαγνητικού συντονισμού (fMIR), όπου βασίζεται στο επίπεδο οξυγόνωσης του αίματος στις μεταβολές της συγκέντρωσης της αιμοσφαιρίνης,
- τη χρήση της φασματοσκοπίας κοντά στο υπέρυθρο (fNIR) που βασίζεται στις αιμοδυναμικές αποκρίσεις που σχετίζονται με τη νευρική συμπεριφορά από την διαφορά στα χαρακτηριστικά απορρόφησης της οξυγονωμένης και αποξυγονωμένης αιμοσφαιρίνης, καιτέλος,
- το ηλεκτροεγκεφαλογράφημα (EEG), όπου τοποθετούνται ηλεκτρόδια σε διάφορες περιοχές στο τριχωτό της κεφαλής για την μέτρηση των ηλεκτρικών δυναμικών που αναπτύσσονται στο εσωτερικό του.

Αυτές οι τεχνικές περιλαμβάνουν χαμηλή χωρική και χρονική ανάλυση και χαμηλή αναλογία σήματος προς θόρυβο (SNR), έχουν λιγότερο κόστος, ενώ είναι ασφαλέστερες καθώς δεν περιλαμβάνουν χειρουργική επέμβαση.



Εικόνα 2.2: Σημεία καταγραφής σήματος για τις τεχνικές ΔΕΥ

(Πηγή: [layers.png \(611×285\) \(neurotechedu.com\)](#))

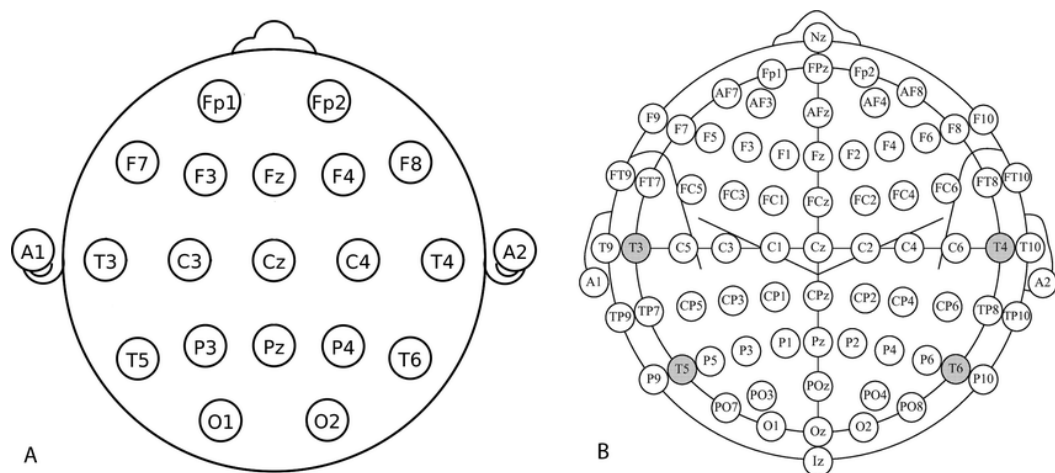
2.4 Το Ηλεκτροεγκεφαλογράφημα (electroencephalogram, EEG)

Το ηλεκτροεγκεφαλογράφημα αποτελεί την πιο συχνή και παλαιότερη μη επεμβατική τεχνική, λόγω του χαμηλού κόστους και της συνολικής αποτελεσματικότητας της απεικόνισης της ηλεκτρικής δραστηριότητας του εγκεφάλου. Ο ρόλος του ηλεκτροεγκεφαλογράφηματος είναι η καταγραφή της ηλεκτρικής δραστηριότητας που συμβαίνει μέσα στον εγκέφαλο με χρήση ηλεκτροδίων που τοποθετούνται εξωτερικά, στο τριχωτό της κεφαλής. Τα εγκεφαλικά κύτταρα επικοινωνούν μεταξύ τους μέσω ηλεκτρικών ερεθισμάτων που ανταλλάσσουν, εκμεταλλευόμενα τις συνάψεις τους, δηλαδή τα σημεία επαφής και σύνδεσης των νευρώνων μεταξύ τους. Σημαντικό είναι ότι παραμένουν ενεργά όλη την ώρα, ακόμη και κατά τον ύπνο. Τα ηλεκτρικά δυναμικά αντιπροσωπεύουν ακριβώς αυτά τα μετασυναπτικά δυναμικά των νευρώνων. Αξίζει να σημειωθεί ότι η ηλεκτροεγκεφαλογραφία υποφέρει κυρίως διότι είναι ευαίσθητη στο θόρυβο, καθώς μεταξύ του ίδιου του σήματος και του αισθητήρα που το καταγράφει μεσολαβούν στρώματα δέρματος και οστού. Επιπλέον ακριβώς επειδή υπάρχει μεγάλη εξασθένηση του σήματος και πτώση του το σηματοθορυβικού λόγου (SNR) λόγω του ανθρώπινου κρανίου, απαιτείται η ταυτόχρονη ενεργοποίηση πολλών νευρώνων για να προκύψει μετρήσιμο σήμα – πράγμα το οποίο επιτυγχάνεται χάρη στην επικοινωνία μεταξύ των νευρώνων.

2.4.1 Διατάξεις Ηλεκτροεγκεφαλογραφίας

Υπάρχουν αρκετές διατάξεις που ορίζουν πώς ακριβώς γίνεται η τοποθέτηση των ηλεκτροδίων για την καταγραφή της ηλεκτρικής δραστηριότητας πάνω στο τριχωτό της κεφαλής, ενώ κάθε ηλεκτρόδιο με την σειρά του παρέχει ένα «κανάλι» ηλεκτροεγκεφαλικού σήματος. Κάθε διάταξη περιλαμβάνει τουλάχιστον 3 ηλεκτρόδια, καθώς γίνεται η καταγραφή της διαφοράς δυναμικού του εκάστοτε ηλεκτροδίου με ένα ηλεκτρόδιο αναφοράς, και για την μέτρηση της διαφοράς δυναμικού είναι αναγκαίο ένα ηλεκτρόδιο γείωσης. Ανάλογα την εφαρμογή ορίζονται και τα απαραίτητα ηλεκτρόδια που χρειάζονται.

Η διάταξη 10-20 είναι μία διεθνώς αναγνωρισμένη μέθοδος που χρησιμοποιεί ανατομικά χαρακτηριστικά της κεφαλής για να καθορίσει την τοποθέτηση των ηλεκτροδίων. Το σύστημα βασίζεται στη σχέση μεταξύ της θέσης του κάθε ηλεκτροδίου και της υποκείμενης περιοχής του εγκεφαλικού φλοιού, διασφαλίζοντας ταυτόχρονα ότι καλύπτονται όλες οι περιοχές του εγκεφάλου. Εκτός από το σύστημα 10-20, υπάρχουν και άλλα συστήματα υψηλότερης ανάλυσης όπως το σύστημα 10-10. Αυτά τα συστήματα αποτελούν επέκταση του αρχικού συστήματος 10-20 όπου και χρησιμοποιούνται πρόσθετα ηλεκτρόδια μεταξύ του βασικού συστήματος 10-20, για μέτρηση της επιφάνειας του εγκεφάλου με υψηλότερη πυκνότητα.



Εικόνα 2.3: Διάταξη ηλεκτροδίων του διεθνούς συστήματος 10-20 (A) και 10-10 (B) για καταγραφή ηλεκτροεγκεφαλογραφίας. Οι περιττοί αριθμοί ηλεκτροδίων βρίσκονται στο αριστερό ημισφαίριο, οι ζυγοί αριθμοί ηλεκτροδίων στο δεξί ημισφαίριο. Τα γράμματα αντιστοιχούν στους λοβούς-F(rontal), T(emporal), P(arietal) και O(ccipital). Τέλος το γράμμα C σημαίνει κέντρο. (Πηγή:

<https://pubmed.ncbi.nlm.nih.gov/27014511/#&gid=article-figures&pid=figure-1-uid-0>)

2.5 Πρότυπα εγκεφαλικής δραστηριότητας σχεδιασμού BCI

Τα τρία κύρια πρότυπα εγκεφαλικής δραστηριότητας που χρησιμοποιούνται για τον σχεδιασμό BCI είναι

- ο Αποσυγχρονισμός/Συγχρονισμός που σχετίζεται με συμβάντα (Event-Related Desynchronization or Synchronization, ERD/ERS),
- τα δυναμικά που σχετίζονται με συμβάντα (Event Related Potentials, ERPs) και
- τα προκλητικά δυναμικά σταθερής κατάστασης (Steady State Evoked Potentials, SSEP).

2.5.1 Event-Related Desynchronization or Synchronization (ERD/ERS)

Ο Αποσυγχρονισμός/Συγχρονισμός (ERD/ERS) που σχετίζεται με συμβάντα αντιστοιχεί σε αυξομειώσεις πλάτους των ταλαντώσεων των σημάτων EEG. Ο αποσυγχρονισμός (ERD) αντιστοιχεί σε νευρώνες του εγκεφάλου που ενεργοποιούνται με πιο αποσυγχρονισμένο τρόπο σε σχέση με την κατάσταση ηρεμίας, δηλαδή προκύπτει μικρότερο πλάτος ταλάντωσης στα σήματα EEG. Αντίθετα ο συγχρονισμός αντιστοιχεί σε νευρώνες του εγκεφάλου που ενεργοποιούνται συγχρονισμένα (ERS), δηλαδή προκύπτει μεγαλύτερο πλάτος ταλάντωσης στα σήματα EEG. Ο Αποσυγχρονισμός/Συγχρονισμός παρατηρείται κατά την διάρκεια νοητικών εργασιών και χρησιμοποιείται ως οδηγός για την μετάφραση εντολών εφαρμογών BCI, Όπως στην νοητική απεικόνιση κινητικών δράσεων (motor imagery) και τα σήματα που λαμβάνονται είναι αυθόρμητα.

2.5.2 Δυναμικά σχετιζόμενα με συμβάντα (Event-related Potentials, ERPs)

Τα ERPs είναι μικρές διακυμάνσεις τάσης και είναι χρονικά κλειδωμένες με ένα συμβάν. Το συμβάν μπορεί να σχετίζεται με αισθητηριακό, γνωστικό ή κινητικό γεγονός, δηλαδή ερέθισμα που δέχεται το υποκείμενο, και η αντίδραση σ' αυτό συμβαίνει και καταγράφεται ως σήμα μέσα σε ένα συγκεκριμένο και πολύ μικρό χρονικό παράθυρο μετά το ερέθισμα (συμβάν). Πιο συγκεκριμένα τα ERPs είναι οποιαδήποτε στερεότυπη ηλεκτροφυσιολογική απόκριση τάσης σε ένα ερέθισμα. Το ERP λαμβάνεται με την καταγραφή των EEG και στη συνέχεια υπολογίζοντας τον μέσο όρο πολλαπλών χρονικών τμημάτων που αντιστοιχούν σε κάποιο συμβάν ενδιαφέροντος. Το πλάτος, η καθυστέρηση και η τοπογραφία των θετικών και αρνητικών παραμορφώσεων που προκύπτουν πάνω στην κυματομορφή του EEG, ως απόκριση στο ερέθισμα/συμβάν, λαμβάνονται υπόψη για την κατηγοριοποίηση των αντιδράσεων του εγκεφάλου στα διάφορα συμβάντα ενδιαφέροντος. Τα ERP χρησιμοποιούνται συχνότερα για έρευνα παρά για την κλινική διάγνωση. Δύο βασικά χαρακτηριστικά των ERP είναι ο χρόνος καθυστέρησης μεταξύ του συμβάντος και του σημείου κορύφωσης όπως διακρίνεται μέσα στο

σήμα, καθώς και η τιμή του πλάτους της αιχμής αυτής, δηλαδή πόση ώρα μετά το ερέθισμα κορυφώθηκε η αντίδραση σ' αυτό, και πόσο μεγάλη ήταν αυτή η αντίδραση.

2.5.3 Προκλητά δυναμικά σταθερής κατάστασης (SSEP)

Τα SSEP είναι μια αντικειμενική, μετρήσιμη διακύμανση της ηλεκτρικής δραστηριότητας που εμφανίζεται στον εγκέφαλο ως απόκριση σε ένα συγκεκριμένο σύνολο οπτικών ερεθισμάτων και είναι μετρήσιμη με χρήση των σημάτων EEG. Τα SSEP μετρούνται όταν το άτομο αντιλαμβάνεται *περιοδικά* ερεθίσματα και ορίζονται από μία αύξηση της ισχύος EEG στη συχνότητα του ερεθίσματος. Όταν το ερέθισμα παρουσιάζεται σε μια σταθερή συχνότητα, το EEG μπορεί να εντοπίσει τις εγκεφαλικές αποκρίσεις που συμβαίνουν συγχρονισμένα με την ίδια αυτή συχνότητα. Οι αποκρίσεις αντιπροσωπεύουν την εγκεφαλική δραστηριότητα ως απόκριση στο ερέθισμα.


2.6 Κινητική φαντασίωση (Motor imagery)

Ο όρος κινητική φαντασίωση (Motor Imagery, MI) αναφέρεται στη νοητική προσομοίωση των κινήσεων του σώματος. Πιο συγκεκριμένα η κινητική φαντασίωση αντιπροσωπεύει τη συνειδητή πρόσβαση στο περιεχόμενο μιας κίνησης, η οποία είναι λειτουργικά ισοδύναμη με τον ασυνείδητο κινητικό σχεδιασμό, δηλαδή είναι μια νοητική διαδικασία κατά την οποία το άτομο προσομοιώνει μία κινητική ενεργεία στο μυαλό νιώθοντας ότι εκτελεί τη δράση για να καταγραφεί η ενέργεια στο ΗΕΓ. Η κινητική φαντασίωση ενεργοποιεί μεταξύ άλλων τους νευρώνες στον αισθητήριο αλλά και στον κινητικό φλοιό. Πριν και κατά την διάρκεια εκτελέσεις νοητικών κινητικών φαντασιώσεων (κίνηση ποδιών, χεριών, γλώσσας) από τον χρήστη, παρατηρείται μείωση εγκεφαλικής δραστηριότητας (ERD). Με την ολοκλήρωση της διαδικασίας, η εγκεφαλική δραστηριότητα επιστρέφει στην αρχική της μορφή με την διαδικασία συγχρονισμού (ERS).

ΚΕΦΑΛΑΙΟ 3: Συστήματα διεπαφών εγκεφάλου-υπολογιστή

3.1 Βασική δομή διεπαφών εγκεφάλου υπολογιστή

Στόχος των συστημάτων διεπαφής εγκεφάλου-υπολογιστή (ΔΕΥ) είναι η σωστή μετάφραση ενός εγκεφαλικής δραστηριότητας για την σωστή υλοποίηση ενός εφαρμογής για την οποία έχουν δημιουργηθεί. Για την σωστή μετάφραση, τα συστήματα ΔΕΥ αποτελούνται από μία βασική δομή. Η βασική δομή ενός φαίνεται και από την παρακάτω Εικόνα 3.1 αποτελείται από το στάδιο συλλογής των δεδομένων, την προ-επεξεργασία των σημάτων, την εξαγωγή χαρακτηριστικών, την ταξινόμηση και τον έλεγχο ενός συσκευής.



Εικόνα 3.1: Βασική δομή ενός BCI συστήματος. (Πηγή:

https://www.researchgate.net/publication/340106984_Recent_Trends_and_Open_Challenges_in_EEG_Based_Brain-Computer_Interface_Systems)

3.2 Καταγραφή εγκεφαλικής δραστηριότητας

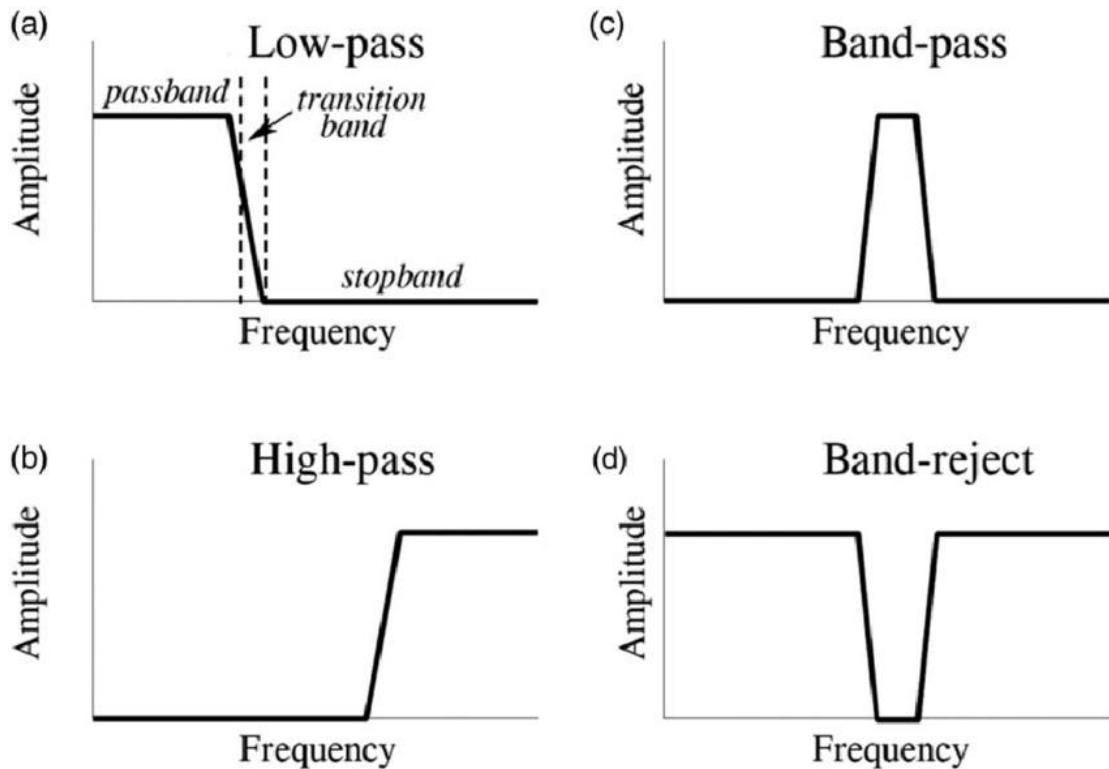
Το πρώτο στάδιο ενός συστήματος BCI είναι η καταγραφή της εγκεφαλικής δραστηριότητας μέσω λήψης και αποτύπωσης των εγκεφαλικών σημάτων. Η διαδικασία εξαρτάται από την τεχνική BCI που χρησιμοποιείται, συνήθως πραγματοποιείται μέσω της ηλεκτρο-εγκεφαλογραφίας με χρήση ηλεκτροδίων όπως έχει αναφερθεί. Η εγκεφαλική δραστηριότητα συλλέγεται ακατέργαστη, περιέχει θόρυβο, ανεπιθύμητες πληροφορίες και απαιτείται επεξεργασία για την εξαγωγή της επιθυμητής πληροφορίας. Για αυτό τον λόγο υπάρχει το δεύτερο στάδιο που είναι η προ-επεξεργασία του σήματος. Τα σήματα τα οποία συλλέγονται δεν είναι τυχαία, σε κάθε πείραμα (συνεδρία) που πραγματοποιείται το άτομο υλοποιεί δοκιμές (trials), δηλαδή εργασίες τις οποίες εφαρμόζει βάση κάποιων οδηγιών που του δίνονται.

3.3 Προ-επεξεργασία σήματος

Η προ-επεξεργασία του σήματος έχει στόχο την ανάδειξη της επιθυμητής πληροφορίας, την απομάκρυνση του θορύβου αλλά και την εκκαθάριση από ανεπιθύμητες πληροφορίες που περιέχει το σήμα. Αρχικά το σήμα ενισχύεται, η ενίσχυση του σήματος είναι ένα απαραίτητο βήμα για την αύξηση του λόγου σήματος προς θόρυβο (Signal-to-noise ratio, SNR) για να βοηθήσει στη διαφοροποίηση του σήματος του εγκεφάλου από τον θόρυβο. Έπειτα πραγματοποιείται δειγματοληψία για την μετατροπή του σήματος από αναλογική σε ψηφιακή μορφή (A/D conversion) για ευκολότερη επεξεργασία. Το στάδιο αυτό συνήθως πραγματοποιείται χωρίς μεγάλη απώλεια ακρίβειας. Τέλος πραγματοποιείται φιλτράρισμα του σήματος. Το φιλτράρισμα ανεπιθύμητων συχνοτήτων είναι ένα ουσιαστικό βήμα για όλα τα συστήματα. Ανάλογα το επιθυμητό εύρος (ζώνη) συχνοτήτων για τα σήματα του εγκεφάλου, εφαρμόζονται πάνω τους τα κατάλληλα φίλτρα για να αφαιρεθούν όλες οι άλλες συχνότητες, έξω από το επιθυμητό εύρος. Θόρυβος και ανεπιθύμητες παρεμβολές στα καταγεγραμμένα σήματα που περιλαμβάνουν υψηλές συχνότητες είναι εύκολο να εντοπιστούν και να αφαιρεθούν από το EEG καθώς τα εγκεφαλικά σήματα είναι κυρίως χαμηλών συχνοτήτων. Τα φίλτρα που χρησιμοποιούνται είναι φίλτρα «0-1» δηλαδή «Pass/No Pass», τα οποία είτε αποκόπτουν κάποιο εύρος συχνοτήτων είτε το αφήνουν να διέλθει εντελώς αναλλοίωτο. Πιο συγκεκριμένα τα φίλτρα που χρησιμοποιούνται είναι τα Υψιπερατά, τα Βαθυπερατά, τα Ζωνοπερατά και τα Ζωνοφρακτικά ή Φίλτρα απόρριψης ζώνης.

- Τα Υψιπερατά φίλτρα (High-pass filters) επιτρέπουν την διέλευση των σημάτων με συχνότητα μεγαλύτερη από μια ορισμένη συχνότητα αποκοπής ω_c και αποκόπτουν (στην πράξη, εξασθενούν ισχυρά) σήματα με συχνότητες χαμηλότερες από τη συχνότητα αποκοπής, $|\omega| < \omega_c$.
- Τα Βαθυπερατά φίλτρα (Low-pass filters) επιτρέπουν την διέλευση των σημάτων με συχνότητα χαμηλότερη από μια ορισμένη συχνότητα αποκοπής ω_c και αποκόπτουν (στην πράξη, εξασθενούν ισχυρά) σήματα με συχνότητες υψηλότερες από τη συχνότητα αποκοπής, $|\omega| > \omega_c$.
- Τα Ζωνοπερατά φίλτρα (Band-pass filters) σχηματίζονται με τον συνδυασμό ενός βαθυπερατού και υψιπερατού φίλτρου με διαφορετικές συχνότητες αποκοπής. Ουσιαστικά το φίλτρο αυτό επιτρέπει τη διέλευση σημάτων που ανήκουν σε ένα συγκεκριμένο εύρος συχνοτήτων, ενώ όποια συχνότητα δεν ανήκει σε αυτό το εύρος αποκόπτεται, $\omega_{c1} \leq |\omega| \leq \omega_{c2}$. Το εύρος συχνοτήτων προσδιορίζεται από δύο συχνότητες αποκοπής ω_{c1} , ω_{c2} .

- Τα Ζωνοφρακτικά Φίλτρα ή Φίλτρα απόρριψης ζώνης (Band-reject ή Band-stop filters) λειτουργούν αντίθετα με τα ζωνοπερατά, αποκόπτουν (στην πράξη, εξασθενούν ισχυρά) ένα συγκεκριμένο εύρος συχνοτήτων, ενώ αφήνουν να διέλθει όποια συχνότητα δεν ανήκει σε αυτό το εύρος. Το εύρος των συχνοτήτων που αποκόπτονται (εξασθενούν ισχυρά) ορίζεται από τις δύο συχνότητες αποκοπής $\omega_{c1} \leq \omega \leq \omega_{c2}$.



Εικόνα 3.2: Τα τέσσερα κοινά φίλτρα (α) Χαμηλοπερατό φίλτρο, (β) Υψηλοπερατό φίλτρο, (γ) Ζωνοπερατό φίλτρο. (δ) Ζωνοφρακτικό (Φίλτρο απόρριψης ζώνης).

(Πηγή: https://www.researchgate.net/publication/315801831_Evaluation_of_arterial_stiffness_by_finger-toe_pulse_wave_velocity_optimization_of_signal_processing_and_clinical_validation)

Στο πεδίο της συχνότητας, τα γραμμικά και χρονικά αμετάβλητα (ΓΧΑ, LTI) ψηφιακά φίλτρα έχουν ρητή συνάρτηση μεταφοράς (πηλίκο δύο πολωνύμων), που δίνεται παρακάτω:

$$H(z) = \frac{b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_M z^{-M}}{1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_N z^{-N}} = \frac{\sum_{k=0}^M b_k z^{-k}}{1 + \sum_{k=1}^N a_k z^{-k}} \quad (3.1)$$

Στο πεδίο του χρόνου, οι συντελεστές του πολωνύμου του αριθμητή b_k και οι συντελεστές του πολωνύμου παρανομαστή a_k μπορούν να χρησιμοποιηθούν για τον υπολογισμό των δεδομένων εξόδου $y(n)$ έχοντας ως γνωστά τα δείγματα του σήματος εισόδου $x(n)$ έως και κάθε στιγμή n :

$$y(n) = b_0 x(n) + \dots + b_M x(n-M) - a_1 y(n-1) - \dots - a_N y(n-N) \quad (3.2)$$

$$y(n) = \sum_{k=0}^M b_k x(n-k) - \sum_{k=0}^M a_k y(n-k) \quad (3.3)$$

Όπως φαίνεται στη σχέση 3.3, η έξοδος την χρονική στιγμή n καθορίζεται από

(α) το άθροισμα των συντελεστών b_k του αριθμητή οι οποίοι πολλαπλασιάζονται με τις προηγούμενες τιμές της εισόδου $x(n-k)$, και

(β) το άθροισμα των συντελεστών του παρονομαστή a_k που πολλαπλασιάζονται με τις προηγούμενες τιμές τις εξόδου $y(n-k)$.

Τα ψηφιακά φίλτρα χωρίζονται σε δύο βασικές κατηγορίες, στα φίλτρα πεπερασμένης κρουστικής απόκρισης (Finite Impulse, FIR) και στα φίλτρα κρουστικής απόκρισης άπειρου μήκους (Infinite Impulse Response, IIR).

Ένα FIR φίλτρο περιγράφεται στο πεδίο του χρόνου από την εξίσωση διαφορών:

$$y(n) = \sum_{k=0}^M b_k x(n-k) \quad (3.4)$$

όπου $x(n)$ είναι το σήμα εισόδου, $y(n)$ το σήμα εξόδου, M ο αριθμός συντελεστών του φίλτρου, και b_k είναι οι συντελεστές του αριθμητή της συνάρτησης μεταφοράς του φίλτρου. Ταυτόχρονα, στα FIR φίλτρα, ο κάθε συντελεστής b_k αποτελεί και την τιμή της κρουστικής απόκρισης στην k -οστή στιγμή για $0 < k < M$ ενός φίλτρου τάξης M .

Ένα IIR φίλτρο περιγράφεται από την εξίσωση διαφορών:

$$y(n) = \sum_{k=0}^M b_k x(n-k) - \sum_{k=0}^N a_k y(n-k) \quad (3.5)$$

Η διαφορά των δύο ψηφιακών φίλτρων, είναι ότι τα FIR φίλτρα δεν χρησιμοποιούν τις προηγούμενες τιμές εξόδου $y(n-k)$ μέσω των συντελεστών a_k παρά μόνο τις προηγούμενες τιμές εισόδου $x(n-k)$ μέσω των συντελεστών b_k . Αντίθετα, ένα IIR φίλτρο για να υπολογίσει την τρέχουσα τιμή εξόδου $y(n)$ χρησιμοποιεί και τις προηγούμενες τιμές εξόδου, $y(n-k)$, μέσω των συντελεστών a_k αλλά και τις προηγούμενες τιμές εισόδου, $x(n-k)$, μέσω των συντελεστών b_k . Οι συντελεστες a_k του παρανομαστή της συνάρτησης μεταφοράς του φίλτρου εκφράζουν το πόσο επηρεάζεται η τιμή της εξόδου $y(n)$ από τις προηγούμενες τιμές της, $y(n-k)$.

Τα IIR φίλτρα θεωρούνται υπολογιστικά πιο αποδοτικά από τα FIR, και συνιστώνται μόνο όταν απαιτείται υψηλή απόδοση και οξείες, απότομες αποκοπές στη ζώνη των συχνοτήτων. Τα FIR

φίλτρα είναι πιο εύκολα στον χειρισμό τους και είναι πάντα ευσταθή, αν και γενικά τείνουν να απαιτούν μεγαλύτερη τάξη φίλτρου για δεδομένες προδιαγραφές, και να εισάγουν συνεπώς σημαντική χρονοκαθυστέρηση.

Η εγκεφαλική δραστηριότητα που λαμβάνεται περιέχει κυρίως χαμηλές συχνότητες. Συνήθως χρησιμοποιείται ζωνοπερατό φίλτρο ώστε να ορίζεται η ζώνη διέλευσης αποκόποντας τις ανεπιθύμητες συχνότητες και τον θόρυβο. Μαζί χρησιμοποιείται και ένα φίλτρο εγκοπής (notch) (ζωνοφρακτικό με πολύ στενή ζώνη αποκοπής), στα 50/60 Hz για Ευρώπη/ΗΠΑ, για την αφαίρεση παρεμβολών των καλωδίων ισχυρών ρευμάτων που είναι κοντά στην διάταξη καταγραφής.

3.4 Εξαγωγή χαρακτηριστικών

Η εξαγωγή χαρακτηριστικών (feature extraction) αποτελεί το τρίτο στάδιο των συστημάτων BCI. Στοχεύει στην επεξεργασία του σήματος για την εξαγωγή μετρήσιμων ποσοτήτων (των παραμέτρων) που αντιπροσωπεύουν καλύτερα και πιο συνοπτικά, σε πιο 'οικονομική' μορφή, την πληροφορία του σήματος και έτσι επιτυγχάνουν τη μείωση της διάστασης των δεδομένων (προβολή σε χώρο χαμηλότερης διάστασης, π.χ. προβολή δεδομένων 3D σε 2D) αλλά και του όγκου τους (συμπίεση) με ελάχιστη απώλεια ποιότητας. Η εξαγωγή χαρακτηριστικών επιλέγεται έτσι ώστε τα εγκεφαλικά σήματα που έρχονται από καταγραφές ίδιας εγκεφαλικής κατάστασης να έχουν κοινά σημεία, και ταυτόχρονα να είναι διαφορετικά από τα σήματα διαφορετικών εγκεφαλικών καταστάσεων. Αφού εξαχθούν, τα χαρακτηριστικά αυτά αντιπροσωπεύουν και συνεπώς αντικαθιστούν το σήμα, δηλαδή τα ερωτήματα απαντώνται αναλύοντας πλέον τα χαρακτηριστικά, αντί για το ίδιο το σήμα.

Ανάλογα το πεδίο ανάλυσης των σημάτων, τα εξαγόμενα χαρακτηριστικά μπορούν να χωριστούν σε τρεις κατηγορίες,

- την **χρονική αναπαράσταση**, η οποία είναι η απλούστερη μορφή πληροφοριών που περιλαμβάνει παραμέτρους όπως τον μέσο όρο του πλάτους των δειγμάτων του σήματος, τη διακύμανση και την ασυμμετρία, και άλλα ανάλογα στατιστικά περιγραφικά μεγέθη,
- την **συχνοτική αναπαράσταση** που υποδυκνύει αλλαγές του σήματος ως προς την συχνότητα, ουσιαστικά δείχνοντας πώς αναλύεται η ισχύς του σήματος στις διάφορες συχνότητες (φάσμα ισχύος).
- τα **χωρικά χαρακτηριστικά** που εξάγονται από την αλληλεπίδραση πολλών καναλιών σήματος μεταξύ τους, και συνήθως απαιτούν κάποιο είδος προεπεξεργασίας με χρήση χωρικών φίλτρων.

3.4.1 Χρονική Αναπαράσταση

Η χρονική αναπαράσταση βασίζεται στην μορφολογία του καταγεγραμμένου σήματος όπως αυτό μεταβάλλεται συναρτήσει του χρόνου (κυματομορφή, με οριζόντιο άξονα το χρόνο). Για να πραγματοποιηθεί η μελέτη των μεταβολών του σήματος, το EEG μετρά ένα δείγμα δραστηριοτήτων που προέρχονται από διάφορες περιοχές του εγκεφάλου, γι' αυτό ορίζονται χρονικά παράθυρα συγκεκριμένου χρόνου που αντιστοιχούν στην επιθυμητή εγκεφαλική δραστηριότητα (epochs ή trials). Γι' αυτό είναι αναγκαίο να υπολογιστούν στατιστικές παράμετροι για την εξαγωγή της πληροφορίας των διάφορων εποχών του σήματος. Οι παράμετροι που συνήθως χρησιμοποιούνται είναι: ο μέσος όρος, η ισχύς, η τυπική απόκλιση, η ασυμμετρία, κλπ., όπως ορίζονται στη συνέχεια, και όπου $x(n)$ είναι το προεπεξεργασμένο σήμα EEG με N αριθμό δειγμάτων, και το μ_n αναφέρεται στον μέσο όρο των δειγμάτων.

- Μέση απόλυτη τιμή (MAV):

$$MAV = \frac{1}{N} \sum_{n=1}^N |x_n| \quad (3.6)$$

- Ισχύς (P):

$$P = \frac{1}{N} \sum_{n=1}^N |x_n|^2 \quad (3.7)$$

- Τυπική απόκλιση (SD):

$$SD = \sqrt{\frac{1}{N} \sum_{n=1}^N (x(n) - \mu_n)^2} \quad (3.8)$$

- Μέσο τετράγωνο ρίζας (RMS):

$$RMS = \left(\frac{1}{N} \sum_{i=1}^N x_i^2 \right)^{1/2} \quad (3.9)$$

- Τετραγωνική ρίζα πλάτους (SRA):

$$SRA = \left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|} \right)^2 \quad (3.10)$$

- Τιμή ασυμμετρίας (SV):

$$SV = \frac{1}{N} \sum_{i=1}^N \left(\frac{X_i - \bar{x}}{\sigma} \right)^3 \quad (3.11)$$

- Τιμή κυρτότητας (KV)

$$KV = \frac{1}{N} \sum_{i=1}^N \left(\frac{x_i - \bar{x}}{\sigma} \right)^4 \quad (3.12)$$

Τα ανωτέρω περιγραφικά στατιστικά χαρακτηριστικά είναι χρήσιμα και απαιτούν χαμηλό υπολογιστικό κόστος αλλά συγκρατούν μόνο λίγη, ουσιαστική βέβαια, από τη συνολική πληροφορία του αρχικού σήματος.

Το 1970 ο Βο Hjorth παρουσίασε τρεις στατιστικές παραμέτρους, την δραστηριότητα, την κινητικότητα και την πολυπλοκότητα. Οι παράμετροι Hjorth έχουν πλεονεκτήματα στις αναλύσεις σε πραγματικό χρόνο καθώς έχουν χαμηλό υπολογιστικό κόστος. Ωστόσο, έχει αποδειχθεί ότι εισέρχεται μια στατιστική συστηματική απόκλιση στον υπολογισμό των παραμέτρων (statistical bias), κάτι που σημαίνει ότι μπορεί να υπάρχει συστηματικό σφάλμα στην ανάλυση που πρέπει να ληφθεί υπόψη. Αυτό το σφάλμα μπορεί να επηρεάσει την ακρίβεια της ερμηνείας των σημάτων, ιδιαίτερα σε πιο περίπλοκες καταστάσεις εγκεφαλικής δραστηριότητας.

Η παράμετρος της κινητικότητας αποτελεί την μέση συχνότητα ή το ποσοστό τυπικής απόκλισης του φάσματος ισχύος. Η κινητικότητα ορίζεται ως ο λόγος της τετραγωνικής ρίζας της διακύμανσης της πρώτη παραγώγου του σήματος $x(t)$ προς την διακύμανση του $x(t)$ που παρουσιάζεται στην παρακάτω εξίσωση:

$$Mobility = \sqrt{\frac{\text{var}\left(\frac{dx(t)}{dt}\right)}{\text{var}(x(t))}} \quad (3.13)$$

όπου $x(t)$ είναι το EEG σήμα.

Η παράμετρος της δραστηριότητας αντιπροσωπεύει την ισχύ του σήματος και τη διακύμανσή της συναρτήσει του χρόνου. Έχει την δυνατότητα να εμφανίσει την ‘επιφάνεια’ (‘εμβადόν’) του φάσματος ισχύος στο πεδίο της συχνότητας. Η παρακάτω εξίσωση αντιπροσωπεύει την παράμετρο της δραστηριότητας:

$$Activity = \text{var}(x(t)) \quad (3.14)$$

όπου $x(t)$ είναι το EEG σήμα.

Η παράμετρος της πολύπλοκότητας αντιπροσωπεύει τη διακύμανση της συχνότητας. Ορίζεται ως ο λόγος της κινητικότητας της πρώτη παραγώγου του σήματος προς την κινητικότητα του σήματος, όπως δίνεται στην παρακάτω εξίσωση:

$$Complexity = \sqrt{\frac{Mobility\left(\frac{dx(t)}{dt}\right)}{Mobility(x(t))}} \quad (3.15)$$

όπου $x(t)$ είναι το EEG σήμα.

3.4.2 Αναπαράσταση στο πεδίο της συχνότητας

Η αναπαράσταση του σήματος στο πεδίο της συχνότητας εμφανίζει την ισχύ του σήματος και δείχνει πώς αυτή κατανέμεται σε ένα συγκεκριμένο εύρος συχνοτήτων. Δείχνει επίσης και τις αλλαγές του σήματος σε σχέση με την συχνότητα. Έτσι υπολογίζοντας το φάσμα ισχύος του σήματος, το οποίο παρέχει πληροφορίες για την ισχύ του σήματος σε κάθε δεδομένη συχνότητα, δίνεται η δυνατότητα υπολογισμού χαρακτηριστικών στο πεδίο των συχνοτήτων. Κάποιες από τις πιο διαδεδομένες τεχνικές μετασχηματισμού του σήματος από το πεδίο του χρόνου προς το πεδίο της συχνότητας για τα σήματα EEG αναφέρονται παρακάτω.

3.4.2.1 Μετασχηματισμός Fourier

Ο μετασχηματισμός Fourier αποτελεί μια από τις πιο διαδεδομένες τεχνικές υπολογισμού μετασχηματισμού ενός σήματος από το πεδίο του χρόνου στο πεδίο της συχνότητας. Πιο συγκεκριμένα αποτελεί ένα μαθηματικό μετασχηματισμό ο οποίος μετατρέπει μια συνάρτηση που αρχικά δίνεται στο πεδίο του χρόνου σε μία νέα μορφή που περιγράφει την ισχύ σε καθεμία από τις συχνότητες που αντιστοιχούν στο αρχικό σήμα στο πεδίο του χρόνου, γιατί κάποια σήματα μπορεί να φαίνονται περίπλοκα στον χρόνο, η ανάλυσή τους στο πεδίο της συχνότητας μπορεί να αποκαλύψει απλούστερες δομικές συνιστώσες. Η βασική ιδέα είναι ότι κάθε σήμα αποτελείται από ένα σύνολο (άθροιση) ημιτόνων και συνημιτόνων που το καθένα έχει διάφορες συχνότητες, πλάτη και φάσεις. Αυτά μπορεί να είναι άπειρα στο πλήθος τους, αλλά πάντως η αναπαράσταση του σήματος από το άθροισμα αυτό είναι ακριβής και όχι προσεγγιστική.

Ο μετασχηματισμός Fourier χρησιμοποιεί μια ολοκλήρωση για να υπολογίσει αυτές τις συνιστώσες συχνότητας για όλο το φάσμα, από το μείον άπειρο έως το συν άπειρο. Μαθηματικά, ως μετασχηματισμός Fourier μίας συνάρτησης $x(t)$ ορίζεται η μιγαδική συνάρτηση πραγματικής μεταβλητής $X(\omega)$, που δίνεται από τη σχέση:

$$X(\omega) = \int_{-\infty}^{+\infty} x(t)e^{-j\omega t} dt \quad (3.17)$$

Με την προϋπόθεση ότι το ολοκλήρωμα υπάρχει, αντικαθιστώντας την κυκλική συχνότητα ω με τη γραμμική συχνότητα f όπου $f = \frac{\omega}{2\pi}$ τότε η σχέση 3.17 διαμορφώνεται ως:

$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt \quad (3.18)$$

Ο μετασχηματισμός Fourier είναι μία αντιστρέψιμη διαδικασία, δηλαδή το αρχικό σήμα $x(t)$ μπορεί να ανασυντεθεί μέσω του αντίστροφου μετασχηματισμού Fourier (IDFT) που περιγράφεται από την σχέση:

$$x(t) = \int_{-\infty}^{+\infty} X(f)e^{j2\pi ft} df \quad (3.19)$$

Ο γρήγορος μετασχηματισμός Fourier (FFT), ο διακριτός μετασχηματισμός Fourier (DFT), και ο βραχυχρόνιος μετασχηματισμός Fourier (STFT) αποτελούν τις πιο συχνές τεχνικές μετατροπής σήματος από το πεδίο του χρόνου στο πεδίο της συχνότητας.

- Ο FFT αποτελεί την πιο γρήγορη μέθοδο μετασχηματισμού επιτρέποντας την να χρησιμοποιηθεί σε εφαρμογές σε πραγματικό χρόνο.
- Ο DFT είναι ο πιο σημαντικός διακριτός μετασχηματισμός, που χρησιμοποιείται για την εκτέλεση της ανάλυσης Fourier. Για διακριτό περιοδικό σήμα $x(n)$, έχοντας πλήθος τιμών N , $n=0,1..N-1$ οι χρονικές στιγμές του διακριτού χρόνου του σήματος $x(n)$ και $X(k)$ συντελεστής DFT στη συχνότητα k .

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j\frac{2\pi kn}{N}} \quad (3.20)$$

3.4.2.2 Η φασματική πυκνότητα ισχύος (Power Spectral Density, PSD)

Η φασματική πυκνότητα ισχύος (PSD) περιγράφει πως η ισχύς του σήματος κατανέμεται στις διάφορες συχνότητες. Υπάρχουν δύο οικογένειες μεθόδων για τον υπολογισμό της φασματικής πυκνότητας ισχύος, οι παραμετρικές και οι μη παραμετρικές μέθοδοι.

- Στις παραμετρικές μεθόδους γίνεται υπόθεση ότι τα δεδομένα παράγονται σύμφωνα με συγκεκριμένο μοντέλο χωρίς κάποιο περιορισμό ανάλυσης συχνότητας. Επίσης χρειάζονται επαρκείς πληροφορίες, χωρίς τις οποίες είναι δύσκολο να υπολογιστεί η φασματική πυκνότητα ισχύος.
- Στις μη παραμετρικές μεθόδους δεν γίνεται καμία υπόθεση σχετικά με την προέλευση των δεδομένων. Αυτές οι μέθοδοι βασίζονται σε διακριτούς μετασχηματισμούς Fourier ενός

τιμήματος του σήματος ή στην συνάρτηση της αυτοσυσχέτισης των δειγμάτων του σήματος.

Κάποιες από τις παραμετρικές και μη παραμετρικές μεθόδους αναφέρονται παρακάτω:

Πίνακας 3.1: Παραμετρικές και μη παραμετρικές μέθοδοι εκτίμησης πυκνότητας φασματικής ισχύος.

Παραμετρικές μέθοδοι	Μη παραμετρικές μέθοδοι
Αυτοπαλινδρόμηση (Auto-regression)	Περιοδόγραμμα
Αλγόριθμος Burg	Τροποποιημένο περιοδόγραμμα
Μέθοδος Yule-Walker	Μέθοδος Welch

3.4.3 Χρονο-συχνοτική αναπαράσταση

Χρησιμοποιώντας τις λεγόμενες ‘χρονο-συχνοτικές αναπαραστάσεις’ το σήμα μπορεί μελετάται ταυτόχρονα στο πεδία του χρόνου και της συχνότητας, παίρνοντας πληροφορία και από τα δύο πεδία. Πιο συγκεκριμένα, από τη χρονο-συχνοτική ανάλυση ενός σήματος ανακτώνται πληροφορίες όπως ποια είναι η ισχύ σε κάθε συχνότητα του σήματος αλλά και σε ποιες χρονικές στιγμές του σήματος εμφανίζεται ισχύς σ’ αυτές τις συχνότητες. Αυτές οι πληροφορίες είναι αρκετά σημαντικές ειδικά σε σήματα στα οποία αλλάζει το συχνοτικό περιεχόμενο καθώς ο χρόνος περνάει (μη στάσιμα σήματα – non-stationary signals) και μπορούν να εξαχθούν χρήσιμες πληροφορίες μόνο αν αναλυθεί το υπο μελέτη σήμα και στα δύο πεδία ταυτόχρονα.

Ο μετασχηματισμός κυματιδίων (Wavelet Transform, WT) είναι μία προηγμένη προσέγγιση για την ανάλυση σημάτων μέσω της αναπαράστασής ταυτόχρονα και στον χρόνο αλλά και στην συχνότητα (για την ακρίβεια, την «κλίμακα» - scale). Πιο συγκεκριμένα ο μετασχηματισμός κυματιδίων κωδικοποιεί αρχικά δεδομένα EEG χρησιμοποιώντας μια οικογένεια συναρτήσεων βάσης που ονομάζονται “κυματίδια” (wavelets). Κάνει μελέτη ασυνήθιστων μοτίβων δεδομένων χρησιμοποιώντας μεταβαλλόμενα παράθυρα, με εκτεταμένα παράθυρα για τις χαμηλές συχνότητες και στενά παράθυρα για τις υψηλές συχνότητες. Τα κυματίδια αυτά μπορεί να είναι συνεχή ή διακριτά περιγράφοντας τα χαρακτηριστικά του σήματος στα δύο πεδία. Έτσι υπάρχει ο διακριτός μετασχηματισμός κυματιδίων (Discrete Wavelet Transform, DWT) και ο συνεχής μετασχηματισμός κυματιδίων (Continuous Wavelet Transform, CWT) που και οι δύο χρησιμοποιούνται αρκετά στην ανάλυση ΗΕΓ.

Ο συνεχής μετασχηματισμός κυματιδίων, CWT, ορίζεται ως:

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \Psi\left(\frac{t-b}{a}\right) dt \text{ όπου } a > 0, b \in (-\infty, \infty) \quad (3.17)$$

όπου a, b ονομάζονται παράμετροι διαστολής και μετάθεσης, η παράμετρος a είναι παράμετρος κλίμακας και b είναι η παράμετρος χρονικής μετατόπισης κυματιδίων, x(t) το σήμα που μετασχηματίζεται και ψ(t) η συνάρτηση κυματιδίου.

Ο διακριτός μετασχηματισμός κυματιδίων, DWT, ορίζεται ως:

$$DWT(j, k) = \int_{-\infty}^{\infty} x(t) \frac{1}{\sqrt{2^j}} \cdot \Psi\left(\frac{t-k^j}{2^j}\right) dt \quad (3.18)$$

όπου η μεταβλητή j είναι παράμετρος κλίμακας και k είναι παράμετρος μετατόπισης, και τα δύο είναι ακέραιοι, x(t) το σήμα που μετασχηματίζεται και ψ(t) η συνάρτηση κυματιδίου.

Ο διακριτός μετασχηματισμός κυματιδίων DWT αποσυνθέτει οποιοδήποτε σήμα σε συντελεστές προσέγγισης και λεπτομέρειας που αντιστοιχούν σε διακριτές περιοχές συχνοτήτων διατηρώντας τις χρονικές πληροφορίες στο σήμα. Η επιλογή συγκεκριμένου μέλους της οικογένειας των κυματιδίων αποτελεί εμπειρική διαδικασία. Σχεδόν όλοι οι ερευνητές δοκιμάζουν όλα τα διαθέσιμα κυματίδια πριν επιλέξουν το καλύτερο, δηλαδή εκείνο που παράγει τα βέλτιστα αποτελέσματα για το δεδομένο σήμα. Η επιλογή ενός μητρικού κυματιδίου είναι αρκετά δύσκολη και αποτελεί πρόκληση κατά την εξαγωγή χαρακτηριστικών που βασίζεται σε κυματίδια.

3.4.4 Χωρική αναπαράσταση

Το χωρικό φιλτράρισμα (spatial filtering) αποτελεί τεχνική για την βελτίωση της αποκωδικοποίησης χρησιμοποιώντας τις θέσεις των ηλεκτροδίων. Στόχος του είναι η αύξηση του λόγου σήματος προς θόρυβο και η μείωση της χωρικής παραμόρφωσης στα σήματα EEG. Το χωρικό φιλτράρισμα μπορεί να χρησιμοποιηθεί για την μείωση των διαστάσεων ή του όγκου των δεδομένων ή για την αύξηση της διαφοράς των διαφόρων σημάτων γειτονικών καναλιών EEG. Η εξίσωση που καθορίζει το χωρικό φίλτρο είναι η εξής:

$$X_s = \sum_i^n x_i \cdot w_i \quad (3.19)$$

όπου X_s είναι το χωρικά φιλτραρισμένο σήμα, x_i είναι το σήμα του καναλιού i και w_i αποτελεί το βάρος του καναλιού i. Με την βοήθεια των χωρικών φίλτρων ανακτάται το αρχικό σήμα του

εγκεφάλου, ταυτόχρονα μειώνεται το μέγεθος των καναλιών σε μικρότερα χωρικά φιλτραρισμένα σήματα με αποτέλεσμα την μείωση των διαστάσεων. Μία από τις τεχνικές χωρικού φιλτραρίσματος για την εξαγωγή δεδομένων για ταξινόμηση που χρησιμοποιούνται συχνά στο BCI είναι ο αλγόριθμος κοινών χωρικών προτύπων (Common Spatial Pattern, CSP). Ο αλγόριθμος CSP αποτελεί τεχνική ανάλυσης πολυκαναλικών δεδομένων, όπως το EEG, με βάση καταγραφές δύο κλάσεων. Είναι χωρικά φίλτρα που αυξάνουν τη διαχωρισιμότητα μεταξύ κλάσεων καθώς μεγιστοποιούν τη διακύμανση του φιλτραρισμένου σήματος μίας κλάσης ενώ ελαχιστοποιούν τη διακύμανση της άλλης κλάσης ταυτόχρονα. Ο CSP είναι μία επιβλεπόμενη τεχνική εφόσον απαιτεί γνωστές δοκιμές (trials) δύο κλάσεων προκειμένου να εκτιμηθεί ο πίνακας χωρικών φίλτρων W . Έστω $\Sigma^{(+)}$ και $\Sigma^{(-)}$ είναι οι εκτιμήσεις των πινάκων συνδιακύμανσης του φιλτραρισμένου σήματος. Χρησιμοποιώντας ζωνοπερατό φίλτρο στις δύο κλάσεις, οι συνδιακυμάνσεις υπολογίζονται με τη μορφή πίνακα από την παρακάτω σχέση:

$$\Sigma^{(c)} = \frac{1}{|I_c|} \sum_{i \in I_c} X_i X_i^T \quad \text{όπου } c \in (+, -) \quad (3.20)$$

όπου I_c ($c \in \{+, -\}$) είναι το σύνολο των δεικτών που αντιστοιχούν σε δοκιμές που ανήκουν σε κάθε κλάση και $|I_c|$ δηλώνει το μέγεθος ενός συνόλου I . Έπειτα η ανάλυση CSP δίνεται με την ταυτόχρονη διαγωνιοποίηση των δύο μητρώων συνδιακύμανσης:

$$\begin{aligned} W^T \Sigma^{(+)} W &= \Lambda^{(+)} \\ W^T \Sigma^{(-)} W &= \Lambda^{(-)} \end{aligned} \quad (3.21)$$

Η κλιμάκωση του W συνήθως καθορίζεται ώστε $\Lambda^{(+)} + \Lambda^{(-)} = I$. Αυτό μπορεί να επιτευχθεί απλά (στο MATLAB: $W = \text{eig}(S1, (S1 + S2))$) λύνοντας το πρόβλημα των γενικευμένων ιδιοτιμών.

$$\Sigma^{(+)} w = \lambda \Sigma^{(-)} w \quad (3.22)$$


Έπειτα η (3.21) ικανοποιείται για το W που αποτελείται από τα γενικευμένα ιδιοδιανύσματα της (3.22) και τα αντίστοιχα στοιχεία διαγώνιου του $\Lambda^{(c)}$ είναι οι ιδιοτιμές που αντιπροσωπεύουν τη διακύμανση στην αντίστοιχη κατάσταση c . Η αναλογία των ιδιοτιμών στην (3.22) ισούται με $\lambda^{(+)}_j / \lambda^{(-)}_j$. Όπου το $\lambda^{(c)}_j$ είναι πάντα μεγαλύτερο ή ίσο με μηδέν και είναι η διακύμανση στην κατάσταση c στο αντίστοιχο εικονικό κανάλι, επιπλέον ισχύει ότι $\lambda^{(+)}_j + \lambda^{(-)}_j = 1$. Επομένως, μια μεγάλη τιμή $\lambda^{(+)}_j$ (ή $\lambda^{(-)}_j$) κοντά στο ένα υποδεικνύει ότι το αντίστοιχο χωρικό φίλτρο w_j παράγει υψηλή διακύμανση στη θετική (ή αρνητική) κατάσταση και χαμηλή διακύμανση στην αρνητική (ή θετική) κατάσταση, αντίστοιχα. Αυτή η αντίθεση μεταξύ των δύο κλάσεων είναι χρήσιμη στην

ταξινόμηση. Ο αλγόριθμος CSP δίνει M χωρικά φίλτρα, παρόλα αυτά τελικά επιλέγεται ένα υποσύνολο των M φίλτρων που μεγιστοποιούν την διακύμανση των δύο κλάσεων.

3.5 Ταξινόμηση


Η ταξινόμηση περιλαμβάνεται στην μηχανική μάθηση και αναφέρεται σε αλγόριθμους που έχουν σκοπό την αναγνώριση και την κατηγοριοποίηση των δεδομένων σε διάφορες ομάδες. Οι προσεγγίσεις στη μηχανική μάθηση συχνά διακρίνονται σε δύο μεγάλες κατηγορίες, στην μάθηση με επίβλεψη και στην μάθηση χωρίς επίβλεψη.

Η επιβλεπόμενη μάθηση είναι μία από τις πιο επιτυχημένες μεθόδους στην μηχανική μάθηση, ο αλγόριθμος δέχεται παραδειγματικές εισόδους, δηλαδή δεδομένα με τα αποτελέσματα τους. Στόχος είναι η παραγωγή ενός γενικού κανόνα προκειμένου να αντιστοιχηθούν τα δεδομένα με τα αποτελέσματα τους, ώστε να χρησιμοποιηθεί έπειτα σε νέο σύνολο δεδομένων για την πρόβλεψη των αποτελεσμάτων. Η ταξινόμηση της επιβλεπόμενης μηχανικής μάθησης μπορεί να χωριστεί σε δυαδική (binary) και σε πολυκατηγορική κατηγοριοποίηση (multiclass classification). Η πιο απλή μορφή ταξινόμησης στη μηχανική μάθηση είναι η δυαδική καθώς περιλαμβάνει μόνο δύο κατηγορίες (κλάσεις) και αποτελεί βάση για πιο πολύπλοκα μοντέλα ταξινόμησης. Στην παρακάτω εικόνα (3.3) δίνεται παράδειγμα δυαδικής ταξινόμησης, η ταξινόμηση πραγματοποιείται μεταξύ των κλάσεων A και B και ο διαχωρισμός τους στην επιφάνεια πραγματοποιείται με την μαύρη γραμμή που ονομάζεται όριο απόφασης (decision boundary). Το όριο απόφασης αποτελεί την οριοθέτηση στην επιφάνεια, δηλαδή όποιο δείγμα προκύψει πάνω από αυτό θα χαρακτηριστεί ως κλάση A ενώ όποιο προκύψει κάτω από το όριο απόφασης θα χαρακτηριστεί ως κλάση B . Η πολυκατηγορική κατηγοριοποίηση περιέχει πάνω από δύο κατηγορίες και απεικονίζεται στην εικόνα 3.4.



Εικόνα 3.3 : Δείγμα Δυαδική ταξινόμησης


(Πηγή: [Binary Classification with TensorFlow Tutorial \(freecodecamp.org\)](https://www.freecodecamp.org/tutorial/binary-classification-with-tensorflow/))



Εικόνα 3.4: Δείγμα πολυκατηγορικής ταξινόμησης

(Πηγή: [Binary Classification with TensorFlow Tutorial \(freecodecamp.org\)](https://www.freecodecamp.org/tutorial/binary-classification-with-tensorflow/))

Η μηχανική μάθηση χωρίς επίβλεψη σε αντίθεση με την επιβλεπόμενη επιδιώκει να βρει μοτίβα και δομές από τα δεδομένα εισόδου τα οποία δεν είναι κατηγοριοποιημένα, δηλαδή δεν παρέχονται τα παραδειγματικά αποτελέσματα, ή τα δεδομένα είναι με άγνωστη δομή και ζητείται η εξαγωγή πληροφορίας από τα δεδομένα. Όπως και στην επιβλεπόμενη μηχανική μάθηση έτσι και στην μη επιβλεπούμενη υπάρχουν δύο μέθοδοι, η συσταδοποίηση (Clustering) και ο μετασχηματισμός (Transformation). Η συσταδοποίηση είναι τεχνική διαίρεσης ενός συνόλου δεδομένων σε λογικές ομάδες. Τα αντικείμενα που τοποθετούνται σε κοινές ομάδες κατά την ανάλυση περιέχουν κοινά χαρακτηριστικά. Ο μετασχηματισμός περιλαμβάνει τεχνικές που μετασχηματίζουν τα δεδομένα συνόλου ώστε να είναι πιο προσιτά και εύκολα προς την κατανόηση για τους ανθρώπου ή τους αλγόριθμους μηχανικής μάθησης. Ο πιο συχνός μετασχηματισμός που υλοποιείται είναι η μείωση διαστάσεων καθώς γίνεται απλοποίηση των μοντέλων ώστε η εκπαίδευση των αλγορίθμων να είναι ευκολότερη, επίσης πραγματοποιείται εξοικονόμηση χρόνου και πόρων καθώς η ανάλυση λιγότερων διαστάσεων απαιτεί λιγότερους υπολογιστικούς πόρους και χρόνο.



Εικόνα 3.5: Παράδειγμα συσταδοποίησης, σημεία δεδομένων ομαδοποιούνται σε τρεις ομάδες.

(Πηγή: <https://www.geeksforgeeks.org/clustering-in-machine-learning/>)

Η ταξινόμηση των διεπαφών εγκεφάλου υπολογιστή αποτελεί θεμελιώδες στάδιο για την ανάλυση της εγκεφαλικής δραστηριότητας και την μετατροπή της σε χρήσιμες εντολές ελέγχου διάφορων εφαρμογών. Τα συστήματα BCI απαιτούν πάντα έναν χρήστη ο οποίος με την σειρά του παράγει διάφορους τύπους δεδομένων. Ο χρήστης πρέπει να αναπτύξει διάφορα μοτίβα διεργασιών του εγκεφάλου ώστε το σύστημα να μάθει τα μοτίβα και να μπορέσει να αναγνωρίσει την επιθυμητή δραστηριότητα μετατρέποντας την σε εντολή. Η διαδικασία επιλογής της εντολής πραγματοποιείται χρήση διάφορων αλγορίθμων που ονομάζονται ταξινομητές. Το στάδιο της ταξινόμησης υλοποιείται εφόσον έχουν πραγματοποιηθεί τα προηγούμενα στάδια ενός συστήματος BCI, δηλαδή η προεπεξεργασία και η επιλογή των χαρακτηριστικών, αυτό επιλέγεται για την καλύτερη μάθηση του αλγορίθμου καθώς τα δεδομένα που εισάγονται στον ταξινομητή είναι τα πιο αποτελεσματικά, δηλαδή αντιπροσωπεύουν καλύτερα τις εγκεφαλικές δραστηριότητες που συνδέονται με τα μοτίβα που το σύστημα BCI αποσκοπεί να αναγνωρίσει. Η απόδοση του κάθε ταξινομητή προκύπτει από τα παραδειγματικά δεδομένα τα οποία θα ταξινομηθούν λανθασμένα. Για την επίτευξη της μετατροπής των εγκεφαλικών δεδομένων σε επιθυμητές εντολές μπορούν να χρησιμοποιηθούν αλγόριθμοι παλινδρόμησης ή ταξινόμησης παρακάτω περιγράφονται κάποιοι ταξινομητές.

3.5.1 Ανάλυση Γραμμικής Διάκρισης (Linear Discriminant Analysis, LDA)

Η μέθοδος LDA βασίζεται στη γραμμική διάκριση του Fisher, μία στατιστική μέθοδο που αναπτύχθηκε από τον Ronald Fisher την δεκαετία του 1930 και αργότερα απλοποιήθηκε από τον C. R. Rao ως μια έκδοση πολλαπλών κλάσεων. Η μέθοδος LDA είναι ένας επιβλεπόμενος

αλγόριθμος μηχανικής μάθησης που χρησιμοποιείται για ταξινόμηση. Στόχος είναι η εύρεση γραμμικού συνδυασμού χαρακτηριστικών που να διαχωρίζει δύο ή περισσότερες κατηγορίες αντικειμένων ή γεγονότων. Η μέθοδος LDA λειτουργεί απεικονίζοντας τα δεδομένα σε έναν χώρο μειωμένων διαστάσεων μεγιστοποιώντας τη διαχώριση μεταξύ των κλάσεων και ελαχιστοποιώντας την μεταβλητότητα εντός της κάθε κλάσης. Αυτό επιτυγχάνεται με την μεγιστοποίηση του λόγου της διακύμανσης μεταξύ των κλάσεων προς την διακύμανση εντός της κάθε κλάσης, δηλαδή γίνεται εύρεση των κατευθύνσεων των χαρακτηριστικών που διαχωρίζουν τις διάφορες κλάσεις δεδομένων.

Σκοπός της τεχνικής LDA είναι να απεικονίσει τον αρχικό πίνακα δεδομένων σε έναν χώρο χαμηλότερης διάστασης. Για την επίτευξη του σκοπού αυτού, ο αλγόριθμος προχωρά σε τρία στάδια.

- Το πρώτο στάδιο αποτελεί τον υπολογισμό της απόστασης μεταξύ των μέσων των διαφορετικών κλάσεων, δηλαδή τον υπολογισμό της διαχωριστικότητας μεταξύ των διαφορετικών κλάσεων που ονομάζεται πίνακας διακύμανσης μεταξύ των τάξεων. Για τον υπολογισμό του πίνακα διακύμανσης εντός των κλάσεων S_B χρησιμοποιείται η εξίσωση

$$S_B = \sum_{i=1}^c n_i S_{B_i} \quad (3.23)$$

όπου c ο αριθμός των κλάσεων, n_i ο αριθμός των δειγμάτων της τάξης i , $S_{B_i} = (\mu_i - \mu)(\mu_i - \mu)^T$ όπου ο πίνακας S_{B_i} εξάγει την διασπορά των μέσων τιμών των τάξεων μ_i γύρω από την συνολικό μέσο όρο μ .

- Το δεύτερο στάδιο είναι ο υπολογισμός της απόστασης μεταξύ του μέσου όρου και των δειγμάτων κάθε κλάσης, η οποία ονομάζεται εσωτερική διακύμανση των κλάσεων. Για κάθε κλάση, j η εσωτερική διακύμανση της κλάσης υπολογίζεται από την παρακάτω εξίσωση

$$S_{W_j} = d_j^T * d_j = \sum_{i=1}^{n_j} (x_{ij} - \mu_j)(x_{ij} - \mu_j)^T \quad (3.24)$$

όπου x_{ij} συμβολίζει το i δείγμα της κλάσης j .

- Το τρίτο στάδιο αποτελεί την κατασκευή του χώρου μικρότερης διάστασης που μεγιστοποιεί την εσωτερική διακύμανση μεταξύ της τάξης και ελαχιστοποιεί την διακύμανση εντός των τάξεων. Για την κατασκευή ενός χώρου χαμηλότερης διάστασης

που μεγιστοποιεί τη διαχωριστικότητα κλάσεων, η τεχνική LDA χρησιμοποιεί έναν πίνακα μετασχηματισμού W . Ο πίνακας μετασχηματισμού W καθορίζεται με την επίλυση ενός προβλήματος βελτιστοποίησης που επιδιώκει να μεγιστοποιήσει τη διασπορά μεταξύ τάξεων, ενώ ταυτόχρονα ελαχιστοποιεί τη διασπορά εντός της κατηγορίας, ένα κριτήριο που διατυπώνεται από τον Fisher.

$$\arg \max_w \frac{W^T S_B W}{W^T S_W W} \quad (3.25)$$


Ο τύπος μπορεί να αναδιατυπωθεί όπως η παρακάτω εξίσωση

$$S_W W = \lambda S_B W \quad (3.26)$$


Το λ αντιπροσωπεύει τις ιδιοτιμές που σχετίζονται με τον πίνακα μετασχηματισμού W . Η λύση σε αυτό το πρόβλημα προκύπτει με τον υπολογισμό των ιδιοτιμών και των ιδιοδιανυσμάτων του $W = S_W^{-1} S_B$, τα ιδιοδιανύσματα που αντιστοιχούν στις μεγαλύτερες ιδιοτιμές θα σχηματίσουν τις στήλες του πίνακα W , καταγράφοντας τις πιο διακριτικές κατευθύνσεις για τον διαχωρισμό των τάξεων.

3.5.2 Μηχανές Διανυσματικής Υποστήριξης (Support Vector Machines, SVM)

Οι μηχανές Διανυσματικής Υποστήριξης είναι αλγόριθμοι μηχανικής μάθησης που χρησιμοποιούν επιβλεπόμενα μοντέλα για την επίλυση σύνθετων προβλημάτων ταξινόμησης, παλινδρόμησης και ανίχνευσης ασυνήθιστων τιμών με το να πραγματοποιούν μετασχηματίσεις δεδομένων που καθορίζουν τα όρια μεταξύ των σημείων δεδομένων, βάση προκαθορισμένων κλάσεων, ή αποτελεσμάτων. Στόχος του αλγόριθμου SVM είναι ο προσδιορισμός ενός υπερεπιπέδου που διαχωρίζει διακριτά τα σημεία δεδομένων διαφορετικών κλάσεων. Υπάρχουν πολλά πιθανά υπερεπίπεδα που θα μπορούσαν να επιλεγούν. Σκοπός είναι να βρεθεί ένα επίπεδο που έχει το μέγιστο περιθώριο, δηλαδή τη μέγιστη απόσταση μεταξύ των σημείων δεδομένων και των δύο κατηγοριών. Η αναπαράσταση διανύσματος υποστήριξης απεικονίζεται στις παρακάτω εικόνες:




Εικόνα 3.6: Πιθανά όρια απόφασης για τον διαχωρισμό των κλάσεων



Εικόνα 3.7: Βέλτιστο όριο απόφασης για τον διαχωρισμό των κλάσεων.

(Πηγή: [Support Vector Machine — Introduction to Machine Learning Algorithms | by Rohith Gandhi | Towards Data Science](#))

Τα διανύσματα υποστήριξης είναι σημεία δεδομένων που βρίσκονται πιο κοντά στο υπερεπίπεδο και επηρεάζουν τη θέση και τον προσανατολισμό του υπερεπίπεδου. Χρησιμοποιώντας αυτά τα διανύσματα υποστήριξης, μεγιστοποιείται το περιθώριο (margin) του ταξινομητή. Σε περίπτωση διαγραφής των διανυσμάτων υποστήριξης θα αλλάξει τη θέση του υπερεπίπεδου.



Εικόνα 3.8: Περιπτώσεις μεγάλου και μικρού περιθωρίου.

(Πηγή: [Support Vector Machine — Introduction to Machine Learning Algorithms | by Rohith Gandhi | Towards Data Science](#))

Έστω ένα σύνολο σημείων δεδομένων που είναι επιθυμητό να κατηγοριοποιηθεί σε δύο κλάσεις. Υπάρχουν δύο περιπτώσεις για αυτά τα δεδομένα: είτε είναι γραμμικά διαχωρίσιμα, είτε το διαχωριστικό υπερεπίπεδο είναι μη γραμμικό. Όταν τα δεδομένα είναι γραμμικά διαχωρισμένα και δεν θέλουμε να έχουμε λανθασμένες ταξινομήσεις, χρησιμοποιούμε SVM με σκληρό περιθώριο (hard margin). Ωστόσο, όταν ένα γραμμικό όριο δεν είναι εφικτό ή θέλουμε να επιτρέψουμε κάποιες εσφαλμένες ταξινομήσεις με την ελπίδα να επιτύχουμε καλύτερη

γενικότητα, μπορούμε να επιλέξουμε ένα ήπιο περιθώριο (soft margin) για τον ταξινομητή. Στην περίπτωση που χρησιμοποιηθεί soft margin πρέπει να ελαχιστοποιηθεί το σφάλμα εσφαλμένης ταξινόμησης.

Στον τομέα των μαθηματικών, τα SVM είναι ένα σύνολο από αλγορίθμους μηχανικής μάθησης που ενσωματώνουν τεχνικές με πυρήνες, δηλαδή κάνουν χρήση πυρηνικών συναρτήσεων για την αλλαγή των χαρακτηριστικών των δεδομένων. Η συνάρτηση πυρήνα είναι μια μέθοδος που χρησιμοποιείται για τη λήψη δεδομένων ως είσοδο και τη μετατροπή τους στην απαιτούμενη μορφή επεξεργασίας. Ο πυρήνας χρησιμοποιείται λόγω ενός συνόλου μαθηματικών συναρτήσεων για τον χειρισμό των δεδομένων που χρησιμοποιούνται στο SVM. Έτσι, η συνάρτηση πυρήνα γενικά μετασχηματίζει το εκπαιδευτικό σύνολο δεδομένων έτσι ώστε μια μη γραμμική επιφάνεια απόφασης να μπορεί να μετασχηματιστεί σε γραμμική εξίσωση με μεγαλύτερο αριθμό διαστάσεων. Οι SVM μπορούν να χωριστούν σε δύο κατηγορίες: τον γραμμικό SVM και το μη γραμμικό SVM. Το γραμμικό SVM, είναι τύπος που χρησιμοποιείται για την ταξινόμηση γραμμικών διαχωρίσιμων δεδομένων. Δηλαδή χρησιμοποιούνται όταν ένα σύνολο δεδομένων μπορεί να διαχωριστεί σε κατηγορίες με μία ευθεία γραμμή. Ενώ τα μη γραμμικά SVM χρησιμοποιούνται για την ταξινόμηση δεδομένων που δεν είναι διακριτά διαχωρίσιμα με μια ευθεία γραμμή, η ταξινόμηση πραγματοποιείται σε υψηλότερες διαστάσεις για τον διαχωρισμό των δεδομένων.

Στον παρακάτω πίνακα απεικονίζονται μοντέλα SVM τα οποία χρησιμοποιούνται για ταξινόμηση, K ορίζεται ως συνάρτηση πυρήνα που, δέχεται δύο εισόδους, x_1, x_2 αποτελούν διανύσματα που αντιπροσωπεύουν μεμονωμένα σημεία δεδομένων από διαφορετικές τάξεις ή κατηγορίες.

Πίνακας 3.2: Επισκόπηση των κοινών συναρτήσεων πυρήνα SVM: Σύνοψη των τυπικών πυρήνων SVM και των μαθηματικών τους μοντέλων.

Τύπος SVM	Mercer Kernel
Γραμμική	$K(x_1, x_2) = x_1 x_2$
Πολυωνυμική	$K(x_1, x_2) = (x_1 x_2 + r)^p$
Γκαουσιανής ή Ακτινικής Βάσης Συνάρτηση (RBF)	$K(x_1, x_2) = \exp(-\gamma \ x_1 - x_2\ ^2)$

- **Γραμμικός πυρήνας:** Αντιπροσωπεύεται ως $K(x_1, x_2) = x_1 x_2$, ο γραμμικός πυρήνας αντιπροσωπεύει το εσωτερικό γινόμενο δύο διανυσμάτων x_1, x_2
- **Πολυωνυμικός πυρήνας:** Το μαθηματικό μοντέλο του πολυωνυμικού πυρήνα αντιπροσωπεύεται από τον τύπο $K(x_1, x_2) = (x_1 x_2 + r)^p$, η παράμετρος p αποτελεί τον βαθμό του πολυωνύμου. $r > 0$ είναι μια ελεύθερη παράμετρος που ανταλλάσσει την επιρροή όρων υψηλότερης τάξης έναντι όρων χαμηλότερης τάξης στο πολυώνυμο.
- **Πυρήνας με Γκαουσιανή ή ακτινική συνάρτηση βάσης:** Το μαθηματικό μοντέλο του πολυωνυμικού πυρήνα αντιπροσωπεύεται από τον τύπο $K(x_1, x_2) = \exp(-\gamma \|x_1 - x_2\|^2)$. Η παράμετρος γ καθορίζει το πλάτος της γκαουσιανής συνάρτησης. Είναι συνήθως θετική τιμή η οποία επηρεάζει την απόδοση του ταξινομητή, γι' αυτό πρέπει να επιλέγεται με προσοχή καθώς και μεγαλώνοντας την παράμετρος μπορεί να οδηγήσει σε overfitting. η διαφορά $\|x_1 - x_2\|^2$ αντιπροσωπεύει την απόσταση μεταξύ δύο δειγμάτων στο χώρο των χαρακτηριστικών.

3.5.3 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks, ANN)

Τα τεχνητά νευρωνικά δίκτυα ή απλώς «νευρωνικά δίκτυα» (NN) είναι μια οικογένεια αλγορίθμων που μιμούνται τις πολύπλοκες λειτουργίες του εγκεφάλου. Έχουν σχεδιαστεί για να μαθαίνουν μοτίβα και σχέσεις από δεδομένα εκπαίδευσης, να προσαρμόζονται και να βελτιώνονται συνεχώς και να εφαρμόζουν αυτή την μάθηση για να κάνουν προβλέψεις ή να παίρνουν αποφάσεις. Η ικανότητά τους να εξάγουν σημαντικές πληροφορίες από πολύπλοκα δεδομένα για την επίλυση προβλημάτων τους ξεχωρίζει από τους κοινούς αλγόριθμους.

Ένα απλό (με τη σημερινή ορολογία, «ρηχό» - shallow και όχι «βαθύ» - deep) νευρωνικό δίκτυο αποτελείται από τρία επίπεδα, το πρώτο επίπεδο αποτελείται από τους νευρώνες εισόδου, το δεύτερο επίπεδο που αποτελείται από τους κρυμμένους νευρώνες, και το τρίτο επίπεδο το οποίο περιέχει τους νευρώνες εξόδου. Τα δεδομένα εισόδου σε ένα νευρωνικό δίκτυο διαβιβάζονται μέσω του δικτύου από επίπεδο σε επίπεδο για την παραγωγή της εξόδου. Οι κρυμμένοι νευρώνες πολλαπλασιάζουν κάθε είσοδό τους με το αντίστοιχο συναπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων. Το ολικό άθροισμα τοποθετείται στη συνάρτηση ενεργοποίησης, η οποία υλοποιείται εσωτερικά σε κάθε κόμβο. Η τιμή που λαμβάνει η συνάρτηση για το εν λόγω όρισμα είναι και η έξοδος του νευρώνα για τις τρέχουσες εισόδους και βάρη.


Υπάρχουν αρκετές αρχιτεκτονικές νευρωνικών δικτύων. Όταν όλοι οι νευρώνες που αποτελούν ένα επίπεδο είναι συνδεδεμένοι με όλους τους νευρώνες του επομένου επιπέδου, τότε τα νευρωνικά ονομάζονται πλήρως συνδεδεμένα (fully connected), ενώ αν υπάρχουν νευρώνες σε ένα επίπεδο που δεν συνδέονται με όλους τους νευρώνες του επόμενου επιπέδου τότε ονομάζονται μερικώς συνδεδεμένα (partially connected).

Τα νευρωνικά δίκτυα χωρίζονται σε δύο κατηγορίες ανάλογα τον τρόπο που τροφοδοτούν οι έξοδοι του ενός επιπέδου τις εισόδους του επομένου, σε πρόσθιας τροφοδότησης (feed-forward) και σε αναδρομικά (reccurent).

- Στα νευρωνικά δίκτυα πρόσθιας τροφοδότησης, οι νευρώνες ενός επιπέδου δεν συνδέονται με νευρώνες προηγούμενου επιπέδου, συνδέονται και τροφοδοτούν τους νευρώνες του επόμενου επιπέδου.
- Στα αναδρομικά νευρωνικά δίκτυα, οι νευρώνες ενός επιπέδου μπορούν να συνδέονται και να τροφοδοτούν και νευρώνες προηγούμενου ή του ίδιου επιπέδου, εκτός από εκείνους του επόμενου επιπέδου.

3.5.3.1 Το perceptron

Το perceptron καταλαμβάνει μία ειδική θέση στην ιστορική εξέλιξη των νευρωνικών δικτύων. Ήταν το πρώτο νευρωνικό δίκτυο που είχε περιγραφεί αλγοριθμικά. Την ‘σπίθα’ για την δημιουργία του την έδωσε ένας ψυχολόγος, ο Rosenblatt [85]. Το Perceptron είναι η απλούστερη μορφή νευρωνικού δικτύου, και μπορεί εν τούτοις να επιτύχει την ταξινόμηση ειδικού τύπου δεδομένων: εκείνων που είναι γραμμικά διαχωριζόμενα. Αποτελείται από ένα γραμμικό συνδυαστή ακολουθούμενο από ένα στοιχείο κατωφλίου και παράγει έξοδο με τιμή ± 1 , Σκοπός του Perceptron είναι να ταξινομήσει ένα σύνολο εισόδων x_1, x_2, \dots, x_n σε μία από τις κλάσεις +1 και -1. Το perceptron τερματίζει όταν δεν υπάρχει κανένα σφάλμα μεταξύ δεδομένων και εκτιμωμένων τιμών.




Εικόνα 3.9: Αρχιτεκτονική δικτύου Perceptron.

(Πηγή: https://www.researchgate.net/publication/228395588_A_HIGHLY_TIME-EFFICIENT_DIGITAL_MULTIPLIER_BASED_ON_THE_A2_BINARY_REPRESENTATION)

3.5.3.2 Πολυεπίπεδο perceptron (Multilayer Perceptron, MLP)

Το MLP εμπίπτει στην κατηγορία των αλγορίθμων πρόσθιας τροφοδότησης επειδή οι είσοδοι συνδυάζονται με τα αρχικά βάρη σε ένα σταθμισμένο άθροισμα και υπόκεινται στη συνάρτηση ενεργοποίησης, όπως ακριβώς στο Perceptron. Αλλά η διαφορά είναι ότι κάθε γραμμικός συνδυασμός διαδίδεται στο επόμενο επίπεδο. Το MLP αποτελείται από τρία επίπεδα, το επίπεδο εισόδου, το κρυφό επίπεδο και το επίπεδο εξόδου. Το επίπεδο εισόδου λαμβάνει το σήμα εισόδου, ενώ η απαιτούμενη εργασία όπως η πρόβλεψη ή η ταξινόμηση πραγματοποιείται στο επίπεδο εξόδου. Ανάμεσα στο επίπεδο εισόδου και εξόδου υπάρχει ένας αυθαίρετος αριθμός κρυφών επιπέδων που τοποθετούνται και αποτελούν την υπολογιστική μηχανή του MLP.



Εικόνα 3.10: Βασική αρχιτεκτονική ενός νευρωνικού δικτύου τύπου Multilayer Perceptron (MLP) με ένα στρώμα εισόδου (ροζ), δύο κρυφά στρώματα (γαλάζια) και δύο κόμβους στο στρώμα εξόδου (κίτρινα).

(Πηγή: <https://medium.com/codex/introduction-to-how-an-multilayer-perceptron-works-but-without-complicated-math-a423979897ac>)

Ο πρωταρχικός στόχος των MLP είναι ο ίδιος σκοπός με το Perceptron, δηλαδή η ελαχιστοποίηση το σφάλματος χρήση διαφορετικής διαδικασίας υπολογισμού που ονομάζεται οπισθοδρόμηση (backpropagation). Αυτός μηχανισμός εκμάθησης που επιτρέπει στο MLP να προσαρμόζει επαναληπτικά τα βάρη στο δίκτυο ώστε κατά την ταξινόμηση να υπάρχουν όσο το δυνατόν λιγότερα πρότυπα που δεν θα έχουν κατηγοριοποιηθεί σωστά. Πιο συγκεκριμένα ο μηχανισμός ο μηχανισμός χωρίζεται σε δύο στάδια: feedforward και backpropagation. Στο στάδιο feedforward, ένα σήμα εισόδου εφαρμόζεται στο επίπεδο εισόδου και η επίδρασή του διαδίδεται, από επίπεδο σε επίπεδο, μέσω του δικτύου μέχρι να παραχθεί μια έξοδος. Στη συνέχεια, η πραγματική τιμή εξόδου του δικτύου συγκρίνεται με την αναμενόμενη πρότυπη έξοδο και υπολογίζεται ένα σήμα σφάλματος για κάθε έναν από τους κόμβους εξόδου. Δεδομένου ότι όλοι οι κρυφοί κόμβοι έχουν συνεισφέρει σε κάποιο βαθμό στο σφάλμα που είναι εμφανή στο επίπεδο εξόδου, τα σήματα σφάλματος εξόδου μεταδίδονται προς τα πίσω, από το επίπεδο εξόδου σε κάθε κόμβο στο κρυφό επίπεδο που συνέβαλε αμέσως στο επίπεδο εξόδου. Αυτή η διαδικασία στη συνέχεια επαναλαμβάνεται, επίπεδο σε επίπεδο, έως ότου κάθε κόμβος στο δίκτυο λάβει ένα σήμα σφάλματος που περιγράφει τη σχετική συνεισφορά του στο συνολικό σφάλμα.

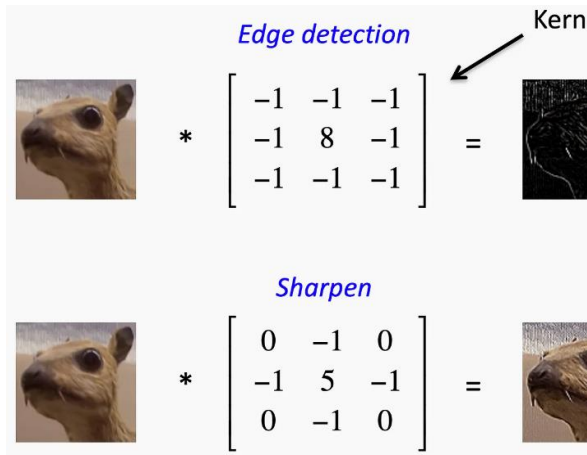
Μόλις καθοριστεί το σήμα σφάλματος για κάθε κόμβο, τα σφάλματα χρησιμοποιούνται στη συνέχεια από τους κόμβους για να ενημερώσουν τις τιμές για κάθε βάρος σύνδεσης μέχρι το δίκτυο να συγκλίνει σε μια κατάσταση που επιτρέπει την κωδικοποίηση όλων των προτύπων εκπαίδευσης. Ο αλγόριθμος backpropagation αναζητά την ελάχιστη τιμή της συνάρτησης

σφάλματος στο χώρο βάρους χρησιμοποιώντας μια τεχνική που ονομάζεται κανόνας δέλτα. Τα βάρη που ελαχιστοποιούν τη συνάρτηση σφάλματος θεωρείται στη συνέχεια ως λύση στο μαθησιακό πρόβλημα.

3.5.3.3 Συνελκτικό Νευρωνικό Δίκτυο (Convolutional Neural Network, CNN)


Το CNN είναι ένα τεχνικό προωθητικό νευρωνικό δίκτυο το οποίο χρησιμοποιείται ευρέως στην αναγνώριση και ταξινόμηση αντικειμένων σε εικόνες. Το πρώτο CNN που δημιουργήθηκε ονομάζεται Lenet, κατασκευάστηκε το 1988 από τον Yann Lecun [41] και χρησιμοποιήθηκε στην αναγνώριση χαρακτήρων όπως η αναγνώριση αριθμών. Τα CNN αποτελούν λύση σε πολλαπλά προβλήματα αναγνώρισης εικόνων, συμπεριλαμβανομένου της ταξινόμησης και ανίχνευσης αντικειμένων, και της τμηματοποίησης της εικόνας. Τα CNN χρησιμοποιούνται σε πολλούς τομείς, κάποιες από αυτές είναι η αναγνώριση προσώπου στα μέσα κοινωνικής δικτύωσης, στην αναγνώριση εμποδίων και αντικειμένων στα αυτό-οδηγούμενα αυτοκίνητα, και στην ανίχνευση ασθενειών. Τα CNN έχουν θέση και στις εφαρμογές BCI, μπορούν να επεξεργαστούν με μεγάλη ταχύτητα δεδομένα EEG και να ανιχνεύσουν μοτίβα ή χαρακτηριστικά παράγοντας αποτέλεσμα με ελάχιστη καθυστέρηση. Τα CNN αποτελούνται από τρία σημαντικά επίπεδα:

- **Convolutional layer:** Η πλειοψηφία των υπολογισμών πραγματοποιείται σε αυτό το επίπεδο, είναι διαδικασία εξαγωγής σημαντικών χαρακτηριστικών από μία εικόνα. Το convolutional layer περιέχει πυρήνες ή φίλτρα τα οποία κινούνται πάνω στην εικόνα, κάθε φίλτρο είναι σαν ένας φακός που αναζητάει συγκεκριμένα μοτίβα στη εικόνα, όπως γραμμές καμπύλες, ή σχήματα. Τα φίλτρα μετακινούνται κατά μήκος της εικόνας και δημιουργούν έναν χάρτη χαρακτηριστικών ο οποίος απεικονίζει την τοποθεσία των μοτίβων της εικόνας όπως παρουσιάζεται στην Εικόνα 3.12 στο οποίο απεικονίζεται η εφαρμογή φίλτρου σε ένα μέρος της αρχικής εικόνας. Η εφαρμογή πολλών φίλτρων είναι σημαντικό στο δίκτυο CNN, καθώς κάθε φίλτρο ειδικεύεται στο να ανακαλύπτει διαφορετικά μοτίβα όπως γραμμές ή γωνίες. Στην εικόνα 3.11 απεικονίζονται δύο φίλτρα μπορούν να εφαρμοστούν σε εικόνα για την παραγωγή διαφορετικών αποτελεσμάτων. Το πρώτο φίλτρο που απεικονίζεται ειδικεύεται στην ανίχνευση άκρων, πιο συγκεκριμένα η έξοδος του φίλτρου αποτελεί έναν χάρτη που εμφανίζει το περίγραμμα του ζώου, επιτρέποντας στο CNN να εστιάσει στις άκρες που είναι σημαντικό στην ανίχνευση αντικειμένων. Το δεύτερο φίλτρο ενισχύει την αντίθεση και τη λεπτομέρεια τονίζοντας την αντίθεση των λεπτομερειών και τη διαφορά μεταξύ των διπλανών pixels.



Εικόνα 3.11: Παράδειγμα φίλτρων για CNN

(Πηγή: [Simple Introduction to Convolutional Neural Networks | by Matthew Stewart, PhD | Towards Data Science](#))



Εικόνα 3.12: Παράδειγμα εφαρμογής συνέλιξης

(Πηγή: [Simple Introduction to Convolutional Neural Networks | by Matthew Stewart, PhD | Towards Data Science](#))

- **Pooling layer:** Στόχος του επιπέδου Pooling είναι η άντληση των πιο σημαντικών χαρακτηριστικών από τον πίνακα της εξόδου του Convolutional επιπέδου. Χρησιμοποιώντας φίλτρο κατά μήκος της εικόνας ελαχιστοποιώντας τις παραμέτρους και την πολυπλοκότητα βελτιώνοντας την απόδοση του CNN.
- **Fully connected layer:** έχει σκοπό την ταξινόμηση της εικόνας με βάση τα χαρακτηριστικά που έχουν εξαχθεί από τα προηγούμενα επίπεδα. Ο όρος 'connected' σημαίνει ότι κάθε νευρώνας σε αυτό το επίπεδο είναι συνδεδεμένος με κάθε ενεργοποιητική μονάδα του προηγούμενου επιπέδου, επιτρέποντας στο δίκτυο να εξετάζει όλα τα χαρακτηριστικά που έχουν εξαχθεί.

3.6 Αξιολόγηση συστήματος

Μετά την ολοκλήρωση του σταδίου της ταξινόμησης, ακολουθηθεί μια διαδικασία αξιολόγησης για να προσδιοριστεί πόσο καλά λειτουργεί το σύστημα. Αυτό επιτυγχάνεται μέσω της εφαρμογής του ταξινομητή σε ένα σύνολο δεδομένων που δεν έχει δει κατά τη φάση εκπαίδευσης, γνωστό ως σετ ελέγχου. Η σημασία αυτού του βήματος είναι κρίσιμη, καθώς μας παρέχει μια εικόνα της πραγματικής απόδοσης του συστήματος.

3.6.1 Δείκτες Αξιολόγησης συστήματος

Οι σημαντικότεροι δείκτες αποτελεσματικότητας ενός αλγορίθμου ταξινόμησης όσον αφορά την ακρίβεια των προβλέψεών του είναι η επιτυχία, η ευαισθησία, η ειδικότητα, η ακρίβεια και ο αρμονικός μέσος (F1-score).

- **Επιτυχία (Accuracy):** Δίνει το επίπεδο σωστής πρόβλεψης του μοντέλου είτε θετικών είτε αρνητικών δειγμάτων, υπολογίζεται από το άθροισμα του πλήθους των αρνητικών και θετικών προβλέψεων που έχουν κατηγοριοποιηθεί σωστά (TP+TN) προς το άθροισμα όλων των προβλέψεων, περιπτώσεων που έχουν πραγματοποιηθεί.

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \cdot 100\%$$

- **Ευαισθησία (Sensitivity):** Δίνει τον αριθμό των θετικών δειγμάτων που έχουν ταξινομηθεί σωστά προς το σύνολο των δειγμάτων που ταξινομήθηκαν ως θετικά.

$$Sensitivity = \frac{TP}{TP + FN} \cdot 100\%$$

- **Ακρίβεια (Precision):** Δίνει τον αριθμό των θετικών δειγμάτων που έχουν ταξινομηθεί σωστά προς όλο τον αριθμό των δειγμάτων που είναι πράγματι θετικά.

$$Precision = \frac{TP}{TP + FP} \cdot 100\%$$

- **Ειδικότητα (Specificity):** Δίνει τον αριθμό των αρνητικών δειγμάτων που έχουν ταξινομηθεί σωστά προς το σύνολο των δειγμάτων που είναι πραγματικά αρνητικά.

$$Specificity = \frac{TN}{TN + FP} \cdot 100\%$$


- **Αρμονικός μέσος (F1 score):** Αποτελεί στατιστικό μετρητή που χρησιμοποιείται για την εκτίμηση της επιτυχίας ενός ταξινομητή. Είναι το διπλάσιο του αρμονικού μέσου της ακρίβειας και της ευαισθησίας, ως ποσοστό %.

$$F1 = 2 \cdot \frac{Precision \cdot Sensitivity}{Precision + Sensitivity} \cdot 100\%$$

3.6.2 Μέθοδος Hold-out

Η μέθοδος Hold-out είναι μια τεχνική διαχωρισμού του συνόλου δεδομένων σε δύο υποσύνολα, το σύνολο εκπαίδευσης (training set) και το σύνολο ελέγχου (test set). Το σύνολο ελέγχου

ονομάζεται επίσης σύνολο hold out, επειδή διατηρείται εκτός της διαδικασίας ανάπτυξης του μοντέλου, δηλαδή δεν χρησιμοποιείται στην εκπαίδευση του μοντέλου. Το ποσοστό του διαχωρισμού καθορίζεται με βάση τον όγκο των διαθέσιμων δεδομένων εκπαίδευσης, ένας συχνός διαχωρισμός είναι 70%-30%, όπου 70% του συνόλου των δεδομένων χρησιμοποιείται για εκπαίδευση και το υπόλοιπο 30% μένει εκτός της διαδικασίας εκπαίδευσης και χρησιμοποιείται αφού ολοκληρωθεί η εκπαίδευση, για τον έλεγχο του μοντέλου. Σκοπός αυτής της τεχνικής είναι η επιλογή του καλύτερου μοντέλου βάση του ποσοστού επιτυχίας στο σύνολο δεδομένων ελέγχου.



Εικόνα 3.13: Μέθοδος Hold-out για την αξιολόγηση μοντέλου

(Πηγή: [Understanding Hold-Out Methods for Training Machine Learning Models - Comet](#))

3.6.3 Πίνακας σύγχυσης

Ο πίνακας σύγχυσης (confusion matrix) παρέχει πληροφορίες σχετικά με την μέτρηση της απόδοσης της σε προβλήματα ταξινόμησης μηχανικής μάθησης. Πιο συγκεκριμένα παρέχει πληροφορίες σχετικά με τις πραγματικές και προβλεπόμενες ταξινομήσεις που υλοποιεί το σύστημα ταξινόμησης. Ο πίνακας εμφανίζει τον αριθμό των περιπτώσεων που παράγονται από το μοντέλο στα δεδομένα ελέγχου. Οι περιπτώσεις είναι:

- Αληθινές θετικές προβλέψεις (TP): Πλήθος θετικών δειγμάτων που έχουν κατηγοριοποιηθεί σωστά από το μοντέλο.
- Αληθινές αρνητικές προβλέψεις (TN): Πλήθος αρνητικών δειγμάτων που έχουν κατηγοριοποιηθεί σωστά από το μοντέλο.
- Λανθασμένες Θετικές προβλέψεις (FP): Πλήθος αρνητικών δειγμάτων που έχουν κατηγοριοποιηθεί λανθασμένα ως θετικά.

- Λανθασμένες αρνητικές προβλέψεις (FN): Πλήθος θετικών δειγμάτων που έχουν κατηγοριοποιηθεί λανθασμένα ως αρνητικά

Βάση αυτών των τεσσάρων τιμών του πίνακα σύγχυσης δίνεται η δυνατότητα προσδιορισμού των δεικτών αξιολόγησης του συστήματος (επιτυχία, ευαισθησία, ακρίβεια, κ.α.) για την αξιολόγηση του μοντέλου.

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negative (TN)	False Positive (FP) Type I Error
	Positive +	False Negative (FN) Type II Error	True Positive (TP)

Εικόνα 3.14: Πίνακας σύγχυσης δυαδικής ταξινόμησης.

(Πηγή: <https://medium.com/analytics-vidhya/what-is-a-confusion-matrix-d1c0f8feda5>)

3.6.4 Τεχνική k-fold Cross-validation

Η τεχνική k-fold Cross-validation αποτελεί τεχνική αξιολόγησης προγνωστικών μοντέλων. Το σύνολο δεδομένων διαιρείται σε k σύνολα τα οποία ονομάζονται 'folds' και το μοντέλο εκπαιδεύεται και αξιολογείται k φορές χρησιμοποιώντας κάθε φορά ένα διαφορετικό υποσύνολο των k συνόλων ως σύνολο ελέγχου (testing set), ενώ τα υπόλοιπα k-1 σύνολα χρησιμοποιούνται ως σύνολο εκπαίδευσης (training set). Η απόδοση του κάθε συνόλου υπολογίζονται κατά μέσο όρο για την εκτίμηση της απόδοσης του μοντέλου. Κάθε σύνολο k υποσυνόλων δεδομένων εκπαίδευσης και αξιολόγησης χρησιμοποιείται μόνο μία φορά κατά την διάρκεια όλης της τεχνικής, για την αποφυγή του overfitting. Η τεχνική αυτή βοηθά στην αξιολόγηση του μοντέλου, την επιλογή και τον συντονισμό υπερ-παραμέτρων, παρέχοντας ένα πιο αξιόπιστο μέτρο της αποτελεσματικότητας ενός μοντέλου.

4-fold validation (k=4)



Εικόνα 3.15: Τεχνική k-fold cross-validation για $k = 4$.

(Πηγή: [Cross-validation - MATLAB & Simulink \(mathworks.com\)](https://www.mathworks.com/help/matlab/cross-validation.html))

ΚΕΦΑΛΑΙΟ 4: Ανάπτυξη συστήματος αναγνώρισης προτύπων BCI με τεχνική motor imagery

4.1 Η πρόκληση και ο σκοπός

Η κινητική φαντασίωση αποτελεί νοητικές διαδικασίες, κατά τις οποίες το άτομο προσομοιώνει μία κινητική ενεργεία στο μυαλό, νιώθοντας ή φαντάζοντας ότι εκτελεί τη δράση για να καταγραφεί η ενέργεια στο EEG. Οι δραστηριότητες περιλαμβάνουν κινήσεις από διάφορα μέρη του σώματος (όπως χέρια ή τα πόδια). Τα σήματα MI είναι ενεργά πάνω από τον κινητικό φλοιό του εγκεφάλου. Λόγω της πολυπλοκότητας του εγκεφάλου καθώς, και με την χρήση των μη επεμβατικών τεχνικών για την λήψη του σήματος υπάρχουν αρκετές προκλήσεις. Κάποιες από τις προκλήσεις αποτελούν το χαμηλό SNR (signal-to-noise ratio), καθώς τα BCI που είναι βασισμένα σε μη επεμβατικές τεχνικές, μετρούν τη μέση δραστηριότητα μεγάλου αριθμού νευρώνων στην επιφάνεια του εγκεφάλου. Όταν ο χρήστης φαντάζεται μία διαδικασία ενεργοποιείται μεγάλος αριθμός νευρώνων, ενώ υπάρχουν και ενεργοποιημένοι νευρώνες άλλων λειτουργιών, ως αποτέλεσμα να υπάρχουν και επικαλυπτόμενες δραστηριότητες που πρέπει να απομονωθούν μέσω του χωρικού φιλτραρίσματος. Άλλη μια πρόκληση, αποτελούν οι αλλαγές στο εξωτερικό περιβάλλον ή η εσωτερική κατάσταση του σώματος των ατόμων, καθώς μπορεί να οδηγήσουν σε απρόβλεπτες επιδράσεις στο σήμα EEG. Γι' αυτό, πολλές μελέτες πραγματοποιούνται σε εργαστηριακό περιβάλλον που είναι ελεγχόμενο για την ποιοτική απόδοση των σημάτων. Επιπλέον η μοναδικότητα των σημάτων οδηγεί στην ανάγκη να εκπαιδευτεί το μοντέλο από την αρχή για κάθε άτομο, πράγμα που συνεπάγεται σε υψηλό υπολογιστικό κόστος.

Για τους παραπάνω λόγους οι εφαρμογές BCI χρήση κινητικής φαντασίωσης αποτελούν μεγάλο ενδιαφέρον. Στόχος της εργασίας είναι η ανάπτυξη συστήματος αναγνώρισης προτύπων διεπαφών εγκεφάλου υπολογιστή με την τεχνική κινητικής φαντασίωσης (MI). Σκοπός είναι η ταξινόμηση ενός συνόλου δεδομένων δύο δραστηριοτήτων. Τα σήματα που παρέχονται είναι γνωστά, δηλαδή δίνονται σε ποιες χρονικές περιόδους ο χρήστης υλοποιεί κάποια συγκεκριμένη διεργασία.

Το σύνολο δεδομένων που επιλέχτηκε είναι το πρώτο σύνολο δεδομένων (Data sets 1). από τον τέταρτο διαγωνισμό διεπαφών εγκεφάλου υπολογιστή (BCI competition IV).

<https://www.bbci.de/competition/iv/>

Τα δεδομένα που περιέχονται στο σύνολο δεδομένων αντιστοιχούν σε καταγεγραμμένα σήματα από επτά υγιή άτομα τα οποία συμμετείχαν στο πείραμα. Σε ολόκληρη την συνεδρία, η κινητική φαντασίωση έγινε χωρίς ανατροφοδότηση. Για κάθε άτομο επιλέχτηκαν 2 κατηγορίες κινητικής φαντασίωσης από τις τρεις (αριστερό χέρι, δεξί χέρι, πόδια). Από τα δεδομένα που παρέχονται χρησιμοποιήθηκαν τα δεδομένα βαθμονόμησης (calibration data), όπου αντιστοιχούν στα πρώτα δύο τρεξίματα. Στα δεδομένα βαθμονόμησης παρουσιάστηκαν βέλη που έδειχναν αριστερά, δεξιά ή κάτω ως οπτικά σήματα σε μια οθόνη υπολογιστή. Τα σήματα εμφανίζονταν για μια περίοδο τεσσάρων δευτερολέπτων, κατά την οποία το άτομο είχε την οδηγία να εκτελέσει την αντίστοιχη φανταστική κίνηση. Αυτές οι περιόδους εναλλάσσονταν με 2 δευτερόλεπτα κενής οθόνης, και 2 δευτερόλεπτα με ένα σταθερό σταυρό που εμφανιζόταν στο κέντρο της οθόνης. Ο σταυρός σταθεροποίησης ήταν επικαλυμμένος πάνω στις ενδείξεις, δηλαδή εμφανιζόταν για 6 δευτερόλεπτα.



Εικόνα 4.1: Ακολουθία οπτικών ερεθισμάτων σε συνεδρία του πρώτου συνόλου δεδομένων του 4^{ου} διαγωνισμού BCI. (Πηγή:

https://www.researchgate.net/publication/229077218_Review_of_the_BCI_competition_IV)

Η καταγραφή των σημάτων πραγματοποιήθηκε χρησιμοποιώντας ενισχυτές BrainAmp MR plus και ένα καπάκι ηλεκτροδίων Ag/AgCl. Μετρήθηκαν σήματα από 59 θέσεις EEG που ήταν πυκνότερα κατανεμημένες πάνω από τις αισθητηριοκινητικές περιοχές. Τα σήματα φιλτραρίστηκαν με ζωνοπερατό φίλτρο με ζώνη διέλευσης μεταξύ 0.05 και 200 Hz και στη συνέχεια ψηφιοποιήθηκαν στα 1000 Hz με ακρίβεια 16 bit (0.1 uV). Επίσης παρέχεται μία έκδοση των δεδομένων σε δειγματοληψία 100Hz. Πρώτα πραγματοποιήθηκε φιλτράρισμα των αρχικών δεδομένων με χαμηλοπερατό φίλτρο Chesbyshev τύπου II και 10^{ου} βαθμού, με απώλεια της περιοχής αποκοπής -50db και συχνότητας ζώνης αποκοπής 49 Hz, και στη συνέχεια υπολογίζοντας τον μέσο όρο των μπλοκ των δέκα δειγμάτων.

Η ανάλυση πραγματοποιήθηκε στο περιβάλλον Matlab, ενώ τα αρχεία με τα δεδομένα εισόδου προέρχονται από τον BCI διαγωνισμό, διατίθενται ελεύθερα και περιλαμβάνουν τις εξής μεταβλητές:

- **cnt**: Τα συνεχή σήματα EEG, το μέγεθος τους είναι [χρόνος x κανάλια]. Ο πίνακας αποθηκεύεται στον τύπο δεδομένων INT16. Για να την μετατροπή σε τιμές μV , χρησιμοποιείται $\text{cnt} = 0.1 * \text{double}(\text{cnt})$.
- **mrk**: Η μεταβλητή mrk περιέχει την δομή των πληροφοριών των ενδείξεων. Συγκεκριμένα περιλαμβάνει δυο μεταβλητές την pos και την y .

-pos: Αποτελεί ένα διάνυσμα που περιέχει τις θέσεις των γεγονότων μέσα στα δεδομένα σήματος EEG. Αυτές οι θέσεις δίνονται σε σημεία δείγματος EEG.

-y: Αποτελεί ένα διάνυσμα κλάσεων (-1,1) που αντιστοιχούν σε ένα γεγονός, είναι η τιμή της κλάσης σε κάθε δεδομένη θέση του διανύσματος και συνδέεται με τις θέσεις των γεγονότων της μεταβλητής pos.

- **nfo**: Περιλαμβάνει επιπλέον μεταβλητές με πληροφορίες, περιέχει τις μεταβλητές fs, clab, classes, xpos, ypos οι οποίες:

-fs: Αποτελεί τον ρυθμό δειγματοληψία.

-clab: Περιέχει τις ονομασίες των καναλιών (ηλεκτροδίων).

-classes: Περιέχει τις ονομασίες των δύο τάξεων της κινητικής φαντασίωσης.

-xpos: Περιλαμβάνει την x-θέση ηλεκτροδίων σε 2D-προβολή.

-ypos: Περιλαμβάνει την y-θέση ηλεκτροδίων σε 2D-προβολή.

Στον παρακάτω πίνακα εμφανίζονται οι δύο κατηγορίες κινητικής φαντασίωσης που δίνονται για κάθε άτομο.

Πίνακας 4.1: Οι δύο κατηγορίες κινητικής φαντασίωσης των ατόμων

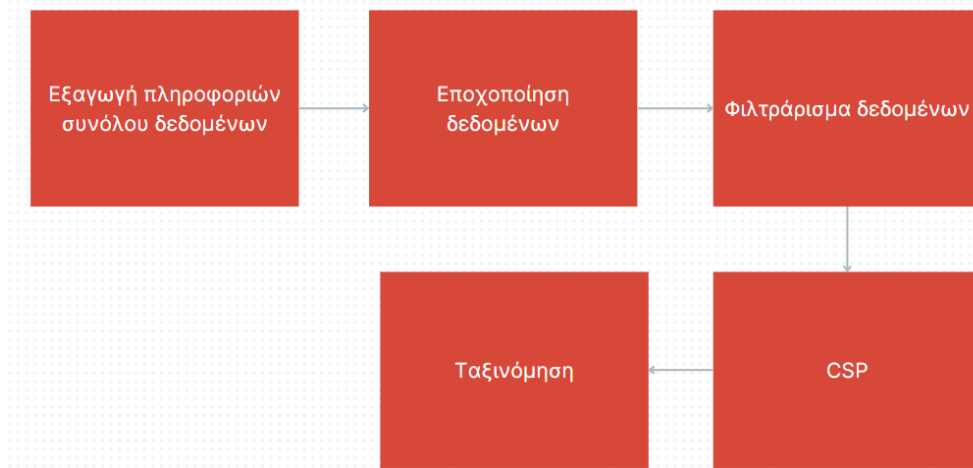
ΑΤΟΜΑ	1^η κατηγορία κινητικής φαντασίωσης (Κλάση (-1))	2^η κατηγορία κινητικής φαντασίωσης (Κλάση (1))
Άτομο A	Αριστερό χέρι	Πόδια
Άτομο B	Αριστερό χέρι	Δεξί χέρι
Άτομο C	Αριστερό χέρι	Δεξί χέρι
Άτομο D	Αριστερό χέρι	Δεξί χέρι
Άτομο E	Αριστερό χέρι	Δεξί χέρι
Άτομο F	Αριστερό χέρι	Πόδια

Άτομο G	Αριστερό χέρι	Δεξί χέρι
---------	---------------	-----------

Το σύνολο δεδομένων που επιλέχτηκε είναι το σύνολο με ρυθμό δειγματοληψίας 100Hz. Ο λόγος που επιλέχτηκε αυτό το σύνολο δεδομένων αποτελεί το μειωμένο υπολογιστικό φορτίο, χαμηλότερος ρυθμός δειγματοληψίας σημαίνει λιγότερα σημεία δεδομένων προς επεξεργασία. Αυτό μπορεί να μειώσει σημαντικά τον υπολογιστικό φόρτο, καθιστώντας τις αναλύσεις πιο γρήγορες και αποτελεσματικές. Άλλος ένας λόγος είναι ότι ο ρυθμός δειγματοληψίας 100Hz είναι επαρκής για την καταγραφή των επιθυμητών ζωνών (7-13Hz). Τέλος απλοποιεί τα στάδια προεπεξεργασίας και ανάλυσης. Μειώνει την πολυπλοκότητα των αλγορίθμων που απαιτούνται για την εξαγωγή και την ταξινόμηση χαρακτηριστικών, κάτι που είναι συχνά κρίσιμο σε εφαρμογές BCI.

4.2 Μεθοδολογία

Στο παρακάτω πλαίσιο εμφανίζονται τα βασικά βήματα για την μελέτη των σημάτων του εγκεφάλου. Το πλαίσιο αποτελείται από τα κύρια στάδια της μεθοδολογίας που πραγματοποιήθηκε για την ταξινόμηση των εγκεφαλικών σημάτων. Η ανάλυση πραγματοποιήθηκε για ένα από τα επτά άτομα.



Εικόνα 4.2: Δομή μεθοδολογίας υλοποίησης πειράματος.

4.2.1 Προ-επεξεργασία δεδομένων

Όπως έχει ήδη αναφερθεί παραπάνω, στο πρώτο στάδιο ενός βασικού συστήματος BCI υλοποιείται η ανάκτηση των δεδομένων. Το δεύτερο στάδιο αποτελεί την προεπεξεργασία δεδομένων, ώστε να διαμορφωθεί και να αναδειχθεί η επιθυμητή πληροφορία της εγκεφαλικής

δραστηριότητας, απομακρύνοντας τον θορυβο αλλά και τις ανεπιθύμητες πληροφορίες που περιέχει το σήμα. Επιθυμητό είναι η εξαγωγή πληροφορίας της δραστηριότητας μ που αντιστοιχεί σε συχνότητες (8-12)Hz. Όταν το άτομο κινεί κάποιο άκρο του σώματος τότε αυτό συνοδεύεται με την μείωση της δραστηριότητας μ στις περιοχές του κινητικού φλοιού που έχουν σχέση με το συγκεκριμένο άκρο. Η μείωση αυτή αποτελεί το ERD. Μετρώντας την ποσότητα της δραστηριότητας μ σε διαφορετικές θέσεις στον κινητικό φλοιό, μπορούμε να προσδιορίσουμε ποιο άκρο κινείται. Μέσω των κατοπτρικών νευρώνων, αυτό το φαινόμενο εμφανίζεται και όταν το άτομο κινεί ένα άκρο, αλλά και όταν το φαντάζεται, ή ακόμα και όταν ένα άτομο βλέπει ένα άλλο άτομο να κινεί ένα άκρο.

4.2.1.1 Εξαγωγή πληροφοριών συνόλου δεδομένων


Το πρώτο στάδιο είναι η εξαγωγή των πληροφοριών που παρέχονται από τον διαγωνισμό BCI δηλαδή η εξαγωγή των παραμέτρων που υπάρχουν στο αρχείο. Πιο συγκεκριμένα εξάγουμε την συχνότητα δειγματοληψίας, τα συνεχή δεδομένα (EEG) τα οποία τα μετατρέπουμε σε διαστάσεις [κανάλια x δείγματα] και τα μετατρέπουμε σε τιμές μV . Γίνεται η μέτρηση των αριθμών καναλιών και δειγμάτων που υπάρχουν υπολογίζοντας τον πίνακα δύο διαστάσεων συνεχών σημάτων. Εξάγονται οι δείκτες υπόδειξης κάθε δοκιμής, δηλαδή το πότε γίνεται το κάθε συμβάν και τους δείκτες ετικετών (κλάσεις) που ταυτοποιούν την κάθε υπόδειξη. Έπειτα εξάγονται οι πληροφορίες για τις υποδείξεις (αριστερό χέρι, δεξί χέρι, πόδια), ο αριθμός των κλάσεων, αλλά και τον αριθμό των συμβάντων που συμβαίνουν συνολικά στα δεδομένα.

4.2.1.2 Εποχοποίηση δεδομένων

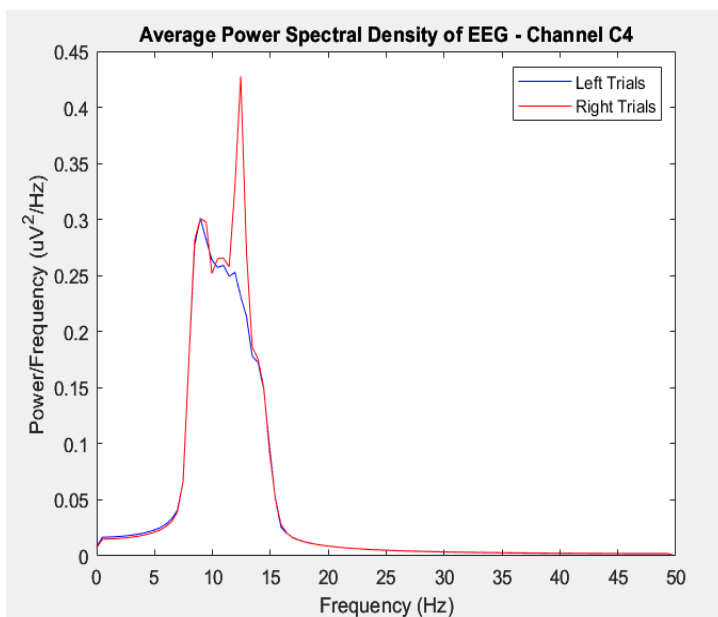
Στην εποχοποίηση των δεδομένων δημιουργείται ένα παράθυρο χρόνου, το οποίο έχει μήκος 2 δευτερολέπτων. Δημιουργούνται 2 πίνακες τριών διαστάσεων [κανάλια x δείγματα x δοκιμές] όπου ο πρώτος πίνακας (left_trials) περιλαμβάνει όλες τις δοκιμές οι οποίες ήταν η πρώτη κλάση (-1). Και αντίστοιχα ο δεύτερος πίνακας (right_trials) περιλαμβάνει όλες τις δοκιμές οι οποίες ήταν η δεύτερη κλάση (+1). Η διαδικασία αυτή ονομάζεται εποχοποίηση ή τμηματοποίηση συνεχών δεδομένων, τα χρονικά παράθυρα ονομάζονται εποχές και είναι χρονικά κλειδωμένα σε σχέση με ένα γεγονός. Το παράθυρο της εποχοποίησης ξεκινάει 0.5 δευτερόλεπτα μετά την έναρξη της υπόδειξης, αυτό πραγματοποιείται, για να δοθεί χρόνος στον άτομο να αντιδράσει και να ξεκινήσει την αντιληπτική απεικόνιση κίνησης, ώστε να γίνει καταγραφή την στιγμή που ο χρήστης είναι ενεργά ασχολούμενος με την κίνηση.

4.2.1.3 Φιλτράρισμα δεδομένων

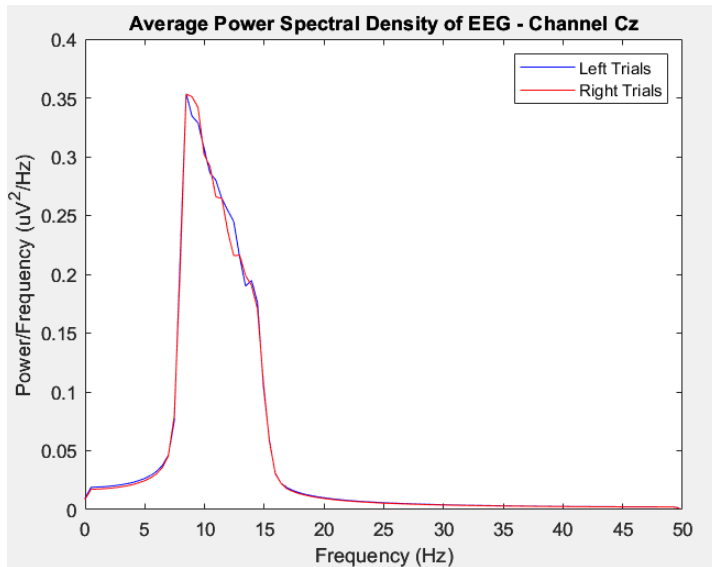
Οι κινήσεις ελέγχονται στον κινητικό φλοιό του εγκεφάλου όπου υπάρχει αυξημένο επίπεδο δραστηριότητας μ (8-13Hz) κατά την εκτέλεση κινήσεων. Με την χρήση ενός Butterworth ζωνοπερατού (bandpass) φίλτρου IIR αποκόπτονται η ανεπιθύμητες συχνότητες χρησιμοποιώντας ζώνη διέλευσης (8-15)Hz για την λήψη χρήσιμης πληροφορία. Η επιλογή του εύρους έγινε καθώς η δραστηριότητα μ σε κάθε εγκέφαλο άτομο είναι διαφορετικός, κάθε εγκέφαλος έχει την δική του ταυτότητα στα εγκεφαλικά σήματα.



Εικόνα 4.3: Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C3 για το Άτομο e.



Εικόνα 4.4: Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C4 για το Άτομο e.



Εικόνα 4.5: Μέση Φασματική Πυκνότητα Ισχύος (PSD) καναλιού C4 για το Άτομο ε.


Στις παραπάνω εικόνες απεικονίζεται η Μέση Φασματική Πυκνότητα Ισχύος (PSD) των δεδομένων EEG για τα κανάλια C3, CZ, C4. Το κανάλι C3 βρίσκεται συνήθως πάνω από τον κινητικό φλοιό στην αριστερή πλευρά του εγκεφάλου και αντιπροσωπεύει τον δεξί χέρι. Το C4 βρίσκεται στην δεξιά πλευρά του κινητικού φλοιού και έχει σχέση με το αριστερό χέρι. Το CZ βρίσκεται στο κέντρο (Εικόνα 2.3). Η Μπλε γραμμή αντιπροσωπεύει τη μέση φασματική πυκνότητα ισχύος κατά τη διάρκεια των left trials (κλάση -1) που αντιστοιχούν στις φανταστικές κινήσεις του αριστερού χεριού, και η κόκκινη γραμμή αντιστοιχεί στις κινήσεις του φανταστικού δεξιού χεριού (κλάση +1). Στην εικόνα παρατηρείται ότι το δεξί ημισφαίριο, ο ρυθμός mu για την κίνηση του αριστερού χεριού είναι χαμηλότερος από ότι για την κίνηση του δεξιού χεριού λόγω του ERD. Στο αριστερό ηλεκτρόδιο, ο ρυθμός mu για την κίνηση του δεξιού χεριού μειώνεται, και στο κεντρικό ηλεκτρόδιο η δραστηριότητα mu είναι ίδια και για τις δύο κλάσεις.

4.2.2 Εξαγωγή χαρακτηριστικών

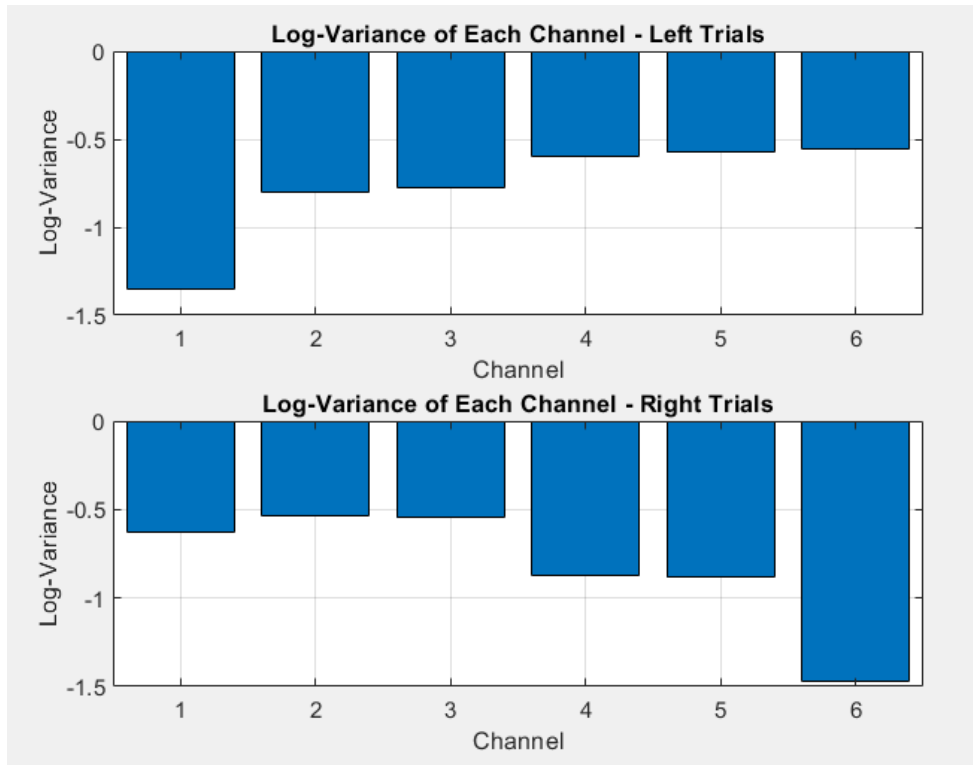
Ο αλγόριθμος που χρησιμοποιείται για την εξαγωγή χαρακτηριστικών είναι ο CSP, ο λόγος που επιλέχτηκε επειδή είναι ιδιαίτερα αποτελεσματικός στην ενίσχυση της διακριτικότητας δύο διακριτών καταστάσεων κινητικής φαντασίωσης. Χρησιμοποιήθηκαν 6 χωρικά φίλτρα, επιλέχθηκαν τα 3 πρώτα που μεγιστοποιούν περισσότερο την διακύμανση της μίας τάξης ενώ ελαχιστοποιούν την διακύμανση της δεύτερης τάξης, και τα 3 τελευταία που μεγιστοποιούν περισσότερο την διακύμανση της δεύτερης τάξης ενώ ελαχιστοποιούν την διακύμανση της πρώτης τάξης.

Το χαρακτηριστικό που χρησιμοποιήθηκε είναι ο λογάριθμος της διακύμανσης. Η διακύμανση παρέχει ένα ποσοτικό μέτρο της διασποράς του σήματος, αντικατοπτρίζοντας τον τρόπο με τον οποίο οι μετρήσεις EEG εξαπλώνονται γύρω από το μέσο όρο, επισημαίνοντας έτσι τα διακριτικά μοτίβα που σχετίζονται με κάθε φανταστική κίνηση. Επιπλέον ο λογάριθμος κανονικοποιεί την κατανομή των χαρακτηριστικών, κάνοντας τον χώρο χαρακτηριστικών πιο γραμμικό και διαχειρίσιμο για τους αλγορίθμους ταξινόμησης.

Στις παρακάτω εικόνες απεικονίζεται ο λογάριθμος της διακύμανσης αντίστοιχα σε κάθε κανάλι πριν και μετά την χρήση του αλγορίθμου CSP. Πριν την χρήση του αλγορίθμου παρατηρείται ότι τα κανάλια έχουν μικρή διαφορά στις τιμές που οφείλετε στο γεγονός ότι οι δύο κλάσεις έχουν παρόμοιες μέσες τιμές λογαριθμικής διακύμανσης σε κάθε κανάλι και υποδεικνύει ότι τα μοτίβα δραστηριότητας του εγκεφάλου είναι παρόμοια κατά τη διάρκεια των δύο κλάσεων. παρατηρείται ότι η μέση τιμή της λογαριθμικής διακύμανσης κάθε καναλιού διαφέρει, δηλαδή τα πρώτα φίλτρα μεγιστοποιούν τη διακύμανση της πρώτης κλάσης ενώ ελαχιστοποιούν την διακύμανση της δεύτερης τάξης, ενώ τα τελευταία φίλτρα μεγιστοποιούν τη διακύμανση της δεύτερης τάξης, ενώ ελαχιστοποιούν τη διακύμανση της πρώτης.




Εικόνα 4.6: Μέση τιμή Λογαριθμικής διακύμανσης κάθε καναλιού ατόμου d




Εικόνα 4.7: Μέση τιμή λογαριθμικής διακύμανσης χρήση των 6 φίλτρων του αλγορίθμου CSP για το άτομο d.

Η διαχωριστικότητα των δύο κλάσεων μπορεί να απεικονιστεί και σε διάγραμμα διασποράς. Το διάγραμμα διασποράς αποτελεί σημαντικό εργαλείο για την διάκριση των δύο κλάσεων. Στις παρακάτω εικόνες απεικονίζονται οι δύο κλάσεις σε ένα δισδιάστατο επίπεδο. Στην πρώτη εικόνα παρατηρούνται τα σημεία των δύο κλάσεων να είναι τυχαία στο διάγραμμα διασποράς. Με την χρήση του αλγόριθμου CSP τα σημεία των δύο κλάσεων διακρίνονται αισθητά στο διάγραμμα διασποράς, Τα σημεία της κλάσης left (κλάση -1) συγκεντρώνονται κατά κάποιο τρόπο αριστερά πάνω, σε σύγκριση με τα σημεία κλάσης δεξιά (κλάση +1) που συγκεντρώνονται δεξιά κάτω. Αξίζει να σημειωθεί ότι επιλέγονται τα πρώτα στοιχεία και τα τελευταία στοιχεία καθώς περιέχουν τις πιο διακριτικές πληροφορίες για την ταξινόμηση των κλάσεων.



Εικόνα 4.8: Διάγραμμα διασποράς συναρτήσεως πρώτου και τελευταίου στοιχείου.



Εικόνα 4.9: Διάγραμμα διασποράς συναρτήσεως πρώτου και τελευταίου στοιχείου χρήση αλγορίθμου CSP για το άτομο d

4.2.3 Ταξινόμηση δεδομένων

Οι αλγόριθμοι ταξινόμησης που χρησιμοποιήθηκαν είναι:

- Ανάλυση Γραμμικής Διάκρισης (LDA)
- Μηχανές Διανυσματικής Υποστήριξης (SVM)

Ο λόγος που μπόρεσαν να χρησιμοποιηθούν και να συγκριθούν αυτοί οι δύο ταξινομητές, ένας γραμμικός (LDA) και ένας μη γραμμικός (SVM), είναι χάρη στην προεπεξεργασία που έχει προηγηθεί με τον CSP. Συγκεκριμένα, ο αλγόριθμος CSP ενισχύει την διαχωριστικότητα μεταξύ των δύο κλάσεων, επιτρέποντας έτσι την χρήση γραμμικών ταξινομητών.

Για την μελέτη των δύο αλγορίθμων ταξινόμησης το σύνολο δεδομένων χωρίστηκε σε δεδομένα εκπαίδευσης και δεδομένα ελέγχου, αυξάνοντας προοδευτικά το ποσοστό των δεδομένων εκπαίδευσης. Συγκεκριμένα, πραγματοποιήθηκε διαχωρισμός των δεδομένων (α) σε 50% δεδομένα εκπαίδευσης και 50% δεδομένα ελέγχου, (β) σε 70%-30% και (γ) σε 80%-20%, αντίστοιχα. Οι διαχωρισμοί αυτοί αφορούσαν και τους δύο αλγόριθμους ταξινόμησης.

Ο έλεγχος πραγματοποιήθηκε σε 2 φάσεις:

- Στην πρώτη φάση χρησιμοποιήθηκαν για τον έλεγχο τα ίδια τα δεδομένα εκπαίδευσης, για να ελεγχθεί πόσο καλά έχει εκπαιδευθεί ο αλγόριθμος. Αυξήθηκαν προοδευτικά τα δεδομένα εισόδου από 50% του διαθέσιμου συνόλου έως και 100% του διαθέσιμου συνόλου, για να μελετηθεί αν τα μεγαλύτερα data sets αυξάνουν και τις επιδόσεις των ταξινομητών.
- Στη δεύτερη φάση χρησιμοποιήθηκαν για τον έλεγχο τα «ξένα» δεδομένα που είχαν κρατηθεί εκτός εκπαίδευσης (hold-out), δηλαδή το 50% / 30% / 20% των συνολικών δεδομένων κατά περίπτωση, προκειμένου να αξιολογηθεί η ικανότητα του κάθε αλγορίθμου για γενίκευση, δηλαδή σωστή κατηγοριοποίηση άγνωστων δεδομένων. Παρακάτω εμφανίζονται τα αποτελέσματα ανά φάση ελέγχου.

(A) Αποτελέσματα 1^{ης} φάσης (σύνολο ελέγχου = σύνολο εκπαίδευσης)

Πίνακας 4.2: Αποτελέσματα LDA με δεδομένα εκπαίδευσης το 50% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	77.0	80.0	74.0
Άτομο Β	92.0	90.0	94.0
Άτομο C	91.0	88.0	94.0
Άτομο D	92.0	94.0	90.0

Άτομο Ε	97.0	96.0	98.0
Άτομο F	93.0	90.0	96.0
Άτομο G	97.0	96.0	98.0
Μέσος όρος	91.3	90.6	92.0

Πίνακας 4.3: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 50% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	75.0	74.0	76.0
Άτομο Β	91.0	88.0	94.0
Άτομο C	92.0	92.0	92.0
Άτομο D	92.0	94.0	90.0
Άτομο Ε	98.0	96.0	100.0
Άτομο F	94.0	92.0	96.0
Άτομο G	97.0	96.0	98.0
Μέσος όρος	91.3	90.3	92.3

Πίνακας 4.4: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 70% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	70.7	77.1	64.3
Άτομο Β	87.1	87.1	87.1
Άτομο C	90.7	91.4	90.0
Άτομο D	90.7	92.9	88.6
Άτομο Ε	96.4	94.3	98.6
Άτομο F	95.0	94.3	95.7
Άτομο G	95.7	91.4	100.0
Μέσος όρος	89.5	89.8	89.2

Πίνακας 4.5: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 70% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	75.0	78.6	71.4
Άτομο Β	86.4	88.6	84.3
Άτομο C	92.1	94.3	90.0
Άτομο D	90.7	92.9	88.6
Άτομο E	96.4	94.3	98.6
Άτομο F	95.7	95.7	95.7
Άτομο G	95.7	92.9	98.6
Μέσος όρος	90.3	91.0	89.6

Πίνακας 4.6: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 80% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	71.2	75.0	67.5
Άτομο Β	88.1	90.0	86.2
Άτομο C	90.0	88.8	91.2
Άτομο D	91.9	92.5	91.2
Άτομο E	95.0	93.8	96.2
Άτομο F	93.1	91.2	95.0
Άτομο G	96.9	93.8	100.0
Μέσος όρος	89.5	89.3	89.6

Πίνακας 4.7: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 80% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	71.9	76.2	67.5
Άτομο Β	88.1	90.0	86.2
Άτομο C	90.6	92.5	88.8

Άτομο D	91.9	92.5	91.2
Άτομο E	94.4	93.8	95.0
Άτομο F	92.5	91.2	93.8
Άτομο G	96.9	93.8	100
Μέσος όρος	89.5	90.0	88.9

Πίνακας 4.8: Αποτελέσματα αλγορίθμου LDA με δεδομένα εκπαίδευσης το 100% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο A	74.5	77.0	72.0
Άτομο B	83.0	85.0	81.0
Άτομο C	91.5	89.0	94.0
Άτομο D	93.5	94.0	93.0
Άτομο E	95.0	93.0	97.0
Άτομο F	93.5	90.0	97.0
Άτομο G	94.5	91.0	98.0
Μέσος όρος	89.4	88.4	90.3

Πίνακας 4.9: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, με δεδομένα εκπαίδευσης το 100% του συνόλου και έλεγχο με τα ίδια δεδομένα εκπαίδευσης.

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο A	78.5	78.0	79.0
Άτομο B	83.0	86.0	80.0
Άτομο C	92.0	92.0	92.0
Άτομο D	92.5	94.0	91.0
Άτομο E	95.5	93.0	98.0
Άτομο F	93.5	91.0	96.0
Άτομο G	94.0	91.0	97.0
Μέσος όρος	89.9	89.3	90.4

(B) Αποτελέσματα 2^{ης} φάσης (σύνολο ελέγχου ≠ σύνολο εκπαίδευσης)

Πίνακας 4.10: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 50% των δεδομένων και έλεγχο με το υπόλοιπο 50% των δεδομένων (50% hold-out)

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	57.0	34.0	80.0
Άτομο Β	65.0	68.0	62.0
Άτομο C	83.0	82.0	84.0
Άτομο D	91.0	92.0	90.0
Άτομο E	92.0	92.0	92.0
Άτομο F	87.0	98.0	76.0
Άτομο G	92.0	88.0	96.0
Μέσος όρος	81.0	79.1	82.9

Πίνακας 4.11: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 50% των δεδομένων και έλεγχο με το υπόλοιπο 50% των δεδομένων (50% hold-out)

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	59.0	40.0	78.0
Άτομο Β	64.0	64.0	64.0
Άτομο C	86.0	88.0	84.0
Άτομο D	91.0	92.0	90.0
Άτομο E	91.0	90.0	92.0
Άτομο F	84.0	100.0	68.0
Άτομο G	93.0	90.0	96.0
Μέσος όρος	81.1	80.6	81.7

Πίνακας 4.12: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 70% των δεδομένων και έλεγχο με το υπόλοιπο 30% των δεδομένων (30% hold-out).

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο Α	56.7	36.7	76.7
Άτομο Β	58.3	53.3	63.3
Άτομο C	86.7	86.7	86.7
Άτομο D	96.7	93.3	100.0
Άτομο E	91.7	93.3	90.0

Άτομο F	90.0	93.3	86.7
Άτομο G	90.0	83.3	96.7
Μέσος όρος	81.4	77.1	85.7

Πίνακας 4.13: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 70% των δεδομένων και έλεγχο με το υπόλοιπο 30% των δεδομένων (30% hold-out)..

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο A	65.0	53.3	76.7
Άτομο B	60.0	56.7	63.3
Άτομο C	86.7	93.3	80.0
Άτομο D	96.7	93.3	100.0
Άτομο E	91.7	93.3	90.0
Άτομο F	88.3	93.3	83.3
Άτομο G	90.0	83.3	96.7
Μέσος όρος	82.6	80.9	84.3

Πίνακας 4.14: Αποτελέσματα αλγορίθμου LDA για εκπαίδευση με το 80% των δεδομένων και έλεγχο με το υπόλοιπο 20% των δεδομένων (20% hold-out).

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
Άτομο A	62.5	60.0	65.0
Άτομο B	67.5	60.0	75.0
Άτομο C	92.5	90.0	95.0
Άτομο D	97.5	95.0	100.0
Άτομο E	92.5	95.0	90.0
Άτομο F	90.0	100.0	80.0
Άτομο G	85.0	75.0	95.0
Μέσος ορός	83.9	82.1	85.7

Πίνακας 4.15: Αποτελέσματα αλγορίθμου SVM με γραμμικό πυρήνα, για εκπαίδευση με το 80% των δεδομένων και έλεγχο με το υπόλοιπο 20% των δεδομένων (20% hold-out).

ΑΤΟΜΑ	Ακρίβεια (%)	Ευαισθησία (%)	Ειδικότητα (%)
-------	--------------	----------------	----------------

Άτομο Α	67.5	70.0	65.0
Άτομο Β	65.0	60.0	70.0
Άτομο C	90.0	95.0	85.0
Άτομο D	95.0	90.0	100.0
Άτομο E	92.5	95.0	90.0
Άτομο F	87.5	100.0	75.0
Άτομο G	87.5	80.0	95.0
Μέσος όρος	83.6	84.3	82.9

Πίνακας 4.16: Συγκριτικός Πίνακας Αποτελεσμάτων Αλγορίθμων (1^η φάση, 2^η φάση).

ΠΙΚΑΝΑΣ	M.O.	M.O.	M.O.
	Ακρίβεια (%)	Ευαισθησίας (%)	Ειδικότητας (%)
Φάση 1^η			
4.2 (LDA 50%)	91.3	90.6	92.0
4.3 (SVM 50%)	91.3	90.3	92.3
4.4 (LDA 70%)	89.5	89.8	89.2
4.5 (SVM 70%)	90.3	91.0	89.6
4.6 (LDA 80%)	89.5	89.3	89.6
4.7 (SVM 80%)	89.8	90.0	88.9
4.8 (LDA 100%)	89.4	88.4	90.3
4.9 (SVM 100%)	89.9	89.3	90.4
Φάση 2^η			
4.10 (LDA 50%-50%)	81.0	79.1	82.9
4.11 (SVM 50%-50%)	81.1	80.6	81.7
4.12 (LDA 70%-30%)	81.4	77.1	85.7
4.13 (SVM 70%-30%)	82.6	80.9	84.3
4.14 (LDA 80%-20%)	83.9	82.1	85.7
4.15 (SVM 80%-20%)	83.6	84.3	82.9

Στον Πίνακα 4.16 εμφανίζεται ο μέσος όρος σε κάθε περίπτωση για κάθε αξιολογητή, για κάθε περίπτωση για όλα τα άτομα.

Στην πρώτη φάση, όπου χρησιμοποιείται το ίδιο το σύνολο των δεδομένων της εκπαίδευσης και για τον έλεγχο, το αποτέλεσμα είναι αρκετά υψηλά. Σε αυτές τις σειρές του Πίνακα 4.16, τόσο το LDA όσο και το SVM εμφανίζουν υψηλές επιδόσεις ευαισθησίας, ειδικότητας και ακρίβειας, που κυμαίνονται γύρω στο 90%, με μικρή διακύμανση κατά περίπτωση. Αν και αυτό το ποσοστό δεν είναι 100%, είναι πάντως αρκετά υψηλό ώστε να θεωρηθεί ότι το μοντέλο έχει εκπαιδευθεί ικανοποιητικά. Βελτιστοποιήσεις στις παραμέτρους ενδέχεται να αυξήσουν περισσότερο το ποσοστό αυτό. Οι υψηλές επιδόσεις στην 1^η φάση είναι αναμενόμενες: όταν ένα μοντέλο αξιολογείται στο ίδιο σύνολο δεδομένων στο οποίο εκπαιδεύτηκε, έχει να αντιμετωπίσει ένα σχετικά εύκολο πρόβλημα. Συχνά εδώ κρύβεται ο κίνδυνος του overfitting, που εμφανίζεται όταν ένας αλγόριθμος εμφανίζει σημαντική διαφορά μεταξύ πολύ υψηλών επιδόσεων στην 1^η φάση ελέγχου (testing set = training set) και πολύ χαμηλότερων στη 2^η φάση ελέγχου (testing set ≠ training set). Στην περίπτωση αυτή, ο αλγόριθμος έχει "απομνημονεύσει" τα δεδομένα αντί να "μάθει" τα μοτίβα, γι' αυτό και οι μετρήσεις απόδοσης είναι τεχνητά υψηλές στο σύνολο εκπαίδευσης αλλά πολύ χαμηλές στο σύνολο ελέγχου.

Όπως φαίνεται από το κάτω μισό του Πίνακα 4.16, (2^η φάση, σύνολο εκπαίδευσης ≠ συνόλου ελέγχου), στην παρούσα περίπτωση δεν συμβαίνει overfitting. Όλες οι επιδόσεις και των δύο αλγορίθμων είναι χαμηλότερες εδώ σε σχέση με την 1^η φάση ελέγχου, αλλά όχι σε βαθμό που να υποψιάζει για overfitting. Η ακρίβεια, ειδικότερα κινείται μεταξύ 81% και 83.9%, που είναι πολύ ικανοποιητικά ποσοστά. Επίσης στη 2^η φάση παρατηρείται ότι και στις 3 περιπτώσεις, 50%-50%, 70%-30% και 80%-20% για τα σύνολα δεδομένων εκπαίδευσης και ελέγχου, αντίστοιχα, υπάρχει μία γενική τάση ο SVM να ξεπερνά ελαφρώς τον LDA σε όρους ακρίβειας. Παρατηρούμε επίσης ότι καθώς αυξάνει το ποσοστό των δεδομένων εκπαίδευσης από 50% σε 70% και 80%, και στους δύο αλγορίθμους η ακρίβεια αυξάνεται.

Μια άλλη παρατήρηση που προκύπτει από τα αναλυτικά αποτελέσματα ανά άτομο (Πίνακες 4.2-4.9 αλλά και Πίνακες 4.10-4.15), είναι ότι για συγκεκριμένα άτομα (τα Α και Β) οι επιδόσεις και των δύο αλγορίθμων είναι αισθητά χαμηλότερες από τις επιδόσεις στα υπόλοιπα άτομα, χαμηλώνοντας έτσι και την μέση επίδοση. Κύριος λόγος που ο ταξινομητής σε κάποια άτομα βγάζει μικρό ποσοστό ακρίβειας είναι η προ-επεξεργασία του σήματος, καθώς και η εξαγωγή χαρακτηριστικών με χρήση της μεθόδου (CSP). Συγκεκριμένα, σε διαφορετικά άτομα είναι σύνηθες να παρατηρείται μεταβλητότητα στα προκύπτοντα χωρικά φίλτρα για διάφορους λόγους. Ένας λόγος είναι ότι η ανατομία και η φυσιολογία του εγκεφάλου κάθε ατόμου διαφέρει, γεγονός που οδηγεί σε διαφορές στα μοτίβα σημάτων EEG, ακόμα και όταν εκτελούνται οι ίδιες φανταστικές εργασίες. Αυτή η μεταβλητότητα σημαίνει ότι τα φίλτρα CSP που έχουν

βελτιστοποιηθεί για ένα άτομο μπορεί να μην είναι βέλτιστα για ένα άλλο. Επιπλέον οι διακυμάνσεις στην ποιότητα του σήματος οφείλονται σε παράγοντες όπως η τοποθέτηση ηλεκτροδίων, η αντίσταση δέρματος-ηλεκτροδίου και το επίπεδο θορύβου στο περιβάλλον εγγραφής, τέτοιοι παράγοντες επηρεάζουν την ικανότητα του αλγόριθμου CSP να βρίσκει διακριτικά χωρικά φίλτρα. Άλλος ένας λόγος έχει σχέση με τον βαθμό στον οποίο τα άτομα αφοσιώνονται στην διεργασία κατά την εγγραφή. Εάν ένα άτομο δεν είναι εστιασμένο και συγκεντρωμένο εκείνη τη στιγμή ή είναι ασυνεπές κατά την διάρκεια της διεργασίας, τα αντίστοιχα σήματα EEG ενδέχεται να μην αντικατοπτρίζουν ξεκάθαρα μοτίβα προς εκμετάλλευση από το CSP. Ένας ακόμη παράγων είναι και ο ρυθμός μ , που ποικίλλει σημαντικά μεταξύ των ατόμων ως προς τη ζώνη συχνοτήτων και την τοπογραφία. Αυτή η μεταβλητότητα μπορεί να επηρεάσει τα χωρικά φίλτρα που προέρχονται από τον αλγόριθμο CSP. Τέλος σε κάποια άτομα είναι απαραίτητος ένας μεγάλος αριθμός δοκιμών (trials) με τον αλγόριθμο CSP για την καλύτερη εκτίμηση χωρικών φίλτρων, αλλιώς μπορεί να οδηγήσει σε λιγότερα αξιόπιστα φίλτρα.

ΚΕΦΑΛΑΙΟ 5: Συμπεράσματα

Στην παρούσα διπλωματική εργασία πραγματοποιήθηκε έρευνα στις διεπαφές εγκεφάλου υπολογιστή, για την πραγματοποίηση της μελέτης ήταν αναγκαίο αρχικά να μελετηθεί η φυσιολογία του ανθρώπινου εγκεφάλου για την περαιτέρω κατανόηση των συστημάτων BCI. Έπειτα έγινε εκτενείς ανάλυση γύρω από την βασική δομή των BCI, αναφέρθηκαν τα βήματα για την δημιουργία τέτοιων συστημάτων καθώς και αξιολογητές για τον έλεγχο των συστημάτων. Στο πειραματικό μέρος της εργασίας, πραγματοποιήθηκε μελέτη στο πρώτο σύνολο δεδομένων του 4^{ου} διαγωνισμού BCI, ακολουθήθηκε η βασική που αναφέρεται στην θεωρία για την δημιουργία συστήματος ταξινόμησης των κλάσεων. Πιο συγκεκριμένα, για την προετοιμασία των δεδομένων, χρησιμοποιήθηκε ζωνοπερατό φίλτρο, για την άντληση μόνο της χρήσιμης πληροφορίας, έπειτα υλοποιήθηκε εξαγωγή δεδομένων χρησιμοποιώντας τον αλγόριθμο CSP, και αφού έγινε η προετοιμασία των δεδομένων χρησιμοποιήθηκαν δύο ταξινομητές, ο αλγόριθμος LDA και ο αλγόριθμος SVM με γραμμικό πυρήνα. Στη συνέχεια έγινε σύγκριση μεταξύ των αλγορίθμων ως προς τις επιδόσεις κατηγοριοποίησης, με την συγκεκριμένη προετοιμασία δεδομένων. Καλύτερος ταξινομητής βρέθηκε ότι είναι ο αλγόριθμος SVM καθώς έφερε καλύτερα αποτελέσματα (ακρίβεια, ευαισθησία, ειδικότητα).

Ωστόσο τα περισσότερα από τα συστήματα BCI δοκιμάζονται σε ένα εποπτευόμενο εργαστήριο και όχι σε πραγματικό περιβάλλον. Όταν σχεδιάζεται ένα σύστημα BCI, είναι απαραίτητο να διερευνηθεί το περιβάλλον στο οποίο μπορεί να χρησιμοποιηθεί η τεχνολογία. Είναι σημαντικό να μελετηθούν διεξοδικά οι απαιτήσεις του συστήματος, οι περιβαλλοντικοί παράγοντες, οι συνθήκες και τα άτομα για τα οποία προορίζεται αυτή η τεχνολογία, ήδη από την αρχική φάση σχεδιασμού του συστήματος.

Επιπλέον, υπάρχουν πολλές σκέψεις γύρω από ηθικά ζητήματα που ξεκινούν από το BCI, καθώς εμπλέκει θέματα που ανήκουν σε πολλαπλούς τομείς.

- Ένα από τα ζητήματα είναι ποιος φέρει την ευθύνη σε περιπτώσεις που το σύστημα BCI λειτουργήσει λανθασμένα: το άτομο που το χρησιμοποιεί ή ο κατασκευαστής;
- Άλλο ένα ζήτημα αφορά την αυτονομία του ατόμου, δηλαδή μέχρι ποιο βαθμό το άτομο είναι αυτόνομο όταν χρησιμοποιεί BCI;
- Υπάρχει κίνδυνος τα συστήματα BCI να επηρεάσουν τις αποφάσεις ή τις πράξεις του ατόμου;

- Άλλο ζήτημα είναι πώς μπορεί να εξασφαλιστεί ότι τα άτομα παρέχουν μετά από πλήρη κατανόηση τη συναίνεσή τους για την χρήση BCI, ιδιαίτερα σε λεπτές περιπτώσεις όπως η νευρο-ενίσχυση.

Αυτά τα ηθικά θέματα απαιτούν προσεκτική σκέψη και συζήτηση μεταξύ ερευνητών, κατασκευαστών, χρηστών και νομοθετών για να διασφαλιστεί ότι η τεχνολογία BCI αναπτύσσεται και χρησιμοποιείται με τρόπο που σέβεται τα ηθικά πρότυπα και την ανθρώπινη αξιοπρέπεια.

ΒΙΒΛΙΟΓΡΑΦΙΑ

1. C.-Y. Chiang, H.-C. Chu, and N.-H. Liu, "Recognizing the Degree of Human Attention Using EEG Signals," *Sensors*, vol. 13, no. 8, pp. 10273–10286, 2013.
2. Ε. Πέτρου, "Εγκεφαλικά Δίκτυα Μέγιστης Ροής Συγχρονισμού Φάσης Μαγνητοεγκεφαλογραφικών Σημάτων," Διπλωματική Εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πολυτεχνείο Κρήτης, Χανιά, 2018.
3. Ινστιτούτο Τεχνολογίας Υπολογιστικών Εκδόσεων (ITYE) "Διόφαντος," Βιολογία Α' Γενικού Λυκείου: http://ebooks.edu.gr/ebooks/v/html/8547/2666/Biologia_A-Lykeiou_html-empl/index9.htm
4. "Ιατρική Φυσική: Φυσική του Ανθρώπινου Σώματος Σημειώσεις," Τμήμα Ιατρικής, Εθνικό και Καποδιστριακό Πανεπιστήμιο Αθηνών: https://eclass.uoa.gr/modules/document/file.php/MED684/IATRIKH-FYSIKH_FYSIKH-TOY-ANΘΡΩΠΙΝΟΥ-ΣΩΜΑΤΟΣ_ΣΗΜΕΙΩΣΕΙΣ_1-corr.pdf.
5. "Electroencephalography," Wikipedia: <https://en.wikipedia.org/wiki/Electroencephalography> .
6. "Δυναμικό ενέργειας," Wikipedia: https://el.wikipedia.org/wiki/Δυναμικό_ενέργειας
7. Ε. Γρηγοράκου, "Επεξεργασία και ανάλυση ηλεκτροεγκεφαλογραφικών σημάτων για την αναγνώριση συγκεντρωτικής του προσεκτικού," Διπλωματική Εργασία, Τμήμα Μηχανικών Βιοϊατρικής Τεχνολογίας, Πανεπιστήμιο Δυτικής Αττικής, Αθήνα, Ιούλιος 2021.
8. Ι.-Χ. Παπαματθαίου, "ΑΝΑΛΥΣΗ ΣΗΜΑΤΟΣ ERP/EEG ΜΕ ΧΡΗΣΗ ΤΟΥ ΠΡΟΓΡΑΜΜΑΤΟΣ LORETA", Αθήνα, 2019.
9. "Βασική Ανατομία του Κεντρικού Νευρικού Συστήματος," Παιδιατρική Νευροχειρουργική: <https://pediatric-neurosurgery.com/anatomy>.
10. Β. Γιάγκα, "Επεξεργασία εικόνων μαγνητικής τομογραφίας εγκεφάλου με αισθητική λογική," Διπλωματική Εργασία, Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, Θεσσαλονίκη, Νοέμβριος 2009.
11. Μ. Γεωργίου, "Διεπαφή BCI για τον έλεγχο συσκευών υποβοήθησης κίνησης," Διπλωματική Εργασία, Τμήμα Ηλεκτρολόγων Μηχανικών και Τεχνολογίας Υπολογιστών, Πανεπιστήμιο Πάτρας, Πάτρα, Μάρτιος 2020.
12. Λ. Θερμός, "Αναγνώριση κίνησης κάτω άκρων μέσω εφαρμογής τεχνικών Machine Learning σε σήματα EEG με χρήση επικαλυπτόμενων παραθύρων," Διπλωματική Εργασία, Σχολή Ηλεκτρολόγων και Μηχανικών Υπολογιστών, Εθνικό Μετσόβιο Πολυτεχνείο, Ιούλιος 2020.

13. J. N. Mak and J. R. Wolpaw, "Clinical Applications of Brain-Computer Interfaces: Current State and Future Prospects," *IEEE Rev. Biomed. Eng.*, vol. 2, pp. 187-199, 2009, doi: 10.1109/RBME.2009.2035356. PMID: 20442804; PMCID: PMC2862632.
14. M. F. Mridha, S. C. Das, M. M. Kabir, A. A. Lima, M. R. Islam, and Y. Watanobe, "Brain-Computer Interface: Advancement and Challenges," in *Sensors*, vol. 21, no. 17, p. 5746, 2021. [Online]. Available: <https://doi.org/10.3390/s21175746>
15. R. Bousseta, I. El Ouakouak, M. Gharbi, and F. Regragui, "EEG based brain computer interface for controlling a robot arm movement through thought," in *IRBM*, vol. 39, pp. 129–135, 2018.
16. Λ. Νικόλαου, "Μια Αρχιτεκτονική Βαθιάς Μηχανικής Μάθησης για Φιλτράρισμα και Ταξινόμηση Δεδομένων σε ΗΕΓ Νοερής Κίνησης," Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πολυτεχνείο Κρήτης, Χανιά, 2020.
17. C. Klaes, "Chapter 28 - Invasive Brain-Computer Interfaces and Neural Recordings From Humans," in *Handbook of Behavioral Neuroscience*, D. Manahan-Vaughan, Ed. Elsevier, vol. 28, pp. 527-539, 2018.
18. "Introduction to Brain-Computer Interfaces," NeuroTechEDU: <https://learn.neurotechedu.com/introtobci/#semi-invasive>
19. B. Sambana and P. Mishra, "A Survey on Brain-Computer Interaction," arXiv preprint arXiv:2201.00997, 2022: <https://arxiv.org/abs/2201.00997>
20. Μ. Κυριακού, "Χρήση Διεπαφών Εγκεφάλου-Υπολογιστή στην Αποκατάσταση Επικοινωνίας Ασθενών με Σύνδρομο Εγκλεισμού," 2021: <https://doi.org/10.13140/RG.2.2.18459.39205>
21. R. Maskeliunas, R. Damaševičius, I. Martišius, and M. Vasiljevas, "Consumer-grade EEG devices: Are they usable for control tasks?" in *PeerJ*, vol. 4, 2016. doi: 10.7717/peerj.1746.
22. "The 10-20 System for EEG," TMSi Blog, TMS International: <https://info.tmsi.com/blog/the-10-20-system-for-eeeg>
23. F. Lotte, L. Bougrain, and M. Clerc, "Electroencephalography (EEG)-Based Brain-Computer Interfaces," in *Wiley Encyclopedia of Electrical and Electronics Engineering*, 2015. doi: 10.1002/047134608X.W8278.
24. "Event-related potential," Wikipedia. [Online]. Available: https://en.wikipedia.org/wiki/Event-related_potential.
25. S. Sur and V. K. Sinha, "Event-related potential: An overview," *Ind Psychiatry J.*, vol. 18, no. 1, pp. 70-73, Jan. 2009. doi: 10.4103/0972-6748.57865. PMID: 21234168; PMCID: PMC3016705.

26. Rashid, Mamunur & Sulaiman, Norizam & Mustafa, Mahfuzah & Khatun, Sabira & Bari, Bifta & Hasan, Md Jahid. (2020). Recent Trends and Open Challenges in EEG Based Brain-Computer Interface Systems. 10.1007/978-981-15-2317-5_31.
27. Obeid, Hasan & Khettab, Hakim & Marais, Louise & Hallab, Magid & Laurent, Stéphane & Boutouyrie, Pierre. (2017). Evaluation of arterial stiffness by finger-toe pulse wave velocity: optimization of signal processing and clinical validation. Journal of hypertension. 35. 10.1097/HJH.0000000000001371.
28. M. Y. M. Naser and S. Bhattacharya, "Towards Practical BCI-Driven Wheelchairs: A Systematic Review Study," in IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 31, pp. 1030-1044, 2023, doi: 10.1109/TNSRE.2023.3236251.
29. Zahra Khademi, Farideh Ebrahimi, Hussain Montazery Kordy, A review of critical challenges in MI-BCI: From conventional to deep learning methods, Journal of Neuroscience Methods, Volume 383, 2023, 109736, ISSN 0165-0270
30. Bisina, K. V., & Azeez, M. A. (2017). "Optimized estimation of power spectral density." 2017 International Conference on Intelligent Computing and Control Systems (ICICCS). doi:10.1109/iccons.2017.8250588
31. "Discrete wavelet transform," Wikipedia, the free encyclopedia
32. S. Arjaria, G. Chaubey, & N. Shukla, (2021). Hjorth Parameter based Seizure Diagnosis using Cluster Analysis. Journal of Physics: Conference Series. 1998. 012020. 10.1088/1742-6596/1998/1/012020.
33. X. Τήλλυρος, "Συγκριτική Αξιολογήση Αλγορίθμων Μηχανικής Μαθησης Σε Δεδομένα Ασθενών Με Διαβήτη", Πειραιάς 2019.
34. Zahra Khademi, Farideh Ebrahimi, Hussain Montazery Kordy, "A review of critical challenges in MI-BCI: From conventional to deep learning methods," Journal of Neuroscience Methods, Volume 383, 2023, 109736, ISSN 0165-0270.
35. Selim, Sahar & Tantawi, Manal & Shedeed, Howida & Badr, Amr. (2020). "A Comparative Analysis of Different Feature Extraction Techniques for Motor Imagery Based BCI System." doi: 10.1007/978-3-030-44289-7_69.
36. Tangermann, Michael & Müller, Klaus-Robert & Aertsen, Ad & N, Birbaumer & Braun, Christoph & C, Brunner & Leeb, Robert & C, Mehring & KJ, Miller & Müller-Putz, Gernot & Nolte, Guido & Pfurtscheller, Gert & Preissl, Hubert & Schalk, Gerwin & Schlögl, Alois & C, Vidaurre & Waldert, Stephan & Blankertz, Benjamin. (2012). "Review of the BCI competition IV. " Frontiers in Neuroscience, 55.
37. Tangermann Michael, Müller Klaus-Robert, Aertsen Ad, Birbaumer Niels, Braun Christoph, Brunner Clemens, Leeb Robert, Mehring Carsten, Miller Kai, Mueller-Putz Gernot, Nolte Guido, Pfurtscheller Gert, Preissl Hubert, Schalk Gerwin, Schlögl Alois, Vidaurre Carmen, Waldert Stephan, Blankertz Benjamin, (2012). "Review of the BCI Competition IV," Frontiers in Neuroscience 6.

38. Jeong, Hojun, and Jonghyun Kim. 2021. "Development of a Guidance System for Motor Imagery Enhancement Using the Virtual Hand Illusion" *Sensors* 21, 6: 2197. <https://doi.org/10.3390/s21062197>
39. Matthew Stewart, PhD, "Simple Introduction to Convolutional Neural Networks," Φεβρουάριος 2019, Towards Data Science: <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>.
40. "Convolutional Neural Network (CNN)," Ιούνιος 2024, TechTarget SearchEnterpriseAI: <https://www.techtarget.com/searchenterpriseai/definition/convolutional-neural-network>.
41. Avijet Biswal, "Convolutional Neural Network Tutorial" Νοέμβριος 2023 Simplilearn: https://www.simplilearn.com/tutorials/deep-learning-tutorial/convolutional-neural-network#introduction_to_cnn.
42. Zoumana Keita, "An Introduction to Convolutional Neural Networks (CNNs)" DataCamp: [An Introduction to Convolutional Neural Networks: A Comprehensive Guide to CNNs in Deep Learning | DataCamp](https://www.datacamp.com/courses/an-introduction-to-convolutional-neural-networks)
43. Tharwat, Alaa & Gaber, Tarek & Ibrahim, Abdelhameed & Hassanien, Aboul Ella. (2017). Linear discriminant analysis: A detailed tutorial. *Ai Communications*. 30. 169-190,. 10.3233/AIC-170729.
44. ML | Linear Discriminant Analysis," GeeksforGeeks: [ML | Linear Discriminant Analysis - GeeksforGeeks](https://www.geeksforgeeks.org/ml-linear-discriminant-analysis/)
45. Confusion Matrix in Machine Learning," GeeksforGeeks, [Online]. Available: <https://www.geeksforgeeks.org/confusion-matrix-machine-learning/>
46. Shanthababu Pandian, "K-Fold Cross-Validation Technique and Its Essentials," Analytics Vidhya, Νοέμβριος. 2023. :<https://www.analyticsvidhya.com/blog/2022/02/k-fold-cross-validation-technique-and-its-essentials/>.
47. [Understanding Hold-Out Methods for Training Machine Learning Models - Comet](https://www.comet.ml/blog/understanding-hold-out-methods-for-training-machine-learning-models)
48. <https://www.elastic.co/what-is/neural-network>
49. <https://medium.com/codex/introduction-to-how-an-multilayer-perceptron-works-but-without-complicated-math-a423979897ac>
50. [https://www.sciencedirect.com/topics/computer-science/multilayer-perceptron#:~:text=A%20multilayer%20perceptron%20\(MLP\)%20is,Data%20Analysis%20Using%20Python%2C%202020](https://www.sciencedirect.com/topics/computer-science/multilayer-perceptron#:~:text=A%20multilayer%20perceptron%20(MLP)%20is,Data%20Analysis%20Using%20Python%2C%202020)
51. <https://medium.com/analytics-vidhya/backpropagation-for-dummies-e069410fa585>
52. <https://www.cse.unsw.edu.au/~cs9417ml/MLP2/BackPropagation.html#Figure%206>

53. https://el.wikipedia.org/wiki/%CE%9A%CF%81%CE%BF%CF%84%CE%B1%CF%86%CE%B9%CE%BA%CF%8C%CF%82_%CE%BB%CE%BF%CE%B2%CF%8C%CF%82
54. http://opencourses.teiwest.gr/modules/document/file.php/CIED107/1.%20%CE%94%CE%B9%CE%B1%CE%BB%CE%AD%CE%BE%CE%B5%CE%B9%CF%82/Signals_and_Systems_Lectures_7.pdf Σήματα και Συστήματα Δρ. Μιχάλης Παρασκευάς Επίκουρος Καθηγητής Διάλεξη 7: Μετασχηματισμός Fourier
55. Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., & Muller, K. (2008). "Optimizing Spatial filters for Robust EEG Single-Trial Analysis." *IEEE Signal Processing Magazine*, 25(1), 41–56. doi: 10.1109/msp.2008.4408441
56. https://en.wikipedia.org/wiki/Support_vector_machine
57. <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
58. Boukadida, Hatem & Hassen, Néjib & Gafsi, Zied & Besbes, Kamel. (2011). "A Highly Time-Efficient Digital Multiplier Based On The A2 Binary Representation. " *International Journal of Engineering Science and Technology*. 3.
59. <https://www.datacamp.com/blog/introduction-to-unsupervised-learning>
60. <https://www.spiceworks.com/tech/big-data/articles/what-is-support-vector-machine/>
61. https://www.mathworks.com/discovery/support-vector-machine.html?s_tid=srchtitle_support_results_1_Support%20Vector%20machines
62. Mayer-Kress G. "Non-linear mechanisms in the brain." *Z Naturforsch C J Biosci*. 1998 Jul-Aug; 53(7-8):677-85. doi: 10.1515/znc-1998-7-820. PMID: 9755519.
63. Abdulkader, S. N., Atia, A., & Mostafa, M.-S. M. (2015). "Brain computer interfacing: Applications and challenges. *Egyptian Informatics Journal*, 16(2)," 213–230. doi: 10.1016/j.eij.2015.06.002
64. Β. Σ. Παπαβασιλείου, "Πρόβλεψη νευρωνικών εκπολώσεων από δυναμικά τοπικού πεδίου με τη χρήση μοντέλου φυσιολογικής λειτουργίας της απόκρισης", 2010
65. Tiwari, Smita & Goel, Shivani & Bhardwaj, Arpit. (2022). "MIDNN- a classification approach for the EEG based motor imagery tasks using deep neural network." *Applied Intelligence*. 52. 10.1007/s10489-021-02622-w.
66. Sivadas, Athira & Broadie, Kendal. (2020). "How Does My Brain Communicate With My Body?" *Frontiers for Young Minds*. 8. 10.3389/frym.2020.540970.
67. https://www.digitalxplore.org/up_proc/pdf/70-139928877263-67.pdf
68. Lotze, Martin & Halsband, Ulrike. (2006). Motor Imagery. *Journal of physiology, Paris*. 99. 386-95. 10.1016/j.jphysparis.2006.03.012.

69. <https://meygeia.gr/diaforetikoi-lovoi-egkefalou/>
70. <https://www.karpathiou.gr/syndromo-vregmatikou-lovou/>
71. <https://www.medicalnewstoday.com/articles/313265>
72. <https://neurooncology.gr/%CE%B1%CE%BD%CE%B1%CF%84%CE%BF%CE%BC%CE%AF%CE%B1-%CE%BA%CE%B1%CE%B9-%CF%86%CF%85%CF%83%CE%B9%CE%BF%CE%BB%CE%BF%CE%B3%CE%AF%CE%B1-%CE%BA%CE%BD%CF%83/%CE%B1%CE%BD%CE%B1%CF%84%CE%BF%CE%BC%CE%AF%CE%B1-%CE%BA%CE%B1%CE%B9-%CF%86%CF%85%CF%83%CE%B9%CE%BF%CE%BB%CE%BF%CE%B3%CE%AF%CE%B1-%CF%84%CE%BF%CF%85-%CE%B5%CE%B3%CE%BA%CE%B5%CF%86%CE%AC%CE%BB%CE%BF/>
73. Ε. Κρεβετζάκη, "Μελέτη νευρομορφικών ιδιοτήτων μνημών εναλλαγής αντίστασης," 2019
74. [Ο εγκέφαλος και η καλή λειτουργία του - Douni Health Products](#)
75. [The Frontal Lobe: What Is It and How Does It Impact Your Health? \(webmd.com\)](#)
76. [Δυναμικό ενέργειας - Βικιπαίδεια \(wikipedia.org\)](#) \
77. [Chart: 43 Alpha, Theta, Delta Brainwave Entrainment Benefits – EOC Institute](#)
78. [What Are the Different Types of Brain Waves? - Electrophysiological Research Blog, News & Events - TMSi](#)
79. Enrique Tomás Martínez Beltrán, Mario Quiles Pérez, Sergio López Bernal, Gregorio Martínez Pérez, Alberto Huertas Celdrán, "SAFECAR: A Brain–Computer Interface and intelligent framework to detect drivers' distractions, " Expert Systems with Applications, Volume 203, 2022, 117402, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2022.117402>.
80. Liang W, Jin J, Xu R, Wang X, Cichocki A. "Variance characteristic preserving common spatial pattern for motor imagery BCI." Front Hum Neurosci. 2023 Nov 9; 17:1243750. doi: 10.3389/fnhum.2023.1243750. PMID: 38021234; PMCID: PMC10666778.
81. https://github.com/wmvanvliet/neuroscience_tutorials/blob/master/eeg-bci/3.%20Imagined%20movement.ipynb
82. https://mne.tools/stable/auto_tutorials/preprocessing/25_background_filtering.html#sphx-glr-auto-tutorials-preprocessing-25-background-filtering-py
83. Π. Γρουμπός, ΣΗΜΑΤΑ ΚΑΙ ΣΥΣΤΗΜΑΤΑ ΙΙ, Σημειώσεις - Διάλεξη 6.
84. B. Hjorth, (1970). "EEG analysis based on time domain properties. " Electroencephalography and Clinical Neurophysiology, 29(3), 306–310. doi: 10.1016/0013-4694(70)90143-4
85. K.-L. Du, & M.N. Swamy (2014). "Perceptrons. " doi: 10.1007/978-1-4471-5571-3_3.

86. Fabien Lotte, Laurent Bougrain, Maureen Clerc. "Electroencephalography (EEG)-based BrainComputer Interfaces." Wiley Encyclopedia of Electrical and Electronics Engineering, Wiley, pp.44, 2015, ff10.1002/047134608X.W8278ff. ffhal-01167515f
87. <https://www.mathworks.com/matlabcentral/fileexchange/72204-common-spatial-patterns-csp>
88. Lang, A., Coin, A., Dubljević, V. (2023). "A Scoping Review of the Academic Literature on BCI Ethics. " In: Dubljević, V., Coin, A. (eds) Policy, Identity, and Neurotechnology. Advances in Neuroethics. Springer, Cham. https://doi.org/10.1007/978-3-031-26801-4_7
89. Burwell, S., Sample, M. & Racine, E. "Ethical aspects of brain computer interfaces: a scoping review. " *BMC Med Ethics* **18**, 60 (2017). <https://doi.org/10.1186/s12910-017-0220-y>

ΠΑΡΑΡΤΗΜΑ Ι

Εδώ παρατίθενται οι κώδικες οι οποίοι χρησιμοποιήθηκαν για το πειραματικό μέρος:

Κώδικας 1: Συνάρτηση για το φιλτράρισμα των δεδομένων

```
function [trials_filt]= filter_IIR(sample_rate,lo,hi,filt_order,trials)
Fpass = [lo hi];
Wpass = Fpass / (sample_rate / 2);
[b, a] = butter(filt_order, Wpass, 'bandpass');
ntrials = size(trials, 3);
trials_filt = zeros(size(trials));
for i = 1:ntrials
    trials_filt(:,:,i) = filtfilt(b, a, trials(:,:,i))';
end
end
```

Κώδικας 2: Εφαρμογή μήτρας χωρικών φίλτρων (W) σε τρισδιάστατο πίνακα.

```
function projected_data = applyCSP(W_selected, data)
[C, T, num_trials] = size(data);
num_filters = size(W_selected, 2);
projected_data = zeros(num_filters, T, num_trials);
for i = 1:num_trials
    trial_data = squeeze(data(:, :, i));
    projected_data(:, :, i) = W_selected' * trial_data;
end
end
```

Κώδικας 3: Συνάρτηση υπολογισμού του λογάριθμου της διακύμανσης.

```
function [log_var_trials]= log_var(trials)
variances = var(trials, 0, 2);
log_var_trials = log(variances);
end
```

Κώδικας 4: Συνάρτηση δημιουργίας διαγράμματος διασποράς συναρτήσει πρώτου και τελευταίου στοιχείου

```
function plot_scatter(left, right)
figure;
nchannels = size(left, 1);
nsamples=size(left,2);
```

```
ntrials=size(left,3);
left = reshape(left, nchannels, nsamples*ntrials);
right = reshape(right, nchannels, nsamples*ntrials);
scatter(left(1,:), left(end,:), 'b','filled');
hold on;
scatter(right(1,:), right(end,:), 'r','filled');
hold off;
xlabel('First component');
ylabel('Last component');
legend('Left', 'right');
end
```

Κώδικας 5: Συνάρτηση δημιουργίας ιστογράμματος μέσης τιμής λογαριθμικής διακύμανσης κάθε καναλιού.

```
function []= vis_log_var(trial_lvleft,trial_lvrigh)

nchannels = size(trial_lvleft, 1);
figure;
x = 1:nchannels;
subplot(2,1,1);
bar(x, mean(trial_lvleft, 3));
xlabel('Channel');
ylabel('Log-Variance');
title('Log-Variance of Each Channel - Left Trials');
grid on;
xlim([0.5 nchannels+0.5]);
subplot(2,1,2);
bar(x, mean(trial_lvrigh,3));
xlabel('Channel');
ylabel('Log-Variance');
title('Log-Variance of Each Channel - Right Trials');
grid on;
xlim([0.5 nchannels+0.5]);
end
```

Κώδικας 6: Συνολικός κώδικας με χρήση αλγορίθμου LDA.

```
clc;
clear;
close all;
data = load('BCICIV_calib_ds1a.mat');
sample_rate = data.nfo.fs;
EEG = data.cnt';
EEG = 0.1 * double(EEG);
[nchannels, n_samples] = size(EEG);

EEGgianaeleksw=EEG';

channel_names = data.nfo.clab';
event_onsets = data.mrk.pos';
event_codes = data.mrk.y';
labels = zeros(1, n_samples);
labels(event_onsets) = event_codes;
```

```

cl_lab = data.nfo.classes;
cl1 = cl_lab{1};
cl2 = cl_lab{2};
nclasses = numel(cl_lab); % 2 classes
nevents = numel(event_onsets); % 200 events
%-----
% The time window (in samples)
win = round(0.5*sample_rate) : round(2.5* sample_rate);

% Length of the time window
nsamples = numel(win);

for cl_idx = 1:nclasses
    code = unique(event_codes(event_codes ~= 0));
    cl_onsets = event_onsets(event_codes == code(cl_idx));

    if cl_idx == 1
        left_trials = zeros(nchannels, nsamples, numel(cl_onsets));
        for i = 1:numel(cl_onsets)
            onset = cl_onsets(i);
            left_trials(:, :, i) = EEG(:, win + onset);
        end
    else
        right_trials = zeros(nchannels, nsamples, numel(cl_onsets));
        for j = 1:numel(cl_onsets)
            onset = cl_onsets(j);
            right_trials(:, :, j) = EEG(:, win + onset);
        end
    end
end
left_trials_filt= filter_IIR(sample_rate,8,15,6,left_trials);
right_trials_filt= filter_IIR(sample_rate,8,15,6,right_trials);
%-----training and testing
train_percentage=0.5;
ntrain_left = floor(size(left_trials_filt, 3) * train_percentage);
ntrain_right = floor(size(right_trials_filt, 3) * train_percentage);
ntest_left = size(left_trials_filt, 3) - ntrain_left;
ntest_Right = size(right_trials_filt, 3) - ntrain_right;

train_left = left_trials_filt(:, :, 1:ntrain_left);
train_right= right_trials_filt(:, :, 1:ntrain_right);
test_left=left_trials_filt(:, :, ntrain_left+1:end);
test_right=right_trials_filt(:, :, ntrain_right+1:end);

%-----
% Apply the CSP
[C, T, N1] = size(train_left);
[~, ~, N2] = size(train_right);
train_left_csp = reshape(train_left, C, T*N1);
train_right_csp = reshape(train_right, C, T*N2);
S1 = cov(train_left_csp');
S2 = cov(train_right_csp');
[W,L] = eig(S1, S1+S2);
%-----
num_filters = 3; % Number of filters
num_total_filters = size(W, 2);

selected_filters = [1:num_filters, (num_total_filters-num_filters+1):num_total_filters];

```

```

% Select top and bottom CSP filters
W_selected = W(:, selected_filters);

% Apply CSP filters to training and testing data
projected_train_left = applyCSP(W_selected, train_left);
projected_train_right = applyCSP(W_selected, train_right);
projected_test_left = applyCSP(W_selected, test_left);
projected_test_right = applyCSP(W_selected, test_right);

[projected_train_left_log_var]= log_var(projected_train_left);
[projected_train_right_log_var]= log_var(projected_train_right);
[projected_test_left_log_var]= log_var(projected_test_left);
[projected_test_right_log_var]= log_var(projected_test_right);

% Combine left and right classes for training
% Selecting the first and the last
features_left = [projected_train_left_log_var(1, :); projected_train_left_log_var(end, :)].';
features_right = [projected_train_right_log_var(1, :); projected_train_right_log_var(end, :)].';

test_features_left = [projected_test_left_log_var(1, :); projected_test_left_log_var(end, :)].';
test_features_right = [projected_test_right_log_var(1, :); projected_test_right_log_var(end, :)].';
test_features = [test_features_left; test_features_right];

test_labels = [-ones(size(test_features_left, 1), 1); ones(size(test_features_right, 1), 1)];

% Combine features from both classes
features = [features_left; features_right];

% Create labels: -1 for left class, 1 for right class
labels = [-ones(size(features_left, 1), 1); ones(size(features_right, 1), 1)];

% Train LDA
ldaClassifier = fitcdiscr(features, labels);

%predictions
predictions = predict(ldaClassifier, test_features);

% Evaluate
accuracy = sum(predictions == test_labels) / numel(test_labels);
confMat = confusionmat(test_labels, predictions);

% Accuracy
fprintf('Accuracy: %.2f%%\n', accuracy * 100);

% Replace labels from -1 to 0
test_labels(test_labels == -1) = 0;
predictions(predictions == -1) = 0;
figure
plotconfusion(test_labels', predictions', 'Testing');

```

Κώδικας 7: Συνολικός κώδικας με χρήση αλγορίθμου SVM με γραμμικό πυρήνα.


```

clc;
clear;
close all;

data = load('BCICIV_calib_ds1g.mat');
sample_rate = data.nfo.fs;
EEG = data.cnt';
EEG = 0.1 * double(EEG);
[nchannels, n_samples] = size(EEG);

EEGgianaeleksw=EEG';

channel_names = data.nfo.clab';
event_onsets = data.mrk.pos';
event_codes = data.mrk.y';
labels = zeros(1, n_samples);
labels(event_onsets) = event_codes;

cl_lab = data.nfo.classes;
cl1 = cl_lab{1};
cl2 = cl_lab{2};
nclasses = numel(cl_lab); % 2 classes
nevents = numel(event_onsets); % 200 events
%-----
% The time window (in samples)
win = round(0.5*sample_rate) : round(2.5* sample_rate);

% Length of the time window
nsamples = numel(win);

for cl_idx = 1:nclasses
    code = unique(event_codes(event_codes ~= 0));
    cl_onsets = event_onsets(event_codes == code(cl_idx));

    if cl_idx == 1
        left_trials = zeros(nchannels, nsamples, numel(cl_onsets));
        for i = 1:numel(cl_onsets)
            onset = cl_onsets(i);
            left_trials(:, :, i) = EEG(:, win + onset);
        end
    else
        right_trials = zeros(nchannels, nsamples, numel(cl_onsets));
        for j = 1:numel(cl_onsets)
            onset = cl_onsets(j);
            right_trials(:, :, j) = EEG(:, win + onset);
        end
    end
end
left_trials_filt= filter_IIR(sample_rate,8,15,6,left_trials);
right_trials_filt= filter_IIR(sample_rate,8,15,6,right_trials);
%-----training and testing
train_percentage=0.5;
ntrain_left = floor(size(left_trials_filt, 3) * train_percentage);
ntrain_right = floor(size(right_trials_filt, 3) * train_percentage);
ntest_left = size(left_trials_filt, 3) - ntrain_left;
ntest_Right = size(right_trials_filt, 3) - ntrain_right;

train_left = left_trials_filt(:, :, 1:ntrain_left);
train_right= right_trials_filt(:, :, 1:ntrain_right);
test_left=left_trials_filt(:, :, ntrain_left+1:end);

```

```

test_right=right_trials_filt(:, :, ntrain_right+1:end);
%-----
% Apply the CSP
[C, T, N1] = size(train_left);
[~, ~, N2] = size(train_right);
train_left_csp = reshape(train_left, C, T*N1);
train_right_csp = reshape(train_right, C, T*N2);

S1 = cov(train_left_csp');
S2 = cov(train_right_csp');
[W,L] = eig(S1, S1+S2);
%-----
num_filters = 3;
num_total_filters = size(W, 2);

selected_filters = [1:num_filters, (num_total_filters-num_filters+1):num_total_filters];

% Select top and bottom CSP filters
W_selected = W(:, selected_filters);

% Apply CSP filters to training and test data
projected_train_left = applyCSP(W_selected, train_left);
projected_train_right = applyCSP(W_selected, train_right);
projected_test_left = applyCSP(W_selected, test_left);
projected_test_right = applyCSP(W_selected, test_right);
%}
[projected_train_left_log_var]= log_var(projected_train_left);
[projected_train_right_log_var]= log_var(projected_train_right);
[projected_test_left_log_var]= log_var(projected_test_left);
[projected_test_right_log_var]= log_var(projected_test_right);

% Combine left and right classes for training
% Selecting the first and the last
features_left = [projected_train_left_log_var(1, :); projected_train_left_log_var(end,
:)].';
features_right = [projected_train_right_log_var(1, :); projected_train_right_log_var(end,
:)].';
test_features_left = [projected_test_left_log_var(1, :); projected_test_left_log_var(end,
:)].';
test_features_right = [projected_test_right_log_var(1, :);
projected_test_right_log_var(end, :)].';
test_features = [test_features_left; test_features_right];

test_labels = [-ones(size(test_features_left, 1), 1); ones(size(test_features_right, 1),
1)];

% Combine features from both classes
features = [features_left; features_right];

% Create labels: -1 for left class, 1 for right class
labels = [-ones(size(features_left, 1), 1); ones(size(features_right, 1), 1)];

svmClassifier = fitcsvm(features, labels, 'KernelFunction', 'linear');

test_features_left = [projected_test_left_log_var(1, :); projected_test_left_log_var(end,
:)].';
test_features_right = [projected_test_right_log_var(1, :);
projected_test_right_log_var(end, :)].';

```

```
test_features = [test_features_left; test_features_right];
test_labels = [-ones(size(test_features_left, 1), 1); ones(size(test_features_right, 1),
1)];

% Make predictions
[svmPredictions, svmScores] = predict(svmClassifier, test_features);

% Evaluate SVM
svmAccuracy = sum(svmPredictions == test_labels) / numel(test_labels);
svmConfMat = confusionmat(test_labels, svmPredictions);

% Accuracy
fprintf('SVM Classifier Accuracy: %.2f%%\n', svmAccuracy * 100);

% Replace class from -1 to 0
test_labels(test_labels == -1) = 0;
svmPredictions(svmPredictions == -1) = 0;
figure
plotconfusion(test_labels', svmPredictions', 'Testing');
```