



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΣΥΣΤΗΜΑΤΩΝ ΜΕΤΑΔΟΣΗΣ ΠΛΗΡΟΦΟΡΙΑΣ ΚΑΙ ΤΕΧΝΟΛΟΓΙΑΣ ΥΛΙΚΩΝ

Άδραγμα μέσω ρομποτικού τηλεχειρισμού
βασισμένου σε Ηλεκτροεγκεφαλογραφικά
σήματα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΧΑΡΑΛΑΜΠΟΥ ΚΑΛΑΒΡΥΤΙΝΟΥ

Επιβλέπουσα: Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

ΕΡΓΑΣΤΗΡΙΟ ΒΙΟΪΑΤΡΙΚΩΝ ΠΡΟΣΟΜΟΙΩΣΕΩΝ ΚΑΙ ΑΠΕΙΚΟΝΙΣΤΙΚΗΣ ΤΕΧΝΟΛΟΓΙΑΣ
Αθήνα, Φεβρουάριος 2018



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Συστημάτων Μετάδοσης Πληροφορίας και Τεχνολογίας Υλικών
Εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας

Έδραγμα μέσω ρομποτικού τηλεχειρισμού βασισμένου σε Ηλεκτροεγκεφαλογραφικά σήματα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΧΑΡΑΛΑΜΠΟΥ ΚΑΛΑΒΡΥΤΙΝΟΥ

Επιβλέπουσα: Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 8η Φεβρουαρίου 2018.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Κωνσταντίνα Νικήτα
Καθηγήτρια Ε.Μ.Π.

.....
Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

.....
Κωνσταντίνος Κυριακόπουλος
Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2018

(Υπογραφή)

.....

ΧΑΡΑΛΑΜΠΟΣ ΚΑΛΑΒΡΥΤΙΝΟΣ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

© 2018 – All rights reserved



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Συστημάτων Μετάδοσης Πληροφορίας και Τεχνολογίας Υλικών
Εργαστήριο Βιοϊατρικών Προσομοιώσεων και Απεικονιστικής Τεχνολογίας

Copyright ©–All rights reserved Χαράλαμπος Καλαβρυτινός, 2018.

Με επιφύλαξη παντός δικαιώματος.

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 τον συγγραφέα.

Η παρούσα διπλωματική εργασία βασίζεται στο πρότυπο \LaTeX του Εργαστηρίου Συστημάτων Βάσεων Γνώσεων και Δεδομένων της Σχολής Ηλεκτρολόγων Μηχανικών Μηχανικών Ηλεκτρονικών Υπολογιστών του Ε.Μ.Π. και το περιεχόμενο της διανέμεται με Creative Commons Attribution–ShareAlike 4.0 International License.

Ευχαριστίες

Αρχικά, θα ήθελα να ευχαριστήσω την επιβλέπουσα καθηγήτρια κα. Νικήτα, για τις συμβουλές και την καθοδήγησή της καθόλη τη διάρκεια εκπόνησης της διπλωματικής εργασίας. Θα ήθελα, εξίσου, να ευχαριστήσω τον καθηγητή κ. Κυριακόπουλο για τη στρατηγική καθοδήγηση και τη δυνατότητα που μου έδωσε να είμαι μέλος στο Εργαστήριο Αυτομάτου Ελέγχου για ένα χρόνο. Τέλος, θα ήθελα να ευχαριστήσω τον καθηγητή κ. Σταφυλοπάτη που δέχθηκε να συμμετάσχει στην τριμελή επιτροπή της διπλωματικής εργασίας.

Θα ήθελα, ακόμα, να ευχαριστήσω όλους όσους γνώρισα μέσα από το εργαστήριο αυτομάτου ελέγχου, που πέρα από εξαιρετικοί ερευνητές είναι και πολύ αξιόλογοι άνθρωποι. Θέλω, επομένως, να ευχαριστήσω το Μπάμπη, τον Παναγιώτη και τον Κωνσταντίνο για όλες τις συμβουλές τους αυτούς τους μήνες, και το Χρήστο, το Δήμο και τον Ισίδωρο για την πολύπλευρη στήριξή τους.

Θα ήθελα, επίσης, να ευχαριστήσω όλους τους κοντινούς μου φίλους, που από την αρχή με στηρίζουν σε κάθε μου βήμα, και κυρίως τους Βασίλη και Στέργιο, χωρίς τη συμβολή των οποίων δε θα μπορούσα να ολοκληρώσω αυτήν την εργασία.

Τέλος, θέλω να ευχαριστήσω την οικογένειά μου, τις αδερφές μου, Αναστασία και Μαρία, για την υποστήριξή τους, και ιδιαίτερος του γονείς μου, Πέτρο και Καίτη, στους οποίους οφείλω ό,τι είμαι σήμερα.

Περίληψη

Τα τελευταία χρόνια τα μέσα Διασύνδεσης Εγκεφάλου-Υπολογιστή (ΔΕΥ) αλλάζουν τον τρόπο επικοινωνίας μεταξύ ανθρώπων και μηχανών. Αυτή η τεχνολογία μπορεί να θεωρηθεί ως το μέλλον όσον αφορά την αλληλεπίδραση ανθρώπου-ρομπότ, αφού επιτρέπει στα ρομπότ να καταλαβαίνουν και να αντιδρούν στη νοητική κατάσταση του ανθρώπινου μυαλού, χωρίς να απαιτείται ιδιαίτερη ανθρώπινη προσπάθεια ή προηγούμενη εκπαίδευση. Η χρήση των βιοσημάτων, και συγκεκριμένα των Ηλεκτροεγκεφαλογραφικών (ΗΕΓ) σημάτων γίνεται όλο και πιο δημοφιλής σε τέτοια μέσα διασύνδεσης. Αυτά τα σήματα, παρόλο που είναι ασθενή και θορυβώδη, και επομένως, δύσκολα στην επεξεργασία, χρησιμοποιούνται ευρέως λόγω της μη επεμβατικής φύσης τους και της ικανότητάς τους να διασφαλίζουν θεαματικά γρήγορη επικοινωνία ανθρώπου-ρομπότ. Πολλοί ερευνητές εστιάζουν στην ανίχνευση και ανάλυση σημάτων που προκαλούνται συγκεκριμένα από την κίνηση των ματιών και των βλεφάρων, γνωστών και ως οφθαλμικών ΗΕΓ σημάτων (artifacts). Αν και στις περισσότερες περιπτώσεις αυτά τα σήματα θεωρούνται ανεπιθύμητα και συνήθως απορρίπτονται, περιέχουν πληροφορία που μπορεί να αποδειχθεί χρήσιμη.

Το επίκεντρο της παρούσας διπλωματικής εργασίας είναι η χρήση τέτοιων ΗΕΓ σημάτων για το χειρισμό ρομποτικού βραχίονα με σκοπο το άδραγμα κάποιου αντικειμένου. Ηλεκτροεγκεφαλογραφικά σήματα αποκτώνται από ανθρώπους κατά τη διάρκεια πειραμάτων, και επεξεργάζονται και αποκωδικοποιούνται με τη χρήση τεχνικών μηχανικής μάθησης για παλινδρόμηση και κατηγοριοποίηση. Μία νέα τεχνική προτείνεται, για τη διευκόλυνση του αδράγματος μέσω της ακινητοποίησης του ρομποτικού βραχίονα κατά τη διάρκεια ακινησίας των ματιών, χρησιμοποιώντας χρονικά προσαρμοζόμενα βάρη για εφαρμογή σε πραγματικό χρόνο. Τέλος, προστίθεται στη διεπαφή ένας τρόπος για να εκφραστεί η ανθρώπινη επιθυμία για άδραγμα, χρησιμοποιώντας αποκλειστικά συγκεκριμένα ΗΕΓ σήματα.

Λέξεις Κλειδιά

ΗΕΓ, ΔΕΥ, Μηχανική μάθηση, Επεξεργασία Σημάτων, Ρομποτικός τηλε-χειρισμός.

Abstract

During the last decades, Brain-Computer interfaces (BCIs) are changing the communication theme between humans and machines. This technology can be considered as the future in human-robot interaction, as it enables the robot to understand and respond to the human mind's cognitive state, without requiring much human effort or training. The use of bio-signals, and in particular Electroencephalography (EEG) signals is becoming increasingly more popular in such interfaces. These signals, despite being weak, noisy and, thus, tricky to process, are being widely used due to their non-intrusive nature and their ability to ensure incredibly fast human-robot communication. Many researchers focus on detecting and analysing signals specifically caused by the movement of the eyes and eyelids, known as ocular EEG artifacts. Even though in most cases these signals are unwanted and likely to be discarded, they carry information that can be proven useful.

The focus of this diploma thesis is the use of such EEG signals for robotic arm manipulation for the purpose of grasping an object. EEG signals are acquired from humans during experiments, and are processed and decoded using machine learning models for regression and classification. A novel method to facilitate grasping by the immobilization of the robotic arm during absence of eye movement is introduced, using adaptive weights for real-time application. Lastly, a way of expressing the human's intent for grasping, using exclusively certain EEG artifacts, is added to this interface.

Keywords

EEG, BCI, Machine learning, Signal Processing, Robotic tele-operation.

Περιεχόμενα

Ευχαριστίες	1
Περίληψη	3
Abstract	5
Περιεχόμενα	8
Κατάλογος Σχημάτων	11
Κατάλογος Πινάκων	13
1 Εισαγωγή	15
1.1 Νευρο-ρομποτική	15
1.2 Διασύνδεση Ανθρώπου-Μηχανής (Human-Machine Interface)	16
1.3 Η Ηλεκτροεγκεφαλογραφία (ΗΕΓ) ως μέσο Διασύνδεσης Ανθρώπου-Μηχανής	17
1.4 Σχετικές εργασίες	18
1.5 Αντικείμενο της διπλωματικής	19
1.6 Οργάνωση της εργασίας	20
2 Μαθηματικές έννοιες και θεωρητικό υπόβαθρο	23
2.1 Ρομποτικοί βραχίονες	23
2.1.1 Ευθεία και αντίστροφη Κινηματική Ανάλυση	24
2.1.2 Διαφορική κινηματική ανάλυση	26
2.1.3 Έλεγχος πλεοναζόντων βαθμών Ελευθερίας	26
2.2 Ψηφιακή επεξεργασία σημάτων	27
2.2.1 Ψηφιακά φίλτρα	27
2.2.2 Φασματική Ανάλυση Σημάτων	28
2.2.3 Ανάλυση σε ανεξάρτητες συνιστώσες	28
2.2.4 Ανάλυση σε κύριες συνιστώσες	29
2.3 Μηχανική μάθηση	30
2.3.1 Παλινδρόμηση και Κατηγοριοποίηση	31
2.3.2 Εξαγωγή Χαρακτηριστικών	31

2.3.3	Μοντέλο Μεταβλητών Κατάστασης	32
2.3.4	Τεχνητά Νευρωνικά Δίκτυα	33
2.3.5	Μηχανές Διανυσμάτων Υποστήριξης	34
2.4	Μετρικές αξιολόγησης	36
3	Καταγραφή πειραματικών δεδομένων	37
3.1	Συσκευές καταγραφής	37
3.2	Πειραματική διάταξη	39
4	HEΓ Σήματα: Ανάλυση και επεξεργασία	41
4.1	Εισαγωγή	42
4.1.1	Τύποι HEΓ σημάτων	43
4.1.2	Μη χρήσιμα HEΓ σήματα (Artifacts)	44
4.2	Επεξεργασία HEΓ σημάτων	46
4.2.1	Απομόνωση σημάτων κίνησης των ματιών για αποκωδικοποίηση	51
4.2.2	Απομόνωση σημάτων κίνησης των ματιών για κατηγοριοποίηση κίνησης	54
4.2.3	Απομόνωση σημάτων κίνησης των βλεφάρων	56
5	Μοντέλο ακινητοποίησης χεριού για επίτευξη αδράγματος	59
5.1	Αποκωδικοποίηση τροχιάς κίνησης στο χώρο με χρήση HEΓ σημάτων	59
5.2	Περιγραφή μοντέλου ακινητοποίησης χεριού	61
5.2.1	Δυαδικός Κατηγοριοποιητής κίνησης των ματιών	62
5.2.2	Υπολογισμός χρονικά μεταβλητών βαρών	64
5.3	Αποτελέσματα και συμπεράσματα	71
6	Το κλείσιμο των βλεφάρων ως μέσο εκδήλωσης πρόθεσης για άδραγμα	75
6.1	Εισαγωγή	75
6.2	Ο κατηγοριοποιητής ανίχνευσης κλειστών βλεφάρων	76
6.3	Εξαγωγή χαρακτηριστικών	77
6.4	Αποτελέσματα και συμπεράσματα	79
7	Επίλογος	83
7.1	Τελικό πείραμα	83
7.2	Συμπεράσματα	84
7.3	Μελλοντικές επεκτάσεις	85
	Γλωσσάριο	87
	Bibliography	90

Κατάλογος Σχημάτων

1.1	Εξαγωγή βιο-σημάτων από άνθρωπο. Πηγή: [25].	16
1.2	Μία γενική περιγραφή μιας ΔΕΥ. Πηγή: [37].	18
1.3	Καλλιτεχνική απεικόνιση λειτουργίας του μέσου διασύνδεσης. Αρχικά ο χρήστης εστιάζει στο τελικό στοιχείο δράσης (ρομποτικό χέρι) του ρομπότ (Α). Με την κίνηση των ματιών καθορίζει την τροχιά κίνησης του χεριού ώστε να φτάσει σε ένα επιθυμητό σημείο (Β). Κλείνοντας τα μάτια η λαβή του ρομποτικού χεριού κλείνει και πιάνει το αντικείμενο (C). Με το ίδιο τρόπο όπως πριν μετακινεί το χέρι σε ένα διαφορετικό επιθυμητό σημείο (D). Κλείνοντας πάλι τα μάτια η λαβή ανοίγει και το αντικείμενο αφήνεται ελεύθερο (E).	19
1.4	Η Διεπαφή Εγκεφάλου-Υπολογιστή, τα υποσυστήματα της οποίας περιγράφονται και αναπτύσσονται στην παρούσα εργασία	20
2.1	Ο Ρομποτικός βραχίονας Mitshbishi PA10 Πηγή: [19].	23
2.2	Στοιχεία ενός ρομποτικού συστήματος. Πηγή: [53].	24
2.3	Διαφορετικές λύσεις αντίστοιχου κινηματικού προβλήματος για τον βραχίονα PUMA. Πηγή: [54].	25
2.4	Παράδειγμα Classification και Regression.	32
2.5	Ένας τεχνητός νευρώνας. Πηγή [36].	33
2.6	Δομή ενός τεχνητού νευρωνικού δικτύου.	34
2.7	Παράδειγμα ενός υπερ-επιπέδου που μεγιστοποιεί το περιθώριο για δεδομένα από δύο οδιαφορετικές κλάσεις. Τα δείγματα πάνω στο περιθώριο ονομάζονται διανύσματα υποστήριξης. Πηγή [14]	35
3.1	Η συσκευή καταγραφής των ΗΕΓ σημάτων Biosemi ActiveTwo.	37
3.2	Τα ηλεκτρόδια που χρησιμοποιούνται για την καταγραφή των σημάτων.	38
3.3	Η συσκευή καταγραφής θέσης και προσανατολισμού Polhemus Liberty	39
3.4	Το ρομποτικό χέρι που χρησιμοποιήθηκε κατά τα πειράματα	40
4.1	Η μέθοδος της ηλεκτροεγκεφαλογραφίας - ΗΕΓ. Πηγή: University of Zurich, Neurofeedback lab.	41
4.2	Η δομή ενός νευρώνα σύμφωνα με το μοντέλο των Attwood, MacKay. Πηγή: [49].	42

4.3	Οι θέσεις των ηλεκτροδίων σύμφωνα με τη σύμβαση του συστήματος 10-20. Πηγή: [49].	43
4.4	Οι άλφα, βήτα, θήτα και δέλτα κυματομορφές. Πηγή: [20].	44
4.5	Διάφορα Artifacts που εμπεριέχονται στα ΗΕΓ σήματα . Πηγή: [10].	45
4.6	Οι θέσεις, τα ονόματα και η αντιστοίχιση με την αρίθμηση των 32 ηλεκτροδίων.	46
4.7	Χάρτες φασματικής πυκνότητας ισχύος για συγκεκριμένες συχνότητες από το EEGLAB για το πείραμα 1.	47
4.8	Χάρτες φασματικής πυκνότητας ισχύος για συγκεκριμένες συχνότητες από το EEGLAB για το πείραμα 2.	48
4.9	Παρουσίαση της μεθόδου εύρεσης των συνιστωσών Artifact με χρήση της μεθόδου ICA. Α) Τμήματα 22 καναλιών ΗΕΓ σημάτων με έντονη αργή κίνηση ματιών, Β) συνιστώσες που προκύπτουν από ICA μαζί με scalp maps πέντε συνιστωσών, που σχετίζονται με τις κινήσεις των ματιών (πάνω δύο) και κραταφικών μυών (κάτω τρεις χάρτες), C) Διορθωμένα ΗΕΓ σήματα έπειτα από αφαίρεση των πέντε συνιστωσών του (Β). Πηγή: [24]	49
4.10	Οι φασματικοί χάρτες των συνιστωσών που χρησιμοποιούνται για την οπτική επιθεώρηση και επιλογή των κατάλληλων συνιστωσών, μέσα από το περιβάλλον του EEGLAB.	50
4.11	Οι προηγούμενη χάρτες του σχήματος 4.10 σε τρισδιάστατη απεικόνιση από το EEGLAB.	51
4.12	Οι συντελεστές συσχέτισης των συνιστωσών με τα κανάλια του frontal lobe και η αυτόματη επιλογή των κατάλληλων συνιστωσών με βάση ένα πειραματικά εξαγόμενο κατώφλι.	52
4.13	Η αυτόματη επιλογή καναλιών χρησιμοποιώντας το συντελεστή συσχέτισης.	53
4.14	Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 1 (πείραμα stop1).	54
4.15	Οι συντελεστές συσχέτισης CC για τα 32 κανάλια.	55
4.16	Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 2 (πείραμα stop1).	56
4.17	Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 3 (πείραμα volblink1).	57
5.1	Η διαδικασία που ακολουθείται για την αποκωδικοποίηση.	60
5.2	Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model χωρίς τη χρήση ICA ή PCA για δεδομένα δοκιμής.	61
5.3	Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model με χρήση PCA για δεδομένα δοκιμής.	62
5.4	Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model με χρήση ICA για δεδομένα δοκιμής.	63
5.5	Το μοντέλο αινητοποίησης του χεριού κατά την αποκωδικοποίηση.	64
5.6	Τα επιμέρους στοιχεία του μοντέλου που παρουσιάστηκε στο σχήμα 5.5.	64

5.7	Τα 9 κανάλια ως χαρακτηριστικά εισόδου στον κατηγοριοποιητή (μπλε χρώμα), και τα τμήματα που αντιστοιχίζονται σε περιόδους ακινησίας (κόκκινο χρώμα) των δεδομένων δοκιμής.	65
5.8	Εύρεση της επιθυμητής εξόδου του κατηγοριοποιητή για τα δεδομένα δοκιμής.	66
5.9	Σύγκριση εξόδου ενός SVM και ενός NN.	67
5.10	Με μπλε χρώμα το βάρος weight1 που θα έπρεπε ιδανικά να χρησιμοποιηθεί, και με πράσινο χρώμα το ιδανικό βάρος που μπορεί να υπολογιστεί από την έξοδο του κατηγοριοποιητή	68
5.13	Τα βάρη όπως υπολογίζονται σύμφωνα με τους αλγόριθμους #1 και #2 για αριθμητικό μέσο	68
5.11	Η διαδικασία διαχωρισμού τυχαίου σήματος σε παράθυρα.	69
5.12	Οι επιτρεπόμενες μεταβάσεις ανάμεσα στις 5 κλίμακες.	69
5.14	Τα βάρη όπως υπολογίζονται σύμφωνα με τους αλγόριθμους #1 και #2 για IQM	69
5.15	Το μοντέλο ακινητοποίησης χειριού με βάρη, για την επίτευξη αδράγματος	70
5.16	Τα επιμέρους βήματα της επεξεργασίας, του κατηγοριοποιητή και του υπολογισμού των βαρών του μοντέλου	70
5.17	Η έξοδος του αποκωδικοποιητή Decoder 1 χωρίς χρήση του μοντέλου ακινητοποίησης	71
5.18	Η έξοδος του μοντέλου ακινητοποίησης για ιδανικά βάρη	72
5.19	Η έξοδος του μοντέλου ακινητοποίησης για πραγματικά βάρη	72
5.20	Σύγκριση του μοντέλου στις χρονικές περιόδους ακινησίας για ιδανικά βάρη	73
5.21	Σύγκριση της μεθόδου στις χρονικές περιόδους ακινησίας για πραγματικά βάρη	74
6.1	Τμήμα του καναλιού fp1 έπειτα από επεξεργασία. Η κατακόρυφη γραμμή σηματοδοτεί τη χρονική στιγμή που ο χρήστης καλείται να κλείσει εθελούσια τα μάτια του. Στο σχήμα παρατηρούνται οι κυματομορφές A που αντιστοιχεί σε ακούσια βλεφάρισμα, B που αντιστοιχεί στο κλείσιμο των ματιών και C που αντιστοιχεί στο άνοιγμα των βλεφάρων.	77
6.2	Το μοντέλο για την κατηγοριοποίηση για εκδήλωση της πρόθεσης για άδραγμα.	78
6.3	Τρόπος διαχωρισμού του σήματος σε επικαλυπτόμενα παράθυρα κατά την είσοδο στον κατηγοριοποιητή.	78
6.4	Η ERP Image για το κανάλι Fp1 με τις 220 εποχές που προέκυψαν από τις πειραματικές μετρήσεις.	79
6.5	Η μέση δραστηριότητα ERP όλων των εποχών για όλους χρήστες (κανάλι Fp1).	80
6.6	Η έξοδος ενός Naive Bayes κατηγοριοποιητή για τα δεδομένα δοκιμής.	81
6.7	Η έξοδος ενός Random Forest κατηγοριοποιητή για τα δεδομένα δοκιμής.	81
6.8	Η έξοδος ενός Τεχνητού Νευρωνικού δικτύου για τα δεδομένα δοκιμής.	82
7.1	Στιγμιότυπο 1 του πειράματος	83
7.2	Στιγμιότυπο 2 του πειράματος	84
7.3	Στιγμιότυπο 3 του πειράματος	84

Κατάλογος Πινάκων

5.1	Σύγκριση των μεθόδων ICA και PCA για την αποκωδικοποίηση. Οι τιμές των σφαλμάτων είναι σε εκατοστά	60
5.2	Σύγκριση των μεθόδων ICA και PCA για την κατηγοριοποίηση ακινησίας σε Νευρωνικό Δίκτυο.	63
5.3	Οι τιμές κβαντοποίησης των τιμών M.	68
5.4	Επίδοση του μοντέλου ακινητοποίησης για σταθεροποίηση της εξόδου αποκωδικοποίησης κατά την ακινησία	74
6.1	Σύγκριση των μεθόδων μεταξύ των τριών κατηγοριοποιητών.	80

Κεφάλαιο 1

Εισαγωγή

Τις τελευταίες δεκαετίες η επιστήμη της ρομποτικής έχει γνωρίσει θεαματική ανάπτυξη. Αν και αρχικά η χρήση των ρομπότ γινόταν σε βιομηχανικό επίπεδο, πλέον στις τεχνολογικά αναπτυγμένες κοινωνίες τα ρομπότ χρησιμοποιούνται καθημερινά σε στρατιωτικές εργασίες, σε επιχειρήσεις διάσωσης, στην ψυχαγωγία, στην νοσοκομειακή περίθαλψη, ως οικιακή βοήθεια. Με την ευρύτερη διάδοση των ρομπότ και την αυτοματοποίηση καθημερινών διαδικασιών, παρουσιάστηκε αμέσως η ανάγκη για άμεση και εύκολη επικοινωνία μεταξύ ανθρώπων και ρομπότ. Η αλληλεπίδραση ανθρώπου-ρομπότ (Human-Robot Interaction) αποτελεί έναν νέο διεπιστημονικό κλάδο που συνδυάζει τη ρομποτική, την τεχνητή νοημοσύνη, κοινωνικές επιστήμες κ.ά. και έχει στόχο την κατά το δυνατόν πιο άμεση, γρήγορη και εύκολη επικοινωνία ανθρώπου-ρομπότ σε φιλικό περιβάλλον. Πιο σύγχρονοι και άμεσοι τρόποι επικοινωνίας και συντονισμού μεταξύ ανθρώπου και ρομπότ μπορούν να δημιουργηθούν αν χρησιμοποιηθούν μέθοδοι της νευρο-επιστήμης (neuro-science), με τη δημιουργία κατάλληλων διεπαφών.

1.1 Νευρο-ρομποτική

Η νευρο-ρομποτική είναι το αποτέλεσμα της συμβολής επιστημών όπως η νευροεπιστήμη, η τεχνητή νοημοσύνη και η ρομποτική. Ασχολείται με την ενσωμάτωση της γνώσης των βιολογικών συστημάτων σε μηχανικά συστήματα. Περιλαμβάνει τη δημιουργία νευρο-βιολογικά εμπνευσμένων ρομποτικών συσκευών [4]. Σε τέτοια περίπτωση προσεγγίζει τις ίδιες περιοχές με την νευρο-επιστήμη:

- κινητήριος έλεγχος και κίνηση
- μάθηση και συστήματα μνήμης
- συστήματα αξίας και επιλογή δράσης


Τα μηχανικά συστήματα που δημιουργούνται, γνωστά και ως νευρο-ρομπότ, μπορούν για παράδειγμα να χρησιμοποιούν μεθόδους ελέγχου κίνησης για εκμάθηση διόρθωσης σφάλματος [39] και προβλεπτικού ελέγχου [51]. Μπορούν ακόμα να μαθαίνουν λαβύρινθους και

διάφορα πρότυπα, σύμβολα, ή χρώματα από οπτικές ή ακουστικές διεγέρσεις και να δρουν αναλόγως [38], ή να προσομοιάσουν διάφορες περίπλοκες λειτουργίες της αισθητήριας αντίληψης οργανισμών, όπως η όραση.

Η νευρο-ρομποτική περιέχει επίσης και τη δημιουργία μοντέλων προσομοίωσης νευρώνων, και τη μελέτη συμβίωσης βιολογικών και μηχανικών συστημάτων. Σήμερα λόγω της αύξησης τις υπολογιστικής δύναμης των υπολογιστών, είναι δυνατή η προσομοίωση τεράστιων ρεαλιστικών νευρωνικών δικτύων και διαφόρων υπολογιστικών μοντέλων. Υπάρχουν πλέον ρομπότ με εξαιρετικές δυνατότητες μάθησης που ξεπερνούν σε απόδοση τις παραδοσιακές μορφές μοντέλων ελέγχου, και αυτός είναι ένας από του λόγους που ο κλάδος έχει προσελκύσει το ενδιαφέρον πολλών ερευνητών τα τελευταία χρόνια.

1.2 Διασύνδεση Ανθρώπου-Μηχανής (Human-Machine Interface)

Το μέσο διασύνδεσης (interface) μεταξύ ανθρώπου και μηχανής αποτελεί ένα ακόμα σημαντικό πεδίο που απασχολεί την ερευνητική κοινότητα στον τομέα της ρομποτικής και επηρεάζει σημαντικά την ταχύτητα και ποιότητα της επικοινωνίας. Τρισδιάστατοι μοχλοί (joystick), απτικοί μηχανισμοί (haptic devices), ακόμα και φωνητικές εντολές έχουν χρησιμοποιηθεί στο παρελθόν για τον τηλεχειρισμό ρομποτικών συστημάτων. Στις περισσότερες περιπτώσεις όμως απαιτούνται περίπλοκοι μηχανισμοί, συστήματα αισθητήρων ή συσκευές καταγραφής εικόνας και βίντεο για το σωστό και ασφαλή τηλε-χειρισμό. Επιπλέον, απαιτείται η χρήση του συστήματος να γίνεται από ειδικά εκπαιδευμένο άτομο, το οποίο να γνωρίζει επαρκώς το σύστημα. Αυτό συνεπάγεται ως ανάγκη την εξοικίωση ενός χρήστη με το σύστημα για κάποιο χρονικό διάστημα πριν από τη χρήση του. Ιδανικά, χρειάζεται ένα μέσο διασύνδεσης που να διακρίνεται από απλά στη χρήση τους συστήματα, να είναι κατανοητό δίχως να χρειάζεται ιδιαίτερη εκπαίδευση από το χρήστη και να μπορεί να δίνει επαρκή αποτελέσματα. Ένας τέτοιος τρόπος διεπαφής χρήστη-ρομπότ είναι μέσω της χρήσης βιο-σημάτων που παράγει συνειδητά ή μη ο άνθρωπος και μπορούν να χρησιμοποιηθούν ως δίαυλος επικοινωνίας με το ρομπότ.




Σχήμα 1.1: Εξαγωγή βιο-σημάτων από άνθρωπο. Πηγή: [25].

Τα βιο-σήματα ανήκουν στην κατηγορία των βιο-ιατρικών σημάτων και ορίζονται ως το αποτέλεσμα διαφόρων φυσιολογικών (physiological) φαινομένων σε ζωντανούς οργανισμούς. Πρόκειται για σήματα που μπορούν να παράγονται στο ανθρώπινο σώμα και μπορούν να ανιχνευθούν, ανάλογα με το είδος προέλευσής τους, με οπτική ή ακουστική επιθεώρηση ή με διάφορες συσκευές καταγραφής [25]. Ανάλογα με την προέλευση χωρίζονται σε οπτικά (π.χ. Οπτοηλεκτρονική πληθυσμογραφία - OEP), ακουστικά (π.χ. Φωνοκαρδιογραφία - PCG), μαγνητικά (π.χ. Μαγνητοκαρδιογραφία - MCG), ηλεκτρικά (π.χ. Ηλεκτρομυογραφία - EMG) κ.ά. Ιδιαίτερο ενδιαφέρον παρουσιάζουν τα ηλεκτρικά σήματα, τα οποία προκύπτουν από την ηλεκτρική δραστηριότητα διαφόρων οργάνων του σώματος, και μπορούν να καταγραφούν με αισθητήρες όπως ηλεκτρόδια. Σε αυτές τις περιπτώσεις, αν και το σύστημα και η συσκευή καταγραφής τέτοιων σημάτων είναι αρκετά περίπλοκα ως προς τη λειτουργία τους, ο χρήστης δεν χρειάζεται να γνωρίζει τίποτα σχεδόν για τη χρήση τους, πέρα από κάποιες απλές οδηγίες.

1.3 Η Ηλεκτροεγκεφαλογραφία (ΗΕΓ) ως μέσο Διασύνδεσης Ανθρώπου-Μηχανής

Μία εξαιρετικά ενδιαφέρουσα προσέγγιση καταγραφής ηλεκτρικών σημάτων είναι η καταγραφή πληροφορίας από το Κεντρικό Νευρικό Σύστημα του ανθρώπου (Central Nervous System). Ο πλέον διαδεδομένος τρόπος καταγραφής πληροφοριών τέτοιου είδους είναι η Ηλεκτροεγκεφαλογραφία ή ΗΕΓ (Electroencephalography or EEG), ένας σύγχρονος, μη επεμβατικός τρόπος καταγραφής ηλεκτρικών σημάτων από τον εγκέφαλο [43]. Ο εγκέφαλος παράγει ηλεκτρικά δυναμικά τα οποία μπορούν να ανιχνευθούν στην εξωτερική επιφάνεια του κρανίου με κατάλληλα ηλεκτρόδια και να χρησιμοποιηθούν σε διεπαφές επικοινωνίας ανθρώπου-μηχανής. Τέτοιες διεπαφές ονομάζονται Διεπαφές Εγκεφάλου-Υπολογιστή (Δ.Ε.Υ.) ή αλλιώς Brain Computer Interfaces (BCI) (Σχ.1.2). Οι Δ.Ε.Υ. μεταφράζουν τα σήματα του εγκεφάλου σε εξόδους που επιτρέπουν στο χρήστη να επικοινωνεί χωρίς τη συμμετοχή περιφερειακών νευρών ή μυών [37]. Αυτά τα σήματα είναι ασθενή και θορυβώδη, αλλά αν επεξεργαστούν κατάλληλα μπορούν να χρησιμοποιηθούν για την ταχεία επικοινωνία ανθρώπου-ρομπότ.

Το κύριο πλεονέκτημα τέτοιων διεπαφών είναι ότι, επειδή δεν εξαρτώνται από το νευρομυϊκό έλεγχο, μπορούν να χρησιμοποιηθούν σε περιπτώσεις που ο χρήστης πάσχει από νευρομυϊκές διαταραχές όπως πλάγια μυατροφική σκλήρυνση (ALS), εγκεφαλική παράλυση (cerebral palsy), ή σε περιπτώσεις παράλυσης λόγω τραυματισμού στη σπονδυλική στήλη. Επιπλέον, χρησιμοποιούνται και σε περιπτώσεις απώλειας των άνω άκρων λόγω τραυματισμού ή ασθένειας, σε παραπληγικούς και τετραπληγικούς ασθενείς. Ο κεντρικός σκοπός της έρευνας σε αυτά τα μέσα διασύνδεσης είναι να δοθεί η δυνατότητα σε τέτοιους χρήστες να καταφέρουν να γνωστοποιήσουν τις επιθυμίες τους σε τρίτους και να μπορούν να αλληλεπιδράσουν με το περιβάλλον τους χρησιμοποιώντας ειδικό λογισμικό ή ρομποτικές συσκευές. Αν και μέχρι στιγμής ο στόχος είναι η διευκόλυνση της ποιότητας ζωής ανθρώπων με κινητικές δυσκολίες ή παράλυση, μπορούν να χρησιμοποιηθούν και από υγιείς χρήστες για πιο γρήγορη αλληλεπίδραση με το περιβάλλον. Απώτερος στόχος για το μέλλον είναι να μπορεί κάποιος χρήστης να επικοινωνεί με αυτόνομες ρομποτικές συσκευές με τις σκέψεις του, χωρίς να χρειάζεται



Σχήμα 1.2: Μία γενική περιγραφή μιας ΔΕΥ. Πηγή: [37].

να δώσει εντολές γραπτώς ή φωνητικά, ή να τηλεχειριστεί χειροκίνητα το ρομπότ. Το θέμα της Ηλεκτροεγκεφαλογραφίας και οι τρόποι χρήσης των σημάτων που παράγονται εξετάζονται λεπτομερώς στο Κεφάλαιο 4 της εργασίας.

1.4 Σχετικές εργασίες


Η κλάδοι που ασχολούνται με την διασύνδεση ανθρώπου-ρομπότ και την Ηλεκτροεγκεφαλογραφία έχουν προσελκύσει το ενδιαφέρον πολλών ερευνητών, λόγω των προοπτικών εξέλιξής τους στο μέλλον. Αν και ο κλάδος έχει έλθει στο προσκήνιο σχετικά πρόσφατα, στην πραγματικότητα η ιδέα της Ηλεκτροεγκεφαλογραφίας αναπτύχθηκε πριν από αρκετές δεκαετίες από τον Γερμανό Hans Berger, ο οποίος το 1929 και μέχρι και το 1938 δημοσίευσε 14 αναφορές [6] σχετικές με το ανθρώπινο ηλεκτροεγκεφαλογράφημα και εισήγαγε την έννοια. Αρκετά χρόνια αργότερα, το 1988, γίνεται η πρώτη αναφορά για έλεγχο ρομπότ μέσω σημάτων ΗΕΓ [9]. Ερευνητές, έχουν εδώ και καιρό αποδείξει ότι τα δυναμικά που σχηματίζονται στην επιφάνεια του εγκεφάλου έχουν συγκεκριμένο εύρος συχνοτήτων και συγκεκριμένες μορφές [49]. Οι κυματομορφές που προκύπτουν μπορεί να αλλάζουν εξαιτίας εξωτερικών ή και εσωτερικών ερεθισμάτων/διεγέρσεων, όπως για παράδειγμα με την κίνηση των ματιών, την αντίληψη σφάλματος, ή την έντονη σκέψη [43].

Πλέον, υπάρχει πληθώρα ερευνητικών προγραμμάτων και εργασιών που ασχολούνται με την ΗΕΓ και την ανάπτυξη των διεπαφών που αναφέρθηκαν νωρίτερα. Πρόσφατα ο Wolpaw κατάφερε να ελέγξει κέρσορα ηλεκτρονικού υπολογιστή μέσω ΗΕΓ σημάτων [62] και ο Stevenson κατάφερε να αποκωδικοποιήσει τροχιά κίνησης στο χώρο μέσω σημάτων από την κίνηση των ματιών [58]. Μεγάλο ενδιαφέρον παρουσιάζουν και έρευνες σχετικά με τα σήματα που προκύπτουν από τις κινήσεις των βλεφάρων, και τον τρόπο που αυτά μπορούν να χρησιμοποιηθούν, όπως αυτή του Ramli το 2015 [46], και οι οποίες χρησιμοποιούνται για να υποστηρίξουν το μοντέλο που παρουσιάζεται στη συνέχεια (Κεφάλαιο 6). Έρευνες όπως αυτή του Lawhern et al. [31] και Chambayil et al. [12], δίνουν ξεκάθαρα αποτελέσματα για τη

διαφορά των σημάτων ανάμεσα στο κλείσιμο, το άνοιγμα, και το βλεφάρισμα (blinking) των ματιών. Επιπλέον, ο Kanoga et al. [26] κατάφερε να διαχωρίζει τα εθελούσια από τα ακούσια βλεφαρίσματα. Στην ηλεκτροεγκεφαλογραφία υπάρχουν σήματα που θεωρούνται ως θόρυβος, και ονομάζονται EEG artifacts. Αυτά τα σήματα προέρχονται από μη επιθυμητές κινήσεις των ματιών, των βλεφάρων, ή των μυών γύρω από το μέτωπο και έχουν ήδη προταθεί αρκετοί τρόποι απομάκρυνσής τους [56], [31], [60]. Όμως, όπως αποδεικνύεται στην πρόσφατη εργασία του Abdelfattah [1] τα σήματα αυτά περιέχουν πληροφορία που μπορεί να φανεί χρήσιμη και να χρησιμοποιηθεί σαν είσοδος σε διεπαφή ανθρώπου-μηχανής.

Τέλος, υπάρχουν πλήθος περιπτώσεων σε πρόσφατες έρευνες που χρησιμοποιείται ο άνθρωπος σε συστήματα εγκεφάλου-υπολογιστή για το χειρισμό ρομπότ. Σε πολλές περιπτώσεις δημιουργούνται υβριδικά (hybrid) συστήματα που συνδυάζουν την εκδήλωση πρόθεσης χρήστη με αυτόματα συστήματα όρασης υπολογιστών κ.ά. [41] ή στις οποίες ο χρήστης χρησιμοποιείται για τη διόρθωση μιας αυτόματης διεργασίας σε περίπτωση λάθους [48].

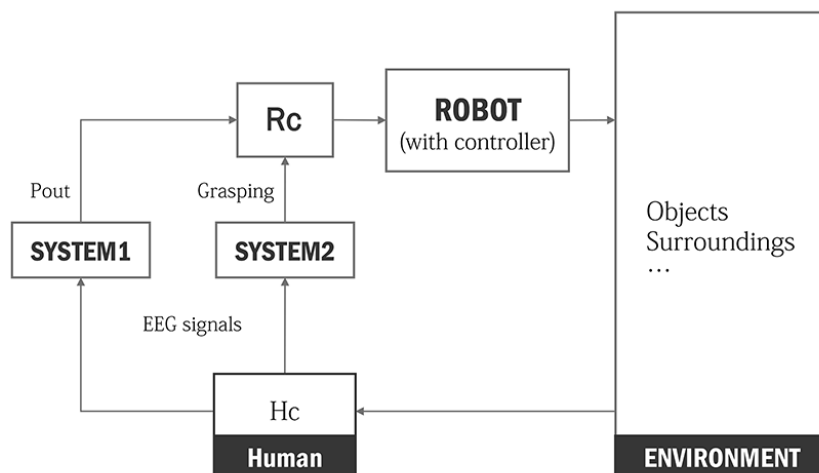
1.5 Αντικείμενο της διπλωματικής



Σχήμα 1.3: Καλλιτεχνική απεικόνιση λειτουργίας του μέσου διασύνδεσης. Αρχικά ο χρήστης εστιάζει στο τελικό στοιχείο δράσης (ρομποτικό χέρι) του ρομπότ (A). Με την κίνηση των ματιών καθορίζει την τροχιά κίνησης του χεριού ώστε να φτάσει σε ένα επιθυμητό σημείο (B). Κλείνοντας τα μάτια η λαβή του ρομποτικού χεριού κλείνει και πιάνει το αντικείμενο (C). Με το ίδιο τρόπο όπως πριν μετακινεί το χέρι σε ένα διαφορετικό επιθυμητό σημείο (D). Κλείνοντας πάλι τα μάτια η λαβή ανοίγει και το αντικείμενο αφήνεται ελεύθερο (E).

Σκοπός της παρούσας εργασίας είναι η σχεδίαση ενός όσον το δυνατόν πιο ολοκληρωμένου μοντέλου διασύνδεσης εγκεφάλου-υπολογιστή, ώστε να επιτευχθεί άδραγμα (grasping) ενός αντικειμένου (σχήμα 1.3). Το σύστημα που προτείνεται χρησιμοποιεί τεχνικές μηχανικής

μάθησης και επεξεργασίας σημάτων και στηρίζεται σε προηγούμενο μοντέλο αποκωδικοποίησης τρισδιάστατης, συνεχούς κίνησης [35]. Στην εργασία αναλύονται διάφοροι μέθοδοι αποκωδικοποίησης βιο-σημάτων που καταγράφονται από τον άνθρωπο, ώστε να εκτιμηθεί η επιθυμητή τροχιά κίνησης ενός ρομποτικού βραχίονα. Επιπλέον, εξετάζονται διαφορετικές τεχνικές μηχανικής μάθησης και επεξεργασίας των σημάτων και παρατίθενται οι συγκρίσεις μεταξύ των.



Σχήμα 1.4: Η Διεπαφή Εγκεφάλου-Υπολογιστή, τα υποσυστήματα της οποίας περιγράφονται και αναπτύσσονται στην παρούσα εργασία

Η συνεισφορά της παρούσας διπλωματικής εργασίας έγκειται στην ανάπτυξη ενός νέου προσαρμοστικού μοντέλου με βάρη που διευκολύνει το άδραγμα, και στηρίζεται στη δημιουργία ενός κατηγοριοποιητή (classifier) για εύρεση της κίνησης ή ακινησίας του ρομποτικού χεριού (System1 στο σχήμα 1.4). Επιπλέον, εξετάζονται διάφορες τεχνικές επεξεργασίας των ΗΕΓ σημάτων και εξετάζεται η δυαδική κατηγοριοποίηση (binary classification) του σύντομου κλείσιμου των ματιών, ως μέσου εκδήλωσης της επιθυμίας του χρήστη για άδραγμα κάποιου αντικειμένου (System2 στο σχήμα 1.4).

1.6 Οργάνωση της εργασίας

Η δομή της εργασίας είναι ως εξής:

- 1ο Κεφάλαιο: παρουσιάζονται εισαγωγικές έννοιες,
- 2ο Κεφάλαιο: παρατίθενται μαθηματικοί ορισμοί και θεωρητικά στοιχεία,
- 3ο Κεφάλαιο: παρουσιάζονται όλες οι λεπτομέρειες για τον εξοπλισμό και την καταγραφή πειραματικών δεδομένων από πραγματικούς χρήστες,
- 4ο Κεφάλαιο: γίνεται μία εκτενής αναφορά στη χρήση και επεξεργασία ΗΕΓ σημάτων στο σύστημα που προτείνεται,

- 5ο Κεφάλαιο: δίνονται όλες οι λεπτομέρειες σχετικά με το μοντέλο ακινητοποίησης του χεριού για άδραγμα,
- 6ο Κεφάλαιο: γίνεται αναφορά στη δημιουργία του κατηγοριοποιητή για την εύρεση του κλείσιμου των ματιών,
- 7ο Κεφάλαιο: παρουσιάζονται το τελικό πείραμα, γενικά συμπεράσματα και μελλοντικές κατευθύνσεις της εργασίας.

Η εργασία ολοκληρώνεται με το γλωσσάριο και την παράθεση της βιβλιογραφίας που χρησιμοποιήθηκε.


Κεφάλαιο 2

Μαθηματικές έννοιες και θεωρητικό υπόβαθρο

Σε αυτό το κεφάλαιο εισάγονται οι απαραίτητες μαθηματικές έννοιες και τα αναγκαία θεωρητικά στοιχεία για την κατανόηση των μοντέλων και των αλγορίθμων που χρησιμοποιούνται στην παρούσα εργασία.

2.1 Ρομποτικοί βραχίονες

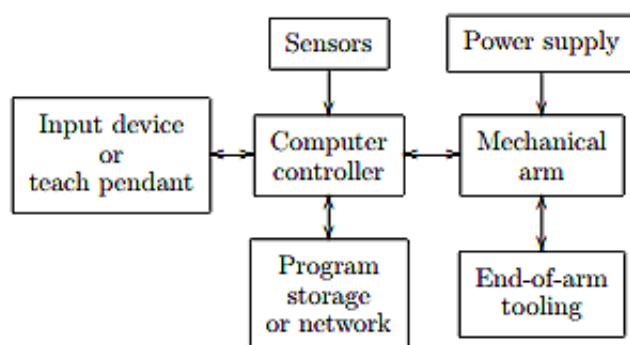
Κοινοί ρομποτικοί χειριστές, τόσο στη βιομηχανία όσο και σε ερευνητικά εργαστήρια, είναι οι ρομποτικοί βραχίονες. Οι ρομποτικοί βραχίονες αποτελούνται από αλληλουχίες άκαμπτων συνδέσμων (links) που συνδέονται μεταξύ τους μέσω αρθρώσεων (joints) για το σχηματισμό μιας κινηματικής αλυσίδας (kinematic chain) [53] (Σχήμα 2.1). Η διάταξη (configuration) ενός χειριστή είναι ο απόλυτος καθορισμός κάθε σημείου του χειριστή στο χώρο που υπάρχει και κινείται.



Σχήμα 2.1: Ο Ρομποτικός βραχίονας Mitsubishi PA10 Πηγή: [19].

Ο αριθμός και οι διάφοροι τύποι συνδέσμων και αρθρώσεων (σφαιρική, στροφική ή πρισμα-

τική) που μπορεί να έχει μια τέτοια αλυσίδα, προσδίδουν διαφορετικούς βαθμούς ελευθερίας (degrees of freedom - DOF). Ένα αντικείμενο έχει n βαθμούς ελευθερίας όταν η διάταξή του μπορεί να οριστεί από n παραμέτρους. Στην άκρη της αλυσίδας τοποθετείται συνήθως ένα τελικό στοιχείο δράσης (End effector) που μπορεί να είναι μια αρπάγη, κάποιο εργαλείο ή κάποιο μηχανικό χέρι. Για την τοποθέτηση του τελικού στοιχείου δράσης σε τρισδιάστατο χώρο, όσον αφορά τη θέση του και τον προσανατολισμό του, απαιτείται να υπάρχουν 6 βαθμοί ελευθερίας. Αν διατίθενται περισσότεροι από όσους απαιτούνται για την εκτέλεση μιας εργασίας (task) τότε το σύστημα ονομάζεται πλεονάζον (redundant). Το σύνολο των σημείων που μπορεί να επενεργήσει το τελικό στοιχείο δράσης ονομάζεται χώρος εργασίας (workspace), είναι υποσύνολο του περιβάλλοντος του ρομπότ και εξαρτάται και από το μέγεθος και τη δομή του. Ο ρομποτικός βραχίονας είναι απλά ένα στοιχείο ενός ευρύτερου ρομποτικού συστήματος,



Σχήμα 2.2: Στοιχεία ενός ρομποτικού συστήματος. Πηγή: [53].

τα στοιχεία του οποίου φαίνονται στο Σχήμα 2.2. Αν και τα συστήματα αυτά είναι μηχανικά συστήματα, ενδιαφερόμαστε κυρίως για τη μαθηματική μοντελοποίηση τέτοιων ρομπότ και η σύντομη ανάλυση που θα ακολουθήσει θα περιοριστεί σε μαθηματικά μοντέλα.

2.1.1 Ευθεία και αντίστροφη Κινηματική Ανάλυση

Ευθεία κινηματική Ανάλυση: Η ευθεία κινηματική ανάλυση (forward kinematics) ενός βραχίονα είναι η συσχέτιση της θέσης/προσανατολισμού του τελικού σημείου δράσης με τις αρθρώσεις που τον αποτελούν

$$p = F(q) \quad (2.1)$$

όπου $p \in \mathbb{R}^m$ είναι η θέση/προσανατολισμός του τελικού σημείου δράσης ως προς το πλαίσιο συντεταγμένων της βάσης του βραχίονα, και $q = [q_1, q_2, \dots, q_n]^T \in \mathbb{R}^n$ είναι το διάνυσμα των τιμών των n βαθμών ελευθερίας των αρθρώσεων. Η συνάρτηση F είναι μη γραμμική και εκφράζει τη σχέση μεταξύ των συντεταγμένων στο χώρο των αρθρώσεων, με αυτές στο χώρο εργασίας. Ο υπολογισμός της συνάρτησης F γίνεται συνήθως μέσω ομογενών μετασχηματισμών από τη βάση του βραχίονα ως και το τελικό σημείο δράσης. Για να γίνει ορθά η κινηματική ανάλυση, τοποθετούμε συστήματα αναφοράς συντεταγμένων σε κάθε σύνδεσμο. Έστω ότι


είναι $O_i(x_i, y_i, z_i)$ το σύστημα αναφοράς του i -οστού συνδέσμου και $O_{i-1}(x_{i-1}, y_{i-1}, z_{i-1})$ το σύστημα αναφοράς του $(i-1)$ -οστού συνδέσμου, και έστω ότι θεωρούμε $A_i^{i-1}(q_i)$ ομογενή μήτρα μετασχηματισμού που εκφράζει τη θέση και τον προσανατολισμό του πλαισίου O_i ως προς το O_{i-1} . Τότε είναι:

$$T_{EE}^0 = A_1^0(q_1)A_2^1(q_2)\dots A_n^{n-1}(q_n) \quad (2.2)$$

όπου T_{EE}^0 είναι το ομογενές μητρώο μετ/σμού από τη βάση του βραχίονα έως το τελικό σημείο δράσης. Ένας ευρέως χρησιμοποιούμενος τρόπος σύμβασης για τα πλαίσια αναφοράς γίνεται με τη μέθοδο Denavit-Hartenberg ή αλλιώς D-H [21]. Σε αυτή τη μέθοδο τα πλαίσια τοποθετούνται με συγκεκριμένους κανόνες και κάθε μήτρα μετ/σμού εκφράζεται ως το γινόμενο τεσσάρων βασικών μετ/σμών

$$A_i = Rot_{z,\theta_i} Tra_{z,d_i} Tra_{x,\alpha_i} Rot_{x,\alpha_i} \quad (2.3)$$

όπου Rot_{z,θ_i} είναι ο πίνακας περιστροφής γωνίας θ_i ως προς τον άξονα z και Tra_{z,d_i} είναι ο πίνακας μεταφοράς απόστασης d_i ως προς τον άξονα z .



Σχήμα 2.3: Διαφορετικές λύσεις αντίστροφου κινηματικού προβλήματος για τον βραχίονα PUMA. Πηγή: [54].

Αντίστροφη κινηματική Ανάλυση: Στην αντίστροφη κινηματική ανάλυση (inverse kinematics) στόχος είναι η αντίστροφη διαδικασία της ευθείας κινηματικής, δηλαδή η εύρεση κατάλληλων γωνιών των αρθρώσεων q για συγκεκριμένη θέση/προσανατολισμό του σημείο δράσης p :

$$q = F^{-1}(p) \quad (2.4)$$

Η εύρεση λύσης στο παραπάνω πρόβλημα δεν εξασφαλίζεται πάντοτε, και πολλές φορές δεν είναι μοναδική εξαιτίας πλεοναζόντων βαθμών ελευθερίας (Σχήμα 2.3), γι' αυτό και υπάρχει μεγάλη δυσκολία στην επίλυση. Η ύπαρξη λύσης εξασφαλίζεται μόνον σε περίπτωση που η επιθυμητή θέση/προσανατολισμός βρίσκεται εντός του χώρου εργασίας και δεν υπάρχουν ιδιόμορφες διατάξεις (singularities), δηλαδή διατάξεις που περιέχουν σημεία στα οποία είναι αδύνατο να πάει το ρομπότ. Γενικά η επίλυση του αντίστροφου κινηματικού προβλήματος χαρακτηρίζεται από μεγάλη δυσκολία, με εξαίρεση απλούς ρομποτικούς χειριστές, που η λύση βρίσκεται πολλές φορές ακόμα και γεωμετρικά.

2.1.2 Διαφορική κινηματική ανάλυση

Σε αυτού του είδους την ανάλυση γίνεται έλεγχος με βάση την ταχύτητα των αρθρώσεων και όχι τη θέση. Για τη διαφορική κινηματική χρησιμοποιείται ένας πίνακας γνωστός ως Ιακωβιανή ορίζουσα (Jacobian) που εκφράζει τη σχέση μεταξύ της ταχύτητας των αρθρώσεων και της ταχύτητας του τελικού σημείου δράσης ως :

$$\dot{p} = J(q)\dot{q} \quad (2.5)$$

όπου \dot{p} είναι η ταχύτητα του τελικού σημείου δράσης ως προς τη βάση του βραχίονα, $J(q)$ η ιακωβιανή και \dot{q} η ταχύτητα των αρθρώσεων.

2.1.3 Έλεγχος πλεοναζόντων βαθμών Ελευθερίας

Όπως αναφέρθηκε και στην προηγούμενη υποενότητα 2.1, όταν είναι $n > m$ και όταν $rank(J) = m$ έχουμε $n - m$ πλεονάζοντες βαθμούς ελευθερίας. Ο υποχώρος του χώρου των αρθρώσεων που απεικονίζεται μέσω της J σε μηδενική ταχύτητα τελικού σημείου δράσης ονομάζεται μηδενικός υποχώρος και μπορεί να εκμεταλλευτεί για τη βελτιστοποίηση κριτηρίων επηρεάζοντας τον τρόπο με τον οποίο το ρομπότ θα δώσει την επιθυμητή ταχύτητα. Η βέλτιστη λύση της διαφορικής εξίσωσης

$$J\dot{q} = \dot{p}, \quad J : m \times n \quad (2.6)$$

ως προς την ελαχιστοποίηση της κλασικής συνάρτησης κόστους

$$F(\dot{q}) = \frac{1}{2} \|\dot{q}\|^2 \quad (2.7)$$

είναι η

$$\dot{q} = J^+ \dot{p}, \quad (2.8)$$

όπου $J^+ = J^T(JJ^T)^{-1}$: Moore-Penrose pseudo-inverse Jacobian [27]. Μια μεθοδολογία διάσπασης της εργασίας πλεοναζόντων ρομπότ [52] είναι:

$$\dot{q} = J^+ \dot{p}_d + (I_n - J^+ J) \dot{q}_r \quad (2.9)$$

που χρησιμοποιείται συχνά για τον έλεγχο ταχυτήτων ρομποτικών βραχιόνων.

2.2 Ψηφιακή επεξεργασία σημάτων

Η ψηφιακή επεξεργασία σημάτων (Digital Signal Processing) ασχολείται με την επεξεργασία των σημάτων στο πεδίο του χρόνου, του χώρου ή και της συχνότητας, με χρήση ψηφιακού υπολογιστικού μέσου, εκτελώντας πράξεις επεξεργασίας σήματος. Τα σήματα που επεξεργάζονται με αυτό το τρόπο είναι μία σειρά από αριθμούς που αντιπροσωπεύουν δείγματα μιας συνεχούς μεταβλητής. Η ψηφιακή επεξεργασία σημάτων χρησιμοποιείται ευρέως σε πολλές εφαρμογές όπως της επεξεργασία ήχου και φωνής, στον υπολογισμό φασματικής πυκνότητας, στην επεξεργασία ψηφιακής εικόνας, στην επεξεργασία βιο-ιατρικών σημάτων κ.ά. [45]

2.2.1 Ψηφιακά φίλτρα

Στη ψηφιακή επεξεργασία σήματος ένα ψηφιακό φίλτρο ορίζεται ως το σύστημα που εκτελεί μαθηματικές πράξεις σε ένα ψηφιακό σήμα διακριτού χρόνου ώστε να μειώσει ή να βελτιώσει συγκεκριμένες πλευρές του σήματος. Κάθε ψηφιακό φίλτρο χαρακτηρίζεται από τη συναρτηση μεταφοράς του (transfer function) ή από τη συνάρτηση διαφορών του (difference equation). Μαθηματική ανάλυση της συνάρτησης μεταφοράς μπορεί να εκτιμήσει τη συμπεριφορά του φίλτρου για κάθε είσοδο. Η συνάρτηση μεταφοράς ενός γραμμικού, χρονικά ανεξάρτητου φίλτρου μπορεί να εκφραστεί μέσω του Z μετ/σμού, όπως φαίνεται στην εξίσωση 2.10

$$H(z) = \frac{B(z)}{A(z)} = \frac{b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_nz^{-n}}{a_0 + a_1z^{-1} + a_2z^{-2} + \dots + a_mz^{-m}} \quad (2.10)$$

όπου η τάξη του φίλτρου είναι το $\max(n, m)$, και τα $b_0, a_0, b_1, a_1, \dots$ αποτελούν τις παραμέτρους του φίλτρου. Η συνάρτηση μεταφοράς του φίλτρου επηρεάζει τόσο το πλάτος όσο και τη φάση του σήματος, ορίζοντας την καθυστέρηση φάσης phase delay τ_ϕ και την καθυστέρηση ομάδας τ_g ως συνάρτηση της συχνότητας ω .

$$\tau_\phi(\omega) = -\frac{\phi(\omega)}{\omega}, \quad \tau_g = -\frac{d\phi(\omega)}{d\omega}$$

$$\phi(\omega) = \arg\{H(\omega)\}$$

Η χρονική απόκριση ενός φίλτρου ορίζεται ως $h[k]$ ή h_k και δείχνει τη συμπεριφορά του φίλτρου με είσοδο τη συνάρτηση δέλτα του Κρόνεκερ $\delta(\omega)$. Με βάση τη συμπεριφορά αυτή τα ψηφιακά φίλτρα χωρίζονται σε δύο κατηγορίες:

- άπειρης χρονικής απόκρισης (IIR) και
- πεπερασμένης χρονικής απόκρισης (FIR)

Στην πρώτη περίπτωση πρόκειται για αναδρομικά φίλτρα, με την έξοδο να εξαρτάται τόσο από την τρέχουσα όσο και από τις προηγούμενες εισόδους και εξόδους, και έχουν μορφή $\sum_{m=0}^M \alpha_m y_{n-m} = \sum_{k=0}^N b_k x_{n-k}$. Στη δεύτερη περίπτωση η χρονική απόκριση ισούται με την ακολουθία των παραμέτρων του φίλτρου $y_n = \sum_{k=0}^N h_k x_{n-k}$. Τα φίλτρα FIR είναι πάντα ευσταθή, αλλά εισάγουν μεγάλη καθυστέρηση ομάδας και χρειάζονται μεγάλη τάξη για την επίτευξη των επιθυμητών χαρακτηριστικών. Τα φίλτρα IIR δεν είναι πάντα απαραίτητα ευσταθή,

και χρειάζονται κάποιο χρόνο για να ξεπεραστεί η μεταβατική κατάσταση και να σταθεροποιηθεί η απόκριση. Δεν απαιτούν, όμως, μεγάλη τάξη και εισάγουν μικρή καθυστέρηση, και άρα είναι προτιμότερα για εφαρμογές εκτέλεσης σε πραγματικό χρόνο (real-time).

2.2.2 Φασματική Ανάλυση Σημάτων

Το φάσμα ισχύος μιας χρονοσειράς (time-series) $x(t)$ περιγράφει τη κατανομή της ισχύος σε συνιστώσες συχνότητας που συνθέτουν το σήμα. Η κατανομή της κατανομής της ισχύος του σήματος είναι απαραίτητη για το σχεδιασμό οποιουδήποτε φίλτρου. Σύμφωνα με την ανάλυση Fourier κάθε φυσικό σήμα μπορεί να διαχωριστεί σε ένα φάσμα από συχνότητες. Το στατιστικό μέσο του σήματος όπως αναλύεται σχετικά με το συχνοτικό περιεχόμενό του, ονομάζεται φάσμα (spectrum) του σήματος. Όταν η ενέργεια (energy) του σήματος συγκεντρώνεται γύρω από ένα διάστημα πεπερασμένου χρόνου, τότε είναι δυνατός ο υπολογισμός της φασματικής πυκνότητας ενέργειας (Energy spectral density). Η ενέργεια του σήματος είναι:

$$E = \int_{-\infty}^{+\infty} |x(t)|^2 dx = \int_{-\infty}^{+\infty} |X(f)|^2 df$$

όπου $X(f)$ είναι ο Μ/Σ Fourier του σήματος $x(t)$ και $S_{xx} = |X(f)|^2$ η φασματική πυκνότητα ενέργειας, που είναι πάντα πραγματική και μη αρνητική, για πραγματικά σήματα. Συχνότερα, χρησιμοποιείται η φασματική πυκνότητα ισχύος ή αλλιώς Power spectral density που σχετίζεται με συνεχή σήματα κατά μήκος ολόκληρου του χρόνου. Περιγράφει τον τρόπο που η ισχύς του σήματος ή της χρονοσειράς κατανέμεται σχετικά με τη συχνότητα. Η μέση ισχύς ενός σήματος $x(t)$ δίνεται ως

$$P = \lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T |x(t)|^2 dt$$

και

$$S_{xx}(f) = \lim_{T \rightarrow \infty} E[|X_T(f)|^2]$$

όπου $E[\cdot]$ είναι η αναμενόμενη τιμή (expected value) μιας ποσότητας. Η φασματική πυκνότητα ισχύος μπορεί να χρησιμοποιηθεί ώστε να αναγνωριστούν εύρη συχνοτήτων που παρουσιάζουν ενδιαφέρον για να γίνει κατάλληλο φιλτράρισμα.

2.2.3 Ανάλυση σε ανεξάρτητες συνιστώσες

Ανάλυση σε ανεξάρτητες συνιστώσες (Independent Components Analysis - ICA) [13] είναι το όνομα που δόθηκε στις τεχνικές εύρεσης ενός πίνακα \mathbf{W} , και ενός διανύσματος w , τέτοιων ώστε τα στοιχεία, $\mathbf{u} = [u_1 \dots u_N]^T$, του γραμμικού μετ/σμού $\mathbf{u} = \mathbf{W}\mathbf{x} + w$ ενός τυχαίου διανύσματος $x = [x_1 \dots x_N]^T$, να είναι στατιστικά ανεξάρτητα. Σε αντίθεση με τεχνικές αποσυσχέτισης όπως η ανάλυση σε κύριες συνιστώσες, η ICA επιβάλλει το αρκετά αυστηρότερο κριτήριο ότι η συνάρτηση πυκνότητας πιθανότητας (probability density function - pdf) να μπορεί να γραφεί σε παράγοντες:

$$f_u(\mathbf{u}) = \prod_{i=1}^N f_{u_i}(u_i) \quad (2.11)$$

Για να επιτευχθεί το παραπάνω χρειάζεται η κοινή πληροφορία (mutual information) μεταξύ των u_i να μηδενίζεται, δηλαδή:

$$I(u_i, u_j) = 0, \forall ij \quad (2.12)$$

Η κοινή πληροφορία είναι μια μετρική που εξαρτάται από όλες τις στατιστικές υψηλής τάξης (higher order statistics) των u_i σε αντίθεση με την ανάλυση σε κύριες συνιστώσες, που βασίζονται μόνο σε στατιστικές μέχρι 2ης τάξης. Η ICA χρησιμοποιείται συνήθως για την επίλυση του προβλήματος άγνωστων πηγών (Blind source separation), δηλαδή στην ανάκτηση ανεξάρτητων πηγαίων σημάτων (π.χ. κάποια φωνή ή μουσική συγκεκριμένου οργάνου) από κάποιο σήμα που περιέχει μια μίξη πλήθους τέτοιων ανεξάρτητων σημάτων (π.χ. από μια καταγεγραμμένη συνομιλία πολλών ατόμων, ή από μια συναυλία). Ένας από του πιο δημοφιλείς αλγόριθμους για την επίτευξη της ανάλυσης σε ανεξάρτητες συνιστώσες βασίζεται στην μεγιστοποίηση πληροφορίας (information maximization - infomax) [5]. Η μοναδική υπόθεση είναι ότι οι άγνωστες ανεξάρτητες συνιστώσες, u_i , έχουν παρόμοια μορφή αθροιστικής συνάρτησης πιθανότητας (cumulative density function - cdf), και ότι γνωρίζουμε τη μορφή αυτή, έστω $F_u(u)$. Η ICA μπορεί τότε να εκτελεστεί μέσω της μεγιστοποίησης της εντροπίας $H(y)$ ενός μη γραμμικού διανύσματος μετασχηματισμού: $\mathbf{y} = F_u(\mathbf{u})$. Αυτό δίνει τη δυνατότητα κανόνων στοχαστικής κλίσης ανάβασης για την ρύθμιση του W και w :

$$\Delta W \propto [\mathbf{W}]^{-1} + \hat{y}x^T, \Delta w \propto \hat{y} \quad (2.13)$$

όπου

$$\hat{y}_i = \frac{\partial}{\partial y_i} \frac{\partial y_i}{\partial u_i} = \frac{\partial f_u(u_i)}{\partial F_u(u_i)}$$

Η χρήση της τεχνικής ICA για blind source separation προϋποθέτει: [34]

- οι πηγές να είναι ανεξάρτητες
- οι καθυστερήσεις του μέσου να είναι αμελητέες
- οι πηγές να έχουν συνάρτηση πυκνότητας πιθανότητας παρόμοια με τη παράγωγο της λογιστικής σιγμοειδούς
- ο αριθμός των ανεξαρτήτων πηγών να μπορεί να είναι το πολύ ίδιος με τον αριθμό των αισθητήρων καταγραφής

2.2.4 Ανάλυση σε κύριες συνιστώσες

Η ανάλυση σε κύριες συνιστώσες (Principal Component Analysis - PCA) είναι ένας μετασχηματισμός χώρου ο οποίος συχνά χρησιμοποιείται για να μειώσει τη διάσταση πολυδιάστατων δεδομένων με σκοπό την καλύτερη και γρηγορότερη ανάλυσή τους [44]. Περιλαμβάνει κυρίως το μηχανισμό αποσύνθεσης σε ιδιο-διανύσματα του πίνακα συνδιακύμανσης (covariance) γνωστό ως Αποσύνθεση Ιδιοτιμών (Singular Value Decomposition - SVD). Μέσω το μηχανισμού αυτού παράγονται οι κύριες συνιστώσες, δηλαδή τα κύρια ιδιοδιανύσματα που σχηματίζουν τους άξονες ενός χώρου, κάθετοι μεταξύ τους. Έστω \mathbf{X} ένας $n \times m$ πίνακας με

m τιμές ενός συνόλου δεδομένων n μεταβλητών, και έστω $\mu = [\mu_1, \mu_2 \dots \mu_n]^T$ ένα διάνυσμα με τη μέση τιμή των μεταβλητών αυτών βασισμένων στις m μετρήσεις. Έστω και ένας $n \times m$ πίνακας \mathbf{Y} που προκύπτει από τον πίνακα \mathbf{X} αφαιρώντας από τις μετρήσεις τις μέσες τιμές. Έστω ο πίνακας Σ ο πίνακα συνδιακύμανσης του \mathbf{U} , δηλαδή:

$$\Sigma = \frac{1}{m-1} \mathbf{Y} \mathbf{Y}^T \quad (2.14)$$

Με χρήση της μεθόδου αποσύνθεσης ιδιοτιμών στο συμμετρικό πίνακα Σ έχουμε

$$\Sigma = \mathbf{P} \mathbf{\Lambda} \mathbf{P}^T \quad (2.15)$$

όπου $\mathbf{\Lambda}$ ένας διαγώνιος πίνακας που περιέχει στην κύρια διαγώνιο τις ιδιοτιμές του πίνακα Σ και ο πίνακας \mathbf{P} είναι ο ορθογώνιος πίνακας που περιέχει τα ιδιοδιανύσματα σε κάθε στήλη. Ο μετ/σμός των κύριων συνιστωσών περιγράφεται τελικά από τον πίνακα \mathbf{U} :

$$\mathbf{U} = \mathbf{P}^T \mathbf{Y} \quad (2.16)$$

Για μείωση της διάστασης επιλέγεται ένας υποπίνακας του \mathbf{U} που περιέχει τις συνιστώσες που παίζουν τον κυριότερο ρόλο, δημιουργώντας έτσι μια νέα αναπαράσταση δεδομένων με χρήση μικρότερης διάστασης.

2.3 Μηχανική μάθηση

Η μηχανική μάθηση (machine learning) είναι πεδίο της επιστήμης των υπολογιστών που αναπτύχθηκε από τον κλάδο της αναγνώρισης προτύπων (Pattern Recognition) και της υπολογιστικής θεωρίας μάθησης [42]. Το πεδίο της αναγνώρισης προτύπων ασχολείται με την αυτόματη εύρεση κανονικοτήτων (πρότυπα) σε δεδομένα με χρήση υπολογιστικών αλγορίθμων. Η μηχανική μάθηση είναι άμεση συνέπεια της αναγνώρισης προτύπων και ασχολείται με την υλοποίηση τρόπων μάθησης υπολογιστικών συστημάτων. Σχετίζεται με την τεχνητή νοημοσύνη και έχει ως στόχο να δώσει στους υπολογιστές τη δυνατότητα να εκτελούν διεργασίες (tasks) χωρίς να έχουν προγραμματιστεί αυστηρώς, αλλά μαθαίνοντας από διάφορα δεδομένα. Στόχος είναι η κατασκευή αλγορίθμων μάθησης για τη δημιουργία μαθηματικών μοντέλων που να μπορούν να προβλέπουν ή να εξάγουν αποφάσεις. Υπάρχουν τρεις κύριες προσεγγίσεις μηχανικής μάθησης, ανάλογα με τον τρόπο κατασκευής του μοντέλου πρόβλεψης και τον τρόπο μάθησης:

- **Επιβλεπόμενη Μάθηση:** Προβλήματα που τα δεδομένα εκπαίδευσης αποτελούν παραδείγματα της εισόδου του μοντέλου μαζί με την αντίστοιχη επιθυμητή έξοδο, είναι γνωστά ως προβλήματα επιβλεπόμενης μάθησης (Supervised Learning). Σε αυτά περιλαμβάνονται πλήθος μαθηματικών μοντέλων όπως τα τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks), οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines), αλγόριθμοι εύρεσης των k κοντινότερων γειτόνων (k -nearest neighbors), δένδρα ταξινόμησης (classification trees) και πολλά άλλα.

- **Μη Επιβλεπόμενη Μάθηση:** Σε άλλες περιπτώσεις το σύνολο των δεδομένων εκπαίδευσης αποτελείται από μια σειρά διανυσμάτων εισόδου χωρίς τις αντίστοιχες εξόδους. Τα προβλήματα αυτά ονομάζονται προβλήματα μη επιβλεπόμενης μάθησης (Unsupervised Learning) και έχουν ως στόχο να ανακαλύψουν ομάδες από παρόμοια παραδείγματα ανάμεσα στα δεδομένα (ομαδοποίηση ή clustering), ή να καθορίσουν την κατανομή των δεδομένων ως προς το χώρο εισόδου (εκτίμηση πυκνότητας ή density estimation), ή να προβάλλουν τα δεδομένα από ένα πολυδιάστατο χώρο σε δύο ή τρεις διαστάσεις για το σκοπό της αναπαράστασης (visualization).
- **Ενισχυτική Μάθηση:** Η τεχνική της ενισχυτικής μάθησης (Reinforcement Learning) [59] ασχολείται με το πρόβλημα εύρεσης κατάλληλων δράσεων υπό συγκεκριμένες συνθήκες, με στόχο τη μεγιστοποίηση ενός βραβείου (reward). Σε αυτή την περίπτωση ο αλγόριθμος μάθησης δε γνωρίζει παραδείγματα εισόδου ή ιδανικές εξόδους, αλλά καλείται να τις ανακαλύψει μέσω δοκιμών και πειραματισμών (trial and error).

Στις πρώτες δύο κατηγορίες η μάθηση γίνεται μέσω του σταδίου της εκπαίδευσης, κατά το οποίο τα δεδομένα εισόδου (και εξόδου στην περίπτωση επιβλεπόμενης μάθησης) χρησιμοποιούνται για την εύρεση των παραμέτρων που χαρακτηρίζουν το μοντέλο. Η εκπαίδευση γίνεται με συγκεκριμένους αλγόριθμους, ανάλογα με το μοντέλο που έχει επιλεχθεί. Τα δεδομένα που χρησιμοποιούνται κατά την εκπαίδευση του μοντέλου ονομάζονται δεδομένα εκπαίδευσης (training data), ενώ αυτά που χρησιμοποιούνται για τη δοκιμή ορθότητας του μοντέλου ονομάζονται δεδομένα δοκιμής (testing data).


2.3.1 Παλινδρόμηση και Κατηγοριοποίηση

Οι αλγόριθμοι επιβλεπόμενης μάθησης μπορούν να χωριστούν σε άλλες δύο επιμέρους κατηγορίες ως προς τη μορφή του διανύσματος εξόδου του μοντέλου που δημιουργούν. Σε περιπτώσεις που ο στόχος είναι να ανατεθεί κάθε διάνυσμα εισόδου σε μία κατηγορία, από ένα πεπερασμένο αριθμό κατηγοριών, ονομάζονται αλγόριθμοι κατηγοριοποίησης ή ταξινόμησης (Classification). Αντίθετα, σε περιπτώσεις που η επιθυμητή έξοδος αποτελείται από μία ή περισσότερες συνεχείς μεταβλητές τότε ονομάζονται αλγόριθμοι παλινδρόμησης (Regression). Ένα παράδειγμα της διαφοροποίησης αυτής φαίνεται στο σχήμα 2.4.

2.3.2 Εξαγωγή Χαρακτηριστικών

Κατά την δημιουργία των μοντέλων μάθησης εμπεριέχεται ένα ενδιάμεσο στάδιο εξαγωγής προκύπτουσων τιμών από ένα αρχικό σετ δεδομένων, που ονομάζεται εξαγωγή χαρακτηριστικών (features extraction) [3]. Οι τιμές αυτές ονομάζονται χαρακτηριστικά και χρησιμοποιούνται ως είσοδοι στους διάφορους αλγόριθμους μηχανικής μάθησης. Γενικότερα, η μέθοδος εξαγωγής χαρακτηριστικών χρησιμοποιείται στη μηχανική μάθηση, στην αναγνώριση προτύπων και στην επεξεργασία εικόνων ή βίντεο. Η χρησιμότητά της έγκειται:

- στη μείωση της διαστατικότητας των δεδομένων εισόδου (dimensionality reduction),



Σχήμα 2.4: Παράδειγμα Classification και Regression.

- στην επιλογή των κατάλληλων για την επιθυμητή διεργασία χαρακτηριστικών, και
- στην καλύτερη αναπαράσταση των δεδομένων.

Με την επιλογή συγκεκριμένων χαρακτηριστικών από ένα πλήθος δυνατών συνδυασμών, επιτυγχάνεται η μείωση των τυχαίων μεταβλητών που βρίσκονται υπό εξέταση, και επομένως σημειώνεται μείωση του υπολογιστικού κόστους. Επιπλέον, η μέθοδος είναι αναγκαία για την επιλογή εκείνων των χαρακτηριστικών που είναι κατάλληλα και περιέχουν την πληροφορία που απαιτείται για μία συγκεκριμένη διεργασία (task). Τέλος, με την εξαγωγή χαρακτηριστικών δημιουργείται συνήθως ένας χώρος χαμηλότερων διαστάσεων από αυτόν του αρχικού σετ δεδομένων, και δίνεται έτσι η δυνατότητα οπτικής αναπαράστασης που βοηθά στη διασθητική αντίληψη του προβλήματος.

Η εξαγωγή χαρακτηριστικών χρησιμοποιείται ακόμα και για την καταπολέμηση του προβλήματος της υπερεκπαίδευσης (overfitting), δηλαδή της περίπτωσης που το μοντέλο μπορεί να αναγνωρίσει μονάχα τα δεδομένα που χρησιμοποιήθηκαν κατά την εκπαίδευση, με αποτέλεσμα να υπάρχει πρόβλημα γενίκευσης (generalization). Γενικά η εξαγωγή και επιλογή των σωστών χαρακτηριστικών αποτελεί ένα αρκετά σύνθετο πρόβλημα της μηχανικής μάθησης που εξαρτάται κυρίως από τη φύση των δεδομένων και του μοντέλου που χρησιμοποιείται.

2.3.3 Μοντέλο Μεταβλητών Κατάστασης

Πρόκειται για μια κατηγορία πιθανοτικών γραφικών μοντέλων [28] που περιγράφουν τη πιθανοτική εξάρτηση (probabilistic dependence) ανάμεσα σε κρυμμένες μεταβλητές κατάστασης και τις παρατηρούμενες μετρήσεις. Το μοντέλο των μεταβλητών κατάστασης (State Space Model) χρησιμοποιεί ένα διάνυσμα κρυφών μεταβλητών οι οποίες μεταβάλλονται μέσω των γραμμικών εξισώσεων που φαίνονται στην εξίσωση 2.17. Τα μοντέλα αυτά είναι παρόμοια και με τα Κρυφά Μοντέλα Markov (Hidden Markov Models) [17] αφού μοντελοποιούν κάποια διακριτή χρονο-σειρά ως αλυσίδα Markov με υποτιθέμενη σταθερή κατανομή, με τη διαφορά ότι στα μοντέλα μεταβλητών καταστάσεων οι μεταβλητές είναι συνεχόμενες (continuous).

Είναι:

$$x_{k+1} = Ax_k + Bu_k + Dw_k \quad (2.17)$$


$$y_k = Cx_k + w_k$$

όπου $x_k \in \mathbb{R}^n$ είναι το διάνυσμα καταστάσεων σε χρόνο kT , με n την τάξη του συστήματος και T την περίοδο δειγματοληψίας, $u_k \in \mathbb{R}^m$ το διάνυσμα εξόδου, w_k λευκός γκαουσιανός θόρυβος και $y_k \in \mathbb{R}^v$ το διάνυσμα εξόδου. Οι πίνακες A, B, C, D καθορίζουν τη σχέση μεταξύ των μεταβλητών.

Η εκτίμηση των στοιχείων των πινάκων αυτών αποτελεί αντικείμενο της μηχανικής μάθησης. Τα μοντέλα που δημιουργούνται μπορούν να χρησιμοποιηθούν για εκτίμηση της εξόδου βάσει συγκεκριμένων εισόδων. Χρησιμοποιούνται συχνά για εφαρμογές της υπολογιστικής νευροεπιστήμης (computational neuroscience) για την ανάπτυξη μοντέλων που να καθορίζουν τα δυναμικά χαρακτηριστικά σε νευρωνικές και συμπεριφορικές αποκρίσεις κατά τη διάρκεια νευρο-φυσιολογικών πειραμάτων. Κύριο ρόλο στους επαναληπτικούς αλγόριθμους εκτίμησης των παραμέτρων παίζει η επιλογή της τάξης του συστήματος.


2.3.4 Τεχνητά Νευρωνικά Δίκτυα

Τα τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks) είναι μια σχετικά καινούρια μέθοδος μηχανικής μάθησης [36], που αναπτύχθηκε τις τελευταίες δεκαετίες και βασίζεται στην ανάπτυξη μαθηματικών μοντέλων εμπνευσμένων από βιολογικούς νευρώνες. Ένας νευρώνας είναι μια απλή υπολογιστική μονάδα που μπορεί να δημιουργήσει συνδέσεις μεταξύ άλλων νευρώνων και να σχηματίσει ένα νευρωνικό δίκτυο. Το μοντέλο ενός απλού τεχνητού νευρώνα φαίνεται παρακάτω στο σχήμα 2.5.



Σχήμα 2.5: Ένας τεχνητός νευρώνας. Πηγή [36].

Είναι $x_i, i = 1, 2, \dots, n$ οι εισοδοί του νευρώνα, w_i τα συναπτικά βάρη (weights), w_0 το κατώφλι ενεργοποίησης ή πόλωση, $u = \sum_{i=1}^n w_i x_i + w_0$ η διέγερση, f μια συνάρτηση ενεργοποίησης και y η έξοδος του νευρώνα. Γενικά, μπορούν να χρησιμοποιηθούν αρκετές συναρτήσεις ενεργοποίησης όπως η σιγμοειδής ή η συνάρτηση βήματος. Το μοντέλο των νευρωνικών δικτύων αποτελείται από διαδοχικά επίπεδα νευρώνων (perceptrons) συνδεδεμένων



Σχήμα 2.6: Δομή ενός τεχνητού νευρωνικού δικτύου.

μεταξύ τους όπως στο σχήμα 2.6, σχηματίζοντας έτσι ένα πολυστρωματικό επίπεδο νευρώνων (Multilayer Perceptron MLP).


Το δίκτυο μπορεί να αποτελείται από διάφορους νευρώνες, ή επίπεδα. Αυτά καθορίζουν την αρχιτεκτονική του δικτύου και καθορίζουν τη συμπεριφορά του τελικού μοντέλου. Τα δίκτυα μπορεί να αποτελούνται από μικρό αριθμό νευρώνων (ρηχά) ή περισσότερων (βαθιά ή πολύ βαθιά δίκτυα), και όσο αυξάνονται οι νευρώνες, τόσο αυξάνεται και η πολυπλοκότητα και οι παράμετροι του δικτύου [22]. Η εκπαίδευση πραγματοποιείται την εύρεση των παραμέτρων του δικτύου, δηλαδή των τιμών των πολώσεων και των βαρών, και μπορεί να γίνει με διάφορους τρόπους όπως π.χ. back propagation. Γενικά, ο ιδανικός αριθμός νευρώνων, καθώς και η επιλογή αλγορίθμου εκπαίδευσης, η επιλογή συνάρτησης ενεργοποίησης και η δομή ενός δικτύου μπορεί να βρεθεί μέσω ευριστικών (heuristic) τρόπων.

2.3.5 Μηχανές Διανυσμάτων Υποστήριξης

Οι Μηχανές Διανυσμάτων Υποστήριξης - ΜΔΥ ή αλλιώς Support Vector Machines - SVM είναι μία ακόμα μέθοδος επιβλεπόμενης μάθησης. Κύριο χαρακτηριστικό των ΜΔΥ είναι ότι ο καθορισμός των παραμέτρων του μοντέλου αντιστοιχεί σε κυρτό πρόβλημα βελτιστοποίησης, και επομένως κάθε τοπική λύση είναι και γενικό βέλτιστο [8]. Οι ΜΔΥ μπορούν να χρησιμοποιηθούν σε περιπτώσεις κατηγοριοποίησης και παλινδρόμησης. Στις ΜΔΥ τα δεδομένα αναπαρίστανται σε χώρο τέτοιο ώστε να διαχωρίζονται σε κατηγορίες έχοντας μεταξύ τους το μέγιστο δυνατό περιθώριο (margin). Χρησιμοποιούνται για κατηγοριοποίηση γραμμικά διαχωρίσιμων δεδομένων, αν και μπορούν να χρησιμοποιηθούν και σε μη γραμμική κατηγοριοποίηση χρησιμοποιώντας κατάλληλους πυρήνες (όπως π.χ. rbf).

Οι πυρήνες (kernels) είναι ουσιαστικά συναρτήσεις ομοιότητας ζευγαριών δεδομένων οι οποίες χρησιμοποιούνται σε τεχνικές μηχανικής μάθησης. Γενικά, στους περισσότερους αλγόριθμους μάθησης τα δεδομένα χρησιμοποιούνται μέσω των διανυσμάτων των χαρακτηριστικών τους για τη λήψη της απόφασης ή την πρόβλεψη κ.λ.π. Στις περιπτώσεις που χρησιμοποιο-

ύνται πυρήνες, όπως στις ΜΔΥ, χρειάζεται μόνο ο πυρήνας τον οποίο ορίζει ο χρήστης. Δίνουν τη δυνατότητα αναπαράστασης των δεδομένων σε χώρο χαρακτηριστικών υψηλών διαστάσεων χωρίς καν να χρειάζεται ο υπολογισμός των συντεταγμένων των δεδομένων στο χώρο αυτό. Αυτή η δυνατότητα είναι υπολογιστικά φθηνότερη από τον υπολογισμό των χαρακτηριστικών, και γι' αυτό υπάρχουν περιπτώσεις που προτιμάται. Για την κατανόηση της λειτουργίας της μεθόδου, ακολουθεί ένα παράδειγμα γραμμικού διαχωρισμού διδιάστατων δεδομένων.



Σχήμα 2.7: Παράδειγμα ενός υπερ-επιπέδου που μεγιστοποιεί το περιθώριο για δεδομένα από δύο οδιαφορετικές κλάσεις. Τα δείγματα πάνω στο περιθώριο ονομάζονται διανύσματα υποστήριξης. Πηγή [14]

Έστω ότι δίνονται δεδομένα δοκιμής $(\vec{x}_1, y_1), \dots, (\vec{x}_n, y_n)$ όπου y_i είναι είτε 1 είτε -1 και αντιστοιχίζεται σε δύο διαφορετικές κατηγορίες που ανήκει το \vec{x}_i . Κάθε διάνυσμα \vec{x}_i είναι p διαστάσεων. Στόχος είναι η εύρεση του υπερ-επιπέδου με το μεγαλύτερο δυνατό περιθώριο που διαχωρίζει τις ομάδες των σημείων που ανήκουν σε $y_i = 1$ από αυτές που ανήκουν σε $y_i = -1$ και το οποίο είναι τέτοιο ώστε η απόσταση ανάμεσα στο υπερ-επίπεδο και το κοντινότερο σημείο \vec{x}_i από οποιαδήποτε ομάδα να μεγιστοποιείται. Ένα υπερ-επίπεδο μπορεί να γραφεί ως το σύνολο των σημείων \vec{x}_i που ικανοποιούν:

$$\vec{w} \cdot \vec{x} - b = 0 \quad (2.18)$$

όπου \vec{w} είναι το κανονικό διάνυσμα του υπερ-επιπέδου. Η παράμετρος $\frac{b}{\|\vec{w}\|}$ ορίζει το offset του υπερ-επιπέδου από την αρχή των αξόνων καταμήκος του διανύσματος \vec{w} . Τελικά, όπως φαίνεται και στο σχήμα 2.7 η απόσταση των δύο υπερ-επιπέδων που πρέπει να μεγιστοποιηθεί είναι $\frac{2}{\|\vec{w}\|}$. Επομένως, για τη μεγιστοποίηση της απόστασης αρκεί να ελαχιστοποιηθεί το $\|\vec{w}\|$.

Γενικά, οι ΜΔΥ είναι κατηγοριοποιητές δύο κλάσεων και αρχικά χρησιμοποιήθηκαν για το

γραμμικό διαχωρισμό δεδομένων. Όμως, πλέον, υπάρχουν μέθοδοι για τη χρήση των ΜΔΥ σε προβλήματα με περισσότερες των δύο κλάσεων, και με τη χρήση πυρήνων επιτρέπεται ο διαχωρισμός και μη γραμμικών δεδομένων, κάτι που καθιστά τις ΜΔΥ μια αρκετά καλή επιλογή μοντέλου κατηγοριοποίησης που μπορεί να εφαρμοστεί σε μεγάλο πλήθος εφαρμογών.

2.4 Μετρικές αξιολόγησης

Για την εκτίμηση των αποτελεσμάτων της εργασίας χρησιμοποιούνται κάποιες μετρικές αξιολόγησης όπως ο συντελεστής συσχέτισης (Correlation Coefficient - CC) ή η ρίζα μέσου τετραγωνικού σφάλματος (Root-Mean Squared Error - RMSE). Για την αξιολόγηση των ταξινομητών χρησιμοποιούνται μετρικές γνωστές ως Receiver Operating Characteristics - ROC όπως η ειδικευση (specificity), η ευαισθησια (sensitivity) και η ακρίβεια (accuracy), οι οποίες ορίζονται παρακάτω.

$$CC_i = \frac{\sum_{k=1}^n (P_i(k) - \bar{P}_i)(\hat{P}_i(k) - \bar{\hat{P}}_i)}{\sqrt{\sum_{k=1}^n (P_i(k) - \bar{P}_i)^2 \sum_{k=1}^n (\hat{P}_i(k) - \bar{\hat{P}}_i)^2}} \quad (2.19)$$

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{k=1}^n (P_i(k) - \hat{P}_i(k))^2} \quad (2.20)$$

όπου P_i και $\hat{P}_i, i \in W$ το κανονικό και το επιθυμητό διάνυσμα εξόδου αντίστοιχα, με W το χώρο που ανήκουν τα διανύσματα εξόδου ανάλογα με την εφαρμογή (αποκωδικοποίηση ή ταξινόμηση). Αντίστοιχα, είναι \bar{P} η μέση τιμή του P υπολογισμένη από τα n δεδομένα. Για τη δυαδική κατηγοριοποίηση ισχύει: TP = True Positive, TN = True Negative, FP = False Positive, FN = False Negative, όπου TP είναι τα δεδομένα που χαρακτηρίζονται σωστά ως 1, TN τα δεδομένα που χαρακτηρίζονται σωστά ως 0, FP τα δεδομένα που χαρακτηρίζονται εσφαλμένα ως 1 και FN τα δεδομένα που χαρακτηρίζονται εσφαλμένα ως 0.

$$Sensitivity = \frac{TP}{TP + FN} \quad (2.21)$$

$$Specificity = \frac{TN}{TN + FP} \quad (2.22)$$

$$Accuracy = \frac{TN + TP}{TN + TP + FN + FP} \quad (2.23)$$

Κεφάλαιο 3

Καταγραφή πειραματικών δεδομένων

3.1 Συσκευές καταγραφής



Σχήμα 3.1: Η συσκευή καταγραφής των ΗΕΓ σημάτων Biosemi ActiveTwo.

Η ανάπτυξη του μοντέλου διασύνδεσης εγκεφάλου-υπολογιστή BCI βασίστηκε σε Ηλεκτροεγκεφαλογραφικά δεδομένα που καταγράφηκαν από πραγματικούς χρήστες. Σημειώνεται ότι οι πειραματικές μετρήσεις έγιναν σε εργαστήριο που δεν είναι ηλεκτρικά ή μαγνητικά μονωμένο, με αποτέλεσμα να αναμένεται μεγάλο ποσοστό θορυβωδών παρεμβολών στα δεδομένα. Κάτι τέτοιο όμως μπορεί εύκολα να αποφευχθεί με κατάλληλη επεξεργασία των σημάτων. Για την καταγραφή των ΗΕΓ σημάτων χρησιμοποιήθηκε ο ηλεκτροεγκεφαλόγράφος



Σχήμα 3.2: Τα ηλεκτρόδια που χρησιμοποιούνται για την καταγραφή των σημάτων.

ActiveTwo (σχήμα 3.1) της Ολλανδικής εταιρίας Biosemi με ενεργά ηλεκτρόδια (active electrodes) (σχήμα 3.2). Στη συσκευή χρησιμοποιήθηκαν 32+2 ηλεκτρόδια, 32 για καταγραφή, 1 για γείωση και άλλο 1 ως ηλεκτρόδιο κοινού σήματος. Τα σήματα ψηφιοποιούνται μέσα στη συσκευή με συχνότητα περίπου 16kHz. Η τοποθέτηση των 32 ηλεκτροδίων γίνεται σε ειδικό σκουφάκι και με βάση το σύστημα 10-20 που παρουσιάζεται στο σχήμα 4.3. Χρησιμοποιήθηκε, επιπλέον, η συσκευή Polhemus Liberty (σχήμα 3.3) για την καταγραφή των συντεταγμένων του χεριού και του ώμου του χρήστη. Πρόκειται για έναν magnetic tracker που καταγράφει τη σχετική θέση και προσανατολισμό μεταξύ αισθητήρων. Η συσκευή χρησιμοποιήθηκε κατά τη φάση της εκπαίδευσης του αποκωδικοποιητή για καταγραφή της επιθυμητής τροχιάς που χρησιμοποιήθηκε ως επιθυμητή έξοδος. Οι μετρήσεις έγιναν σε καρτεσιανό σύστημα συντεταγμένων και με συχνότητα δειγματοληψίας 240 Hz. Τα δεδομένα που προέκυψαν επεξεργάστηκαν καταλλήλως, και χρησιμοποιήθηκαν για την εύρεση του επιθυμητού διανύσματος εξόδου (σχήμα 5.2) του αποκωδικοποιητή και για τον καθορισμό των περιοχών ακινησίας (σχήμα 5.8).

Κατά τη διάρκεια των πειραμάτων χρησιμοποιήθηκαν, ακόμα, κάποια μαλακά ρομποτικά χέρια όπως αυτό που παρουσιάζεται στο σχήμα 3.4. Τα μαλακά χέρια απέχουν πολύ από την κλασική προσέγγιση σχεδιασμού ρομποτικών χεριών και δίνουν τη δυνατότητα μεγαλύτερης ασφάλειας και ευρωστίας (robustness) κατά το άδραγμα. Το ανθρωπομορφικό και υποενεργό ρομποτικό χέρι που χρησιμοποιήθηκε κατά τα πειράματα χρησιμοποιεί έναν κινητήρα [29].

Στόχος είναι το σύστημα να μπορεί να λειτουργεί με προσάρτηση του χεριού σε έναν ρομποτικό βραχίονα όπως τον Mitsubishi PA-10 που υπάρχει στο εργαστήριο.



Σχήμα 3.3: Η συσκευή καταγραφής θέσης και προσανατολισμού Polhemus Liberty

3.2 Πειραματική διάταξη

Η καταγραφή των δεδομένων έγινε από έξι διαφορετικούς χρήστες (subjects). Σε όλες τις περιπτώσεις χρησιμοποιήθηκαν ειδικά προγράμματα σε γλώσσες C++ και python για την καταγραφή. Ο χειρισμός του βραχίονα και του χεριού γίνεται μέσα από το πρόγραμμα ROS σε περιβάλλον Linux. Κατά τη διάρκεια των πειραμάτων έγιναν αρκετές δοκιμές (trials) που δε ξεπερνούσαν σε χρόνο τα 2 λεπτά. Ανάμεσα στα trials οι χρήστες ξεκουράζονταν για λίγα δευτερόλεπτα, προτού συνεχιστεί η διαδικασία.

Στα πειράματα αποκωδικοποίησης της κίνησης των ματιών, τα οποία θα είναι γνωστά από το εξής ως πειράματα τύπου 1, ο χρήστης καλείται να παρακολουθήσει με τα μάτια την τροχιά ενός αντικειμένου ή του δικού του χεριού. Στο χρήστη τοποθετούνται τα ηλεκτρόδια τα οποία συνδέονται στον εγκεφαλογράφο για καταγραφή. Στο αντικείμενο τοποθετείται ο ένας αισθητήρας καταγραφής θέσης της συσκευής Liberty, ενώ ο δεύτερος αισθητήρας τοποθετείται στον ώμο του χρήστη και θεωρείται ως θέση αναφοράς. Η τροχιά κίνησης που ακολουθεί το αντικείμενο είναι τέτοια ώστε να έχει περιόδους που το αντικείμενο σταματά να κινείται. Κατά τα πειράματα οι χρήστες συμβουλεύονται να κρατούν όσο το δυνατόν σταθερότερο το κεφάλι τους και να μην κάνουν απότομες κινήσεις που μπορούν να επηρεάζουν τις μετρήσεις. Μέσα από τα προγράμματα εξασφαλίζεται η αποθήκευση των χρονικών στιγμών καταγραφής των δεδομένων από κάθε συσκευή, με σκοπό το συγχρονισμό τους.

Στα πειράματα εύρεσης των σημάτων κατά το κλείσιμο των ματιών (πειράματα τύπου 2) ο χρήστης καλείται να κλείσει τα βλέφαρα των ματιών του κατά το άκουσμα ενός ήχου. Ο ήχος αυτός επαναλαμβάνεται τυχαία ανά ταχτά χρονικά διαστήματα εύρους 3 ως 6 δευτερολέπτων.




Σχήμα 3.4: Το ρομποτικό χέρι που χρησιμοποιήθηκε κατά τα πειράματα

Για την καταγραφή χρησιμοποιήθηκαν 3 διαφορετικοί χρήστες και συγκεντρώθηκαν συνολικά 220 δοκιμές (trials). Κατά τα πειράματα οι χρήστες έχουν τη δυνατότητα να κουνούν το κεφάλι τους ή τα μάτια τους, ή ακόμα και να τα ανοιγοκλείνουν στιγμιαία. Το βλεφάρισμα δεν επηρεάζει τις πειραματικές μετρήσεις, και αντιθέτως προτείνεται ώστε να εξασφαλίζεται η συχνή ύγρανση των ματιών και να αποφεύγεται η κόπωση.

Κεφάλαιο 4

ΗΕΓ Σήματα: Ανάλυση και επεξεργασία


Η Ηλεκτροεγκεφαλογραφία - ΗΕΓ (Electroencephalography - EEG) είναι μια σύγχρονη μέθοδος καταγραφής της δραστηριότητας του κεντρικού νευρικού συστήματος. Για την καταγραφή χρησιμοποιούνται συνήθως συστήματα όπως αυτό που φαίνεται στην εικόνα 4.1. Τα σήματα που προκύπτουν ονομάζονται ηλεκτροεγκεφαλογραφικά - ΗΕΓ σήματα. Παρακάτω γίνεται μια σύντομη αναφορά για τον τρόπο προέλευσης και καταγραφής των σημάτων αυτών.



Σχήμα 4.1: Η μέθοδος της ηλεκτροεγκεφαλογραφίας - ΗΕΓ. Πηγή: University of Zurich, Neurofeedback lab.

4.1 Εισαγωγή


Η εγκεφαλική δραστηριότητα σχετίζεται με τα συναπτικά ρεύματα, δηλαδή τα ρεύματα μεταξύ των συνάψεων των νευρώνων. Νευρώνες είναι τα κύτταρα του νευρικού συστήματος με τη δομή που φαίνεται στο σχήμα 4.2. Ασθενή δυναμικά μερικών δεκάδων μικροβολτ (μV) σχηματίζονται στην κυτταρική μεμβράνη των νευρώνων, τα οποία μεταβάλλονται κατά τις κυτταρικές λειτουργίες [49]. Αυτά τα δυναμικά ονομάζονται συνηθώς μετασυναπτικά δυναμικά (post synaptic potentials). Η πληροφορία που μεταφέρεται από ένα νευρώνα ονομάζεται δυναμικό δράσης (Action Potential) και προέρχεται από την ανταλλαγή ιόντων κατά μήκος της νευρωνικής μεμβράνης. Τα διαμεμβρανικά ρεύματα που ρέουν κατά τη διέγερση των συνάψεων των νευρώνων που ανήκουν στον εγκεφαλικό φλοιό (cerebral cortex) παράγουν ένα ηλεκτρικό πεδίο πάνω στο κρανίο (scalp) που μπορεί να καταγραφεί μέσω του ηλεκτροεγκεφαλογραφήματος.



Σχήμα 4.2: Η δομή ενός νευρώνα σύμφωνα με το μοντέλο των Attwood, MacKay. Πηγή: [49].

Η ηλεκτροεγκεφαλογραφία είναι μία μη επεμβατική μέθοδος, αφού τα σήματα καταγράφονται στην εξωτερική επιφάνεια του κρανίου. Υπάρχουν, όμως, και επεμβατικές μέθοδοι κατά τις οποίες τοποθετούνται ηλεκτρόδια απευθείας στον εγκέφαλο με χειρουργική επέμβαση. Τέτοιες μέθοδοι είναι αρκετά πρωτοπόρες και δίνουν τη δυνατότητα καταγραφής των σημάτων χωρίς την εισαγωγή επιπλέον θορύβου, αλλά δε χρησιμοποιούνται συχνά λόγω της δυσκολίας εφαρμογής τους. Για την ηλεκτροεγκεφαλογραφία χρησιμοποιείται συνήθως ένα σκουφάκι (cap) με ειδικές υποδοχές όπως φαίνεται στο σχήμα 4.1. Ο αριθμός των ηλεκτροδίων που τοποθετούνται κυμαίνεται από 16, 32, 64 έως και 128. Για την τοποθέτηση των ηλεκτροδίων χρησιμοποιείται ειδικό αγωγίμο τζελ. Τα ηλεκτρόδια συνδέονται έπειτα με μια συσκευή που αναλαμβάνει την καταγραφή των σημάτων και ονομάζεται εγκεφαλογράφος. Κάθε ένα ηλεκτρόδιο θεωρείται ως κανάλι εισόδου στα δεδομένα μετρήσεων. Οι θέσεις των ηλεκτροδίων στο διεθνές σύστημα 10-20, μαζί με τα ονόματα των καναλιών και την αρίθμησή τους, φαίνονται στο σχήμα 4.3.

παράδειγμα η κυματομορφή Φ (φ) που σχετίζεται με το κλείσιμο των βλεφάρων [55].



Σχήμα 4.4: Οι άλφα, βήτα, θήτα και δέλτα κυματομορφές. Πηγή: [20].

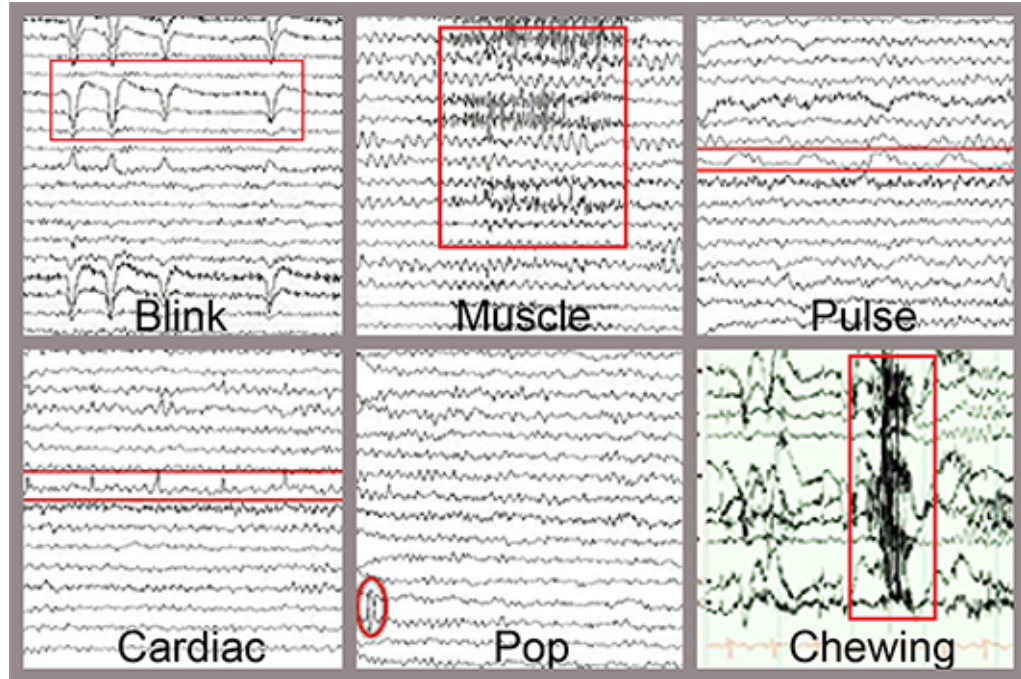
Εκτός από το διαχωρισμό που γίνεται με βάση το εύρος συχνοτήτων των κυματομορφών, υπάρχουν συγκεκριμένα δυναμικά που εμφανίζονται ως αποκρίσεις σε συγκεκριμένα εσωτερικά ή εξωτερικά ερεθίσματα/διεγέρσεις. Μια γνωστή κατηγορία είναι αυτή των δυναμικών συμβάντος (Event Related Potential) που εμφανίζονται ως αποτέλεσμα κάποιων διεγέρσεων και μπορούν επιπλέον να διαχωριστούν σε προκλητά ή εκπεμπόμενα (evoked and emitted potentials), ανάλογα με την προέλευση της διέγερσης. Σε αυτή την κατηγορία εμπίπτουν δυναμικά όπως:

- τα P300 evoked potentials τα οποία αποτελούνται από μια θετική κορυφή (peak) παραγόμενη στα 300 ms από τη διέγερση,
- τα Steady State Visually Evoked Potentials (SSVEP), δηλαδή τα οπτικά παραγόμενα δυναμικά σταθερής κατάστασης, τα οποία σχετίζονται με την οπτική διέγερση του αμφιβληστροειδούς χιτώνα (retina),
- τα Slow Cortical Potentials (SCP) που εμπεριέχουν τους ρυθμούς (rhythms) άλφα, βήτα, μι, και γάμμα, και σχετίζονται με την αλλαγή στην κατάσταση συναίσθησης, και
- οι Sensorimotor Rhythms (SMR) που σχετίζονται με την αισθητήρια περιοχή του εγκεφαλικού φλοιού, και την επεξεργασία αισθητήριων πληροφοριών για το σχεδιασμό, έλεγχο και την εκτέλεση κινήσεων [1].

4.1.2 Μη χρήσιμα ΗΕΓ σήματα (Artifacts)

Εκτός από τα δυναμικά που αναφέρθηκαν παραπάνω και χρησιμοποιούνται σε Διεπαφές εγκεφάλου-υπολογιστή, στις ίδιες συχνότητες υπάρχουν και άλλα σήματα λόγω κινήσεων των μυών του κεφαλιού, των ματιών κ.ά. που πολλές φορές αναμιγνύονται με τα σήματα αυτά. Αυτά

τα σήματα ονομάζονται artifacts ή artefacts και θεωρούνται από τους περισσότερους ως μη χρήσιμη πληροφορία που πρέπει να ανιχνεύεται και να αφαιρείται. Μπορούν να χωριστούν σε βιολογικά (προερχόμενα από άλλες πηγές πέρα του εγκεφάλου) ή μη βιολογικά (προερχόμενα από ηλεκτρικά φαινόμενα σε συσκευές καταγραφής). Τα πιο γνωστά τέτοια σήματα είναι [10]:



Σχήμα 4.5: Διάφορα Artifacts που εμπεριέχονται στα ΗΕΓ σήματα . Πηγή: [10].


- σήματα που σχετίζονται με την κίνηση των ματιών (ocular artifacts), είτε λόγω αργών, λείων κινήσεων, είτε λόγω απότομων και γρήγορων κινήσεων (saccadic eye movement), είτε λόγω πεταρίσματος (eye flutter) ή βλεφαρίσματος (blinking),
- σήματα που σχετίζονται με τις κινήσεις των μυών στο κεφάλι, κοντάστο μέτωπο ή το λαιμό (muscle artifacts)
- σήματα που σχετίζονται με την κίνηση της ανθρώπινης γλώσσας, την ομιλία ή την κατάπωση και κίνηση του σαγονιού,
- καρδιακά σήματα (cardiac artifacts) που σχετίζονται με τους κτύπους της καρδιάς και σήματα παλμού (pulse artifacts) που προκύπτουν στην περίπτωση που ένα ηλεκτρόδιο τοποθετείται πάνω από κάποιο αγγείο,
- σήματα που είναι μη βιολογικά ή μηχανικά και σχετίζονται με τη θέση των ηλεκτροδίων, απότομες αποφορτίσεις (electrode pop) ή ανεπιθύμητες κινήσεις πάνω στην κεφαλή.

Υπάρχουν, επιπλέον, ανεπιθύμητα σήματα που μπορεί να προκύπτουν από εξωτερικές πηγές, όπως το ηλεκτρικό πεδίο διαφόρων συσκευών γύρω από το χώρο των πειραμάτων (μετασηματοποιητές, υπολογιστές ή συσκευές τηλεφωνίας) ή το δίκτυο τροφοδοσίας (line noise) και

μαγνητικές παρεμβολές. Αυτός είναι ο λόγος που πολλές φορές τα πειράματα των μετρήσεων προτείνεται να γίνονται σε ηλεκτρικά και μαγνητικά απομονωμένα εργαστήρια, και ένας από τους λόγους που πολλές συσκευές καταγραφής τέτοιων σημάτων λειτουργούν με μπαταρία και όχι με απευθείας σύνδεση στο δίκτυο τροφοδοσίας.

Από αυτά, μεγάλο ενδιαφέρον παρουσιάζουν τα σήματα που οφείλονται στις κινήσεις των ματιών. Τέτοια σήματα μπορούν να καταγραφούν και από την τεχνική της Ηλεκτροοπτομετρίας (EOG) με ηλεκτρόδια τοποθετημένα απευθείας στην περιοχή των ματιών. Στην ΗΕΓ αυτά τα σήματα παρουσιάζονται κυρίως στο μετωπιαίο λοβό (frontal lobe), που βρίσκεται στο μπροστινό μέρος του εγκεφάλου. Η παρούσα εργασία προτείνει την εκμετάλλευση τέτοιων δυναμικών για τη δημιουργία μιας διεπαφής BCI. Βασίζεται σε προηγούμενη εργασία [35] αφού στηρίζεται στην τρισδιάστατη αποκωδικοποίηση της κίνησης των ματιών.

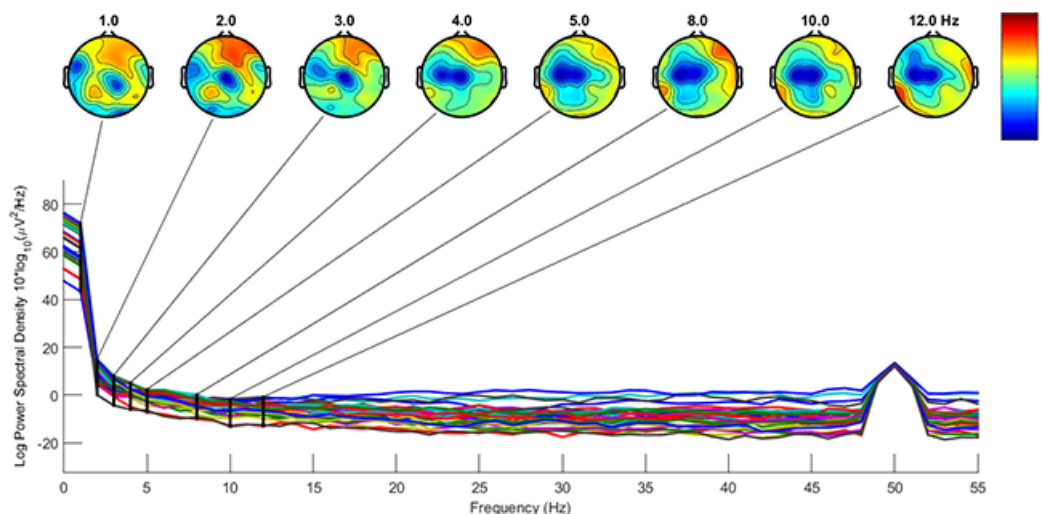
4.2 Επεξεργασία ΗΕΓ σημάτων



Σχήμα 4.6: Οι θέσεις, τα ονόματα και η αντιστοίχιση με την αρίθμηση των 32 ηλεκτροδίων.

Στην παρούσα υποενότητα παρουσιάζονται τρόποι επεξεργασίας των ΗΕΓ σημάτων για την χρήση τους σε αποκωδικοποίηση κίνησης και κατηγοριοποίηση. Για την επεξεργασία των σημάτων χρησιμοποιήθηκε το περιβάλλον MATLAB™. Για διευκόλυνση της αναπαράστασης των δεδομένων χρησιμοποιήθηκε επιπλέον το open source toolbox του MATLAB™, EEGLAB [15], που αναπτύχθηκε από τον Makeig et al το 2004. Χρησιμοποιείται ευρέως στην επεξεργασία τέτοιου είδους δεδομένων και δίνει τη δυνατότητα εύκολης αναπαράστασης των μετρήσεων, όπως π.χ. με την τοπογραφική αναπαράσταση της φασματικής πυκνότητας ισχύος (power spectral density - psd) σύμφωνα με τις θέσεις των ηλεκτροδίων (σχήμα 4.7). Στο σχήμα παρατηρούμε ότι τα κανάλια που παρουσιάζουν ενδιαφέρον (δηλαδή αυτά που ανήκουν στο μπροστινό μέρος του εγκεφάλου), είναι τα κανάλια [1, 2, 3, 4, 27, 28, 29, 30] λόγω αρίθμησης του συστήματος. Παρακάτω γίνεται αναφορά σε σήματα που προέρχονται

από πειραματικές μετρήσεις. Περισσότερες πληροφορίες σχετικά με τα πειράματα δίνονται στο κεφάλαιο 3.




Σχήμα 4.7: Χάρτες φασματικής πυκνότητας ισχύος για συγκεκριμένες συχνότητες από το EEGLAB για το πείραμα 1.

Στο σχήμα 4.7 φαίνεται η φασματική πυκνότητα ισχύος των καναλιών για ανεπεξέργαστα δεδομένα. Πρόκειται για πείραμα τύπου 1 (συμβατική ονοματοδοσία stop1) κατά το οποίο ο χρήστης καλείται να παρακολουθεί με τα μάτια του την φυσική κίνηση του χεριού του, και έχει ως στόχο την αποκωδικοποίηση της κίνησης. Φαίνονται, επιπλέον, οι φασματικοί χάρτες (spectral maps) στις συγκεκριμένες συχνότητες, σύμφωνα με τις θέσεις των ηλεκτροδίων (σχήμα 4.6). Από αυτούς του χάρτες μπορεί κάποιος να διακρίνει σε ποια σημεία του κεφαλιού συσσωρεύεται η ισχύς. Σύμφωνα με τη βιβλιογραφία ([24] και σχήμα 4.9) φαίνεται ότι η δραστηριότητα που σχετίζεται με την κίνηση των ματιών υπάρχει σε χαμηλές συχνότητες με εύρος 2-3 Hz. Επιπλέον, σε αυτούς τους χάρτες διακρίνονται και διαφορετικά artifacts που μοιάζουν με muscle artifacts (σύγκριση με σχήμα 4.9), και πως στη συχνότητα των 50 Hz διακρίνεται μια κορυφή (spike) λόγω του θορύβου τροφοδοσίας γραμμής.

Στο σχήμα 4.8 φαίνεται η φασματική πυκνότητα ισχύος για πείραμα τύπου 2 (συμβατική ονοματοδοσία volblink1) κατά το οποίο ο χρήστης καλείται να κλείσει για ένα σύντομο χρονικό διάστημα τα μάτια του σε συγκεκριμένους χρόνους. Από το σχήμα μπορεί κάποιος να διακρίνει ότι η δραστηριότητα που σχετίζεται με το κλείσιμο των ματιών κυμαίνεται σε εύρος 2-8Hz. Όπως και στην προηγούμενη περίπτωση διακρίνεται ο θόρυβος γραμμής τροφοδοσίας και επιπλέον artifacts που προέρχονται από άλλες πηγές και είναι ανεπιθύμητα.

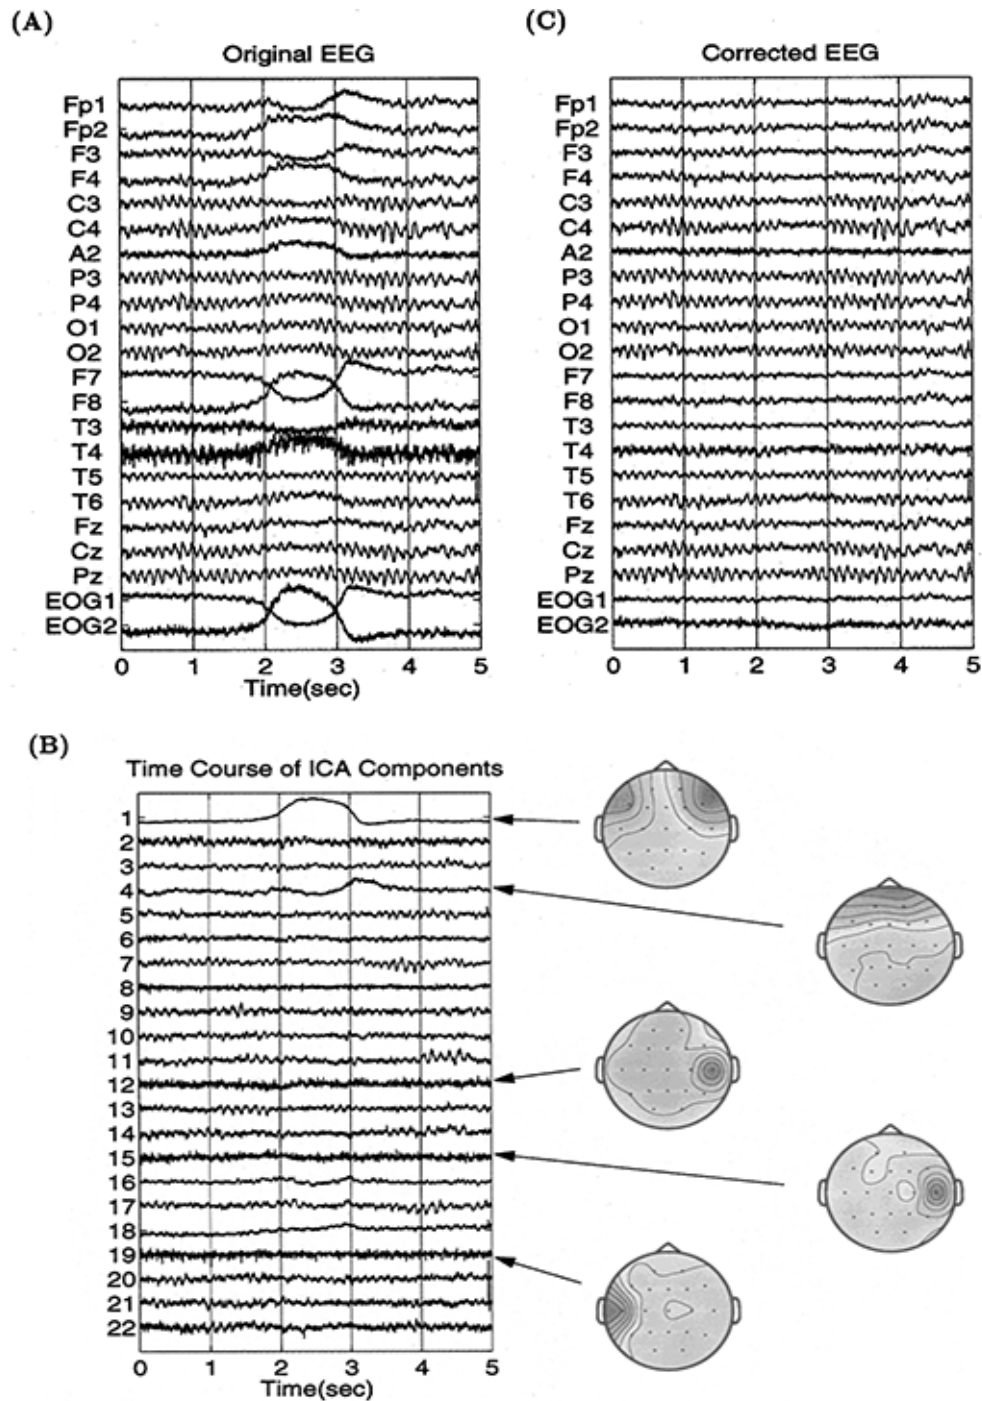
Στόχος της επεξεργασίας των σημάτων είναι η απομόνωση των eye movement artifacts για τη χρήση τους σε τεχνικές μάθησης. Όπως έχει ήδη αναφερθεί, τα σήματα που προκύπτουν από τις κινήσεις των ματιών εμπλέκονται μαζί με σήματα χαμηλών συχνοτήτων (1-8 Hz) που ανήκουν στους ρυθμούς δέλτα (δ) και θήτα (θ) και με άλλα artifacts. Συνεπώς, ένα απλό ζωνοπερατό φίλτράρισμα (bandpass filtering) δεν αρκεί για τη σωστή αποσύμπλεξη των σημάτων.



Σχήμα 4.8: Χάρτες φασματικής πυκνότητας ισχύος για συγκεκριμένες συχνότητες από το EEGLAB για το πείραμα 2.

Για την αποσύμπλεξη μπορούν να χρησιμοποιηθούν οι μέθοδοι PCA ή ICA, οι οποίες περιγράφονται στο κεφάλαιο 2. Η μέθοδος PCA βρίσκει τις ορθογωνικές διευθύνσεις των μεγαλύτερων διακυμάνσεων στα δεδομένα, ενώ στη μέθοδο ICA οι συνιστώσες δε χρειάζεται να είναι ορθογωνικές. Σύμφωνα με τη μέχρι τώρα βιβλιογραφία [24], [30] δεν υπάρχει κανένας λόγος οι νευροβιολογικές ΗΕΓ πηγές να είναι χωρικά ορθογωνικές μεταξύ τους, και άρα η μέθοδος ICA χρησιμοποιείται συχνότερα για τον ορθότερο διαχωρισμό των artifacts.


Για τη χρήση της μεθόδου ICA υπάρχουν κάποιες προϋποθέσεις οι οποίες αναφέρονται εν συντομία στην υποενότητα 2.2.3 του κεφαλαίου 2. Στην περίπτωση της ηλεκτροεγκεφαλογραφίας, τα artifacts προέρχονται από διαφορετικές πηγές από αυτές των καθαρών ΗΕΓ σημάτων, αφού τα πρώτα σχετίζονται με τις κινήσεις των ματιών, ενώ τα δεύτερα προέρχονται από τη συναπτική δραστηριότητα των νευρώνων. Επομένως η προϋπόθεση για ανεξαρτησία των πηγών ικανοποιείται. Επιπλέον, στην περίπτωση της ΗΕΓ υποθέτουμε ότι η αγωγιμότητα όγκου (volume conduction) του εγκεφάλου είναι ακαριαία και γραμμική, και άρα και η δεύτερη προϋπόθεση ικανοποιείται επίσης. Η τρίτη προϋπόθεση θεωρείται ως πιθανότητα, και η τέταρτη προϋπόθεση ότι τα ΗΕΓ σήματα είναι γραμμικοί συνδυασμοί ακριβώς N πηγών αμφισβητείται, αφού δεν είναι γνωστό πόσες ανεξάρτητες πηγές συνεισφέρουν στην καταγραφούσα ΗΕΓ δραστηριότητα.



Σχήμα 4.9: Παρουσίαση της μεθόδου εύρεσης των συνιστωσών Artifact με χρήση της μεθόδου ICA. A) Τμήματα 22 καναλιών ΗΕΓ σημάτων με έντονη αργή κίνηση ματιών, B) συνιστώσες που προκύπτουν από ICA μαζί με scalp maps πέντε συνιστωσών, που σχετίζονται με τις κινήσεις των ματιών (πάνω δύο) και χροταφικών μυών (κάτω τρεις χάρτες), C) Διορθωμένα ΗΕΓ σήματα έπειτα από αφαίρεση των πέντε συνιστωσών του (B). Πηγή: [24]

Παρόλα αυτά, η άγνοια του αριθμού N των ανεξάρτητων πηγών δεν προκαλεί ιδιαίτερο πρόβλημα, αφού πολλές πηγές είναι αρκετά κοντά μεταξύ τους και άρα ένας μεγάλος αριθμός

Ν αρκεί για να γίνει σωστά ο διαχωρισμός [18]. Η χρήση του αλγόριθμου για το διαχωρισμό των σημάτων φαίνεται και στο σχήμα 4.9 όπου γίνεται χρήση της μεθόδου για απαλοιφή των artifacts.



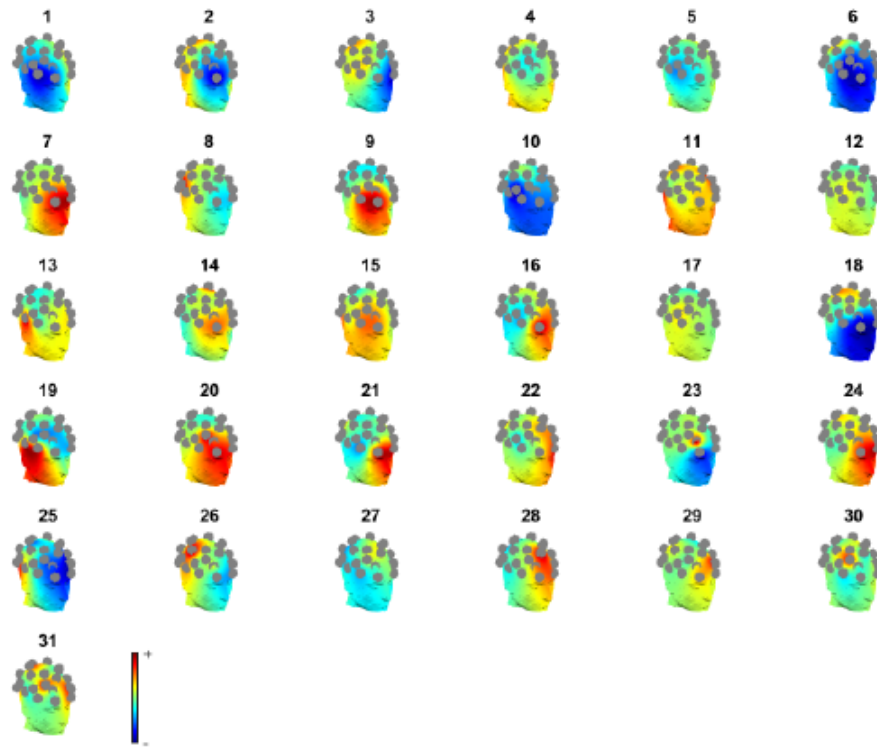
Σχήμα 4.10: Οι φασματικοί χάρτες των συνιστωσών που χρησιμοποιούνται για την οπτική επιθεώρηση και επιλογή των κατάλληλων συνιστωσών, μέσα από το περιβάλλον του EEGLAB.

Η απαλοιφή των επιθυμητών συνιστωσών γίνεται χρησιμοποιώντας τον αντίστροφο του πίνακα W όπως ορίστηκε στην ενότητα του κεφαλαίου 2.2.3 ως:

$$x' = (W)^{-1}u' \quad (4.1)$$

όπου u' είναι ο διορθωμένος πίνακας με μηδενισμένες τις γραμμές των συνιστωσών που θέλουμε να αφαιρέσουμε.

Η επιλογή των κατάλληλων συνιστωσών στα offline πειράματα γίνεται με χρήση της οπτικής επιθεώρησης των φασματικών χάρτων των συνιστωσών, όπως φαίνεται στο σχήμα 4.10 και στο σχήμα 4.11. Η επιλογή των κατάλληλων συνιστωσών σε πειράματα πραγματικού χρόνου γίνεται με βάση τη συσχέτιση των εξαχθείσων συνιστωσών με τα κανάλια που αντιστοιχούν στο μετωπιαίο λοβό (frontal lobe) και στα οποία γνωρίζουμε ότι υπάρχει έντονα η ζητούμενη εγκεφαλική δραστηριότητα, όπως φαίνεται στο σχήμα 4.12. Παρακάτω αναφέρονται με λεπτομέρεια οι μέθοδοι επεξεργασίας που ακολουθήθηκαν για τα συστήματα που υλοποιούνται στην εργασία.



Σχήμα 4.11: Οι προηγούμενη χάρτες του σχήματος 4.10 σε τρισδιάστατη απεικόνιση από το EEGLAB.

4.2.1 Απομόνωση σημάτων κίνησης των ματιών για αποκωδικοποίηση

Το πρώτο βήμα έπειτα από την καταγραφή των ΗΕΓ σημάτων είναι η αναφορά (re-referencing) των καναλιών ως προς ένα καινούριο σημείο, ώστε να επιτευχθεί το μέγιστο δυνατό CMRR - Common Mode Rejection Ratio, σύμφωνα και με τις οδηγίες της κατασκευάστριας εταιρίας Biosemi. Μπορούν να επιλεχθούν πολλών ειδών συνδυασμοί καναλιών ως αναφορά, αλλά συνήθως επιλέγεται κάτι από τα ακόλουθα:

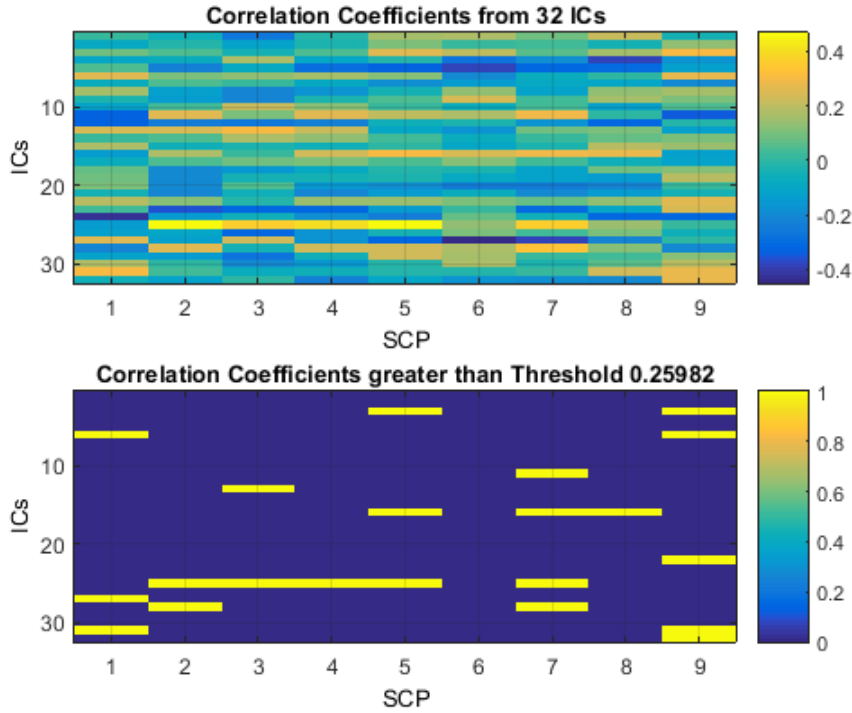
- το κεντρικό ηλεκτρόδιο στην κορυφή της κεφαλής (Cz),
- η μέση τιμή όλων των ηλεκτροδίων (Common Average Reference - CAR),
- η μέση τιμή μεταξύ δύο ηλεκτροδίων, ένα σε κάθε αυτί του χρήστη.

Στις πειραματικές μετρήσεις επιλέχθηκε ως αναφορά το κανάλι Cz (κανάλι 32) λόγω της ιδιαίτερης θέσης των επιθυμητών σημάτων. Οι θέσεις των ηλεκτροδίων φαίνονται στην εικόνα 4.6. Είναι:

$$eeg'_i(n) \leftarrow eeg_i(n) - eeg_{32}(n), i \in [1, 2, \dots, 30, 31] \quad (4.2)$$

με eeg_i να είναι το σήμα σε κάθε κανάλι i και n να αντιπροσωπεύει τα δείγματα χρόνου.

Όσον αφορά τα ψηφιακά φίλτρα που χρησιμοποιήθηκαν, αρχικά εφαρμόζεται ένα anti-aliasing, IIR Butterworth βαθυπερατό φίλτρο πρώτης τάξης με συχνότητα αποκοπής 44 Hz,



Σχήμα 4.12: Οι συντελεστές συσχέτισης των συνιστωσών με τα κανάλια του frontal lobe και η αυτόματη επιλογή των κατάλληλων συνιστωσών με βάση ένα πειραματικά εξαγόμενο κατώφλι.

ώστε να γίνει ο αποδεκατισμός (decimation) του σήματος από τα 16,384 Hz, (συχνότητα λειτουργίας εγκεφαλογράφου) στα 500 Hz (η συχνότητα λειτουργίας του ρομποτικού βραχίονα του εργαστηρίου). Έπειτα από το resampling ακολουθεί φιλτράρισμα με ένα διαφορετικό IIR butterworth βαθυπερατό φίλτρο 2ης τάξης, με συχνότητα αποκοπής 3.5 Hz όπως αποφασίστηκε με βάση την ανάλυση που φαίνεται στο σχήμα 4.7 και με βάση τους φασματικούς χάρτες κρανίου. Είναι:

$$eeg'_i(n) \leftarrow \frac{1}{a_0} \left(\sum_{j=0}^2 b_j eeg_i(n-j) - \sum_{j=1}^2 a_j eeg'_i(n-j) \right), n > 2 \quad (4.3)$$

Έτσι απομονώνονται πλήρως οι χαμηλές συχνότητες στις οποίες γνωρίζουμε ότι υπάρχουν τα σήματα που αναζητούμε. Στη συνέχεια, γίνεται η λεγόμενη διόρθωση βάσης (baseline correction), δηλαδή η εύρεση και η αφαίρεση της μέσης τιμής κάθε καναλιού. Η ενέργεια αυτή διευκολύνει τόσο τη μηχανική μάθηση όσο και τους μετασχηματισμούς όπως η PCA.

$$eeg'_i(n) \leftarrow eeg_i(n) - E[eeg_i(n \in [1, 2, \dots,])] \quad (4.4)$$

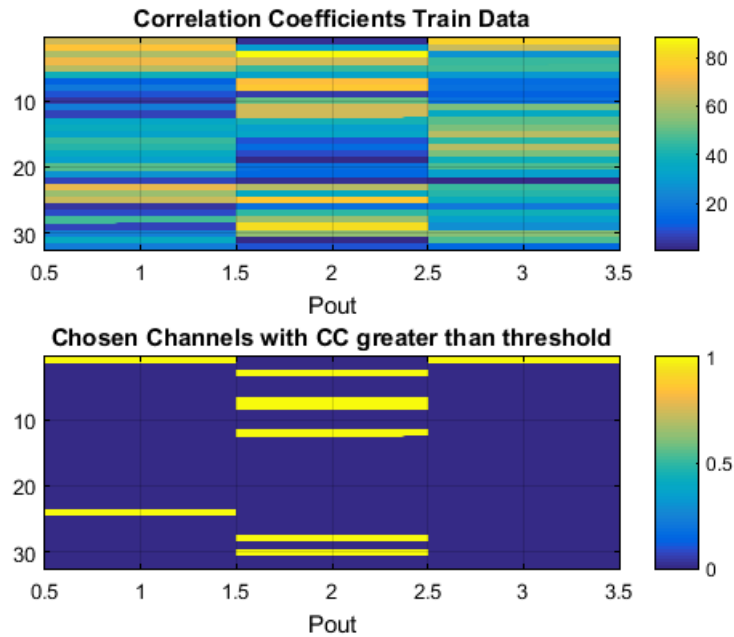
Σε περίπτωση που η επεξεργασία γίνεται σε πραγματικό χρόνο τότε γίνεται αναδρομικός υπολογισμός της μέσης τιμής ως:

$$E[eeg_i]_n \leftarrow \frac{E[eeg_i]_{n-1}(n-1) + eeg_{in}}{n} \quad (4.5)$$

Στη συνέχεια μπορεί να χρησιμοποιηθεί είτε η μέθοδος PCA είτε η ICA ώστε να γίνει η καλύτερη απομόνωση των ζητούμενων σημάτων και μείωση της διάστασης των δεδομένων εισόδου. Σε αυτό το σημείο, γίνεται αυτόματα η επιλογή των καναλιών που χρησιμοποιούνται αργότερα για την εκπαίδευση του μοντέλου μάθησης. Για την επιλογή χρησιμοποιείται η γωνία μεταξύ των ΗΕΓ καναλιών, επιλέγοντας αυτά που είναι ορθογώνια μεταξύ τους, δηλαδή αυτά που ελαχιστοποιούν το μέτρο του συνημιτόνου της γωνίας τους.

$$\cos\theta_{ij} = \frac{\langle EEG_i EEG_j \rangle}{\|EEG_i\| \|EEG_j\|} \quad (4.6)$$

Χρειάζεται επιπλέον να βρεθούν τα κανάλια που έχουν συσχέτιση με την κίνηση προς εξέταση, δηλαδή εκείνα που έχουν συσχέτιση με το διάνυσμα εξόδου της αποκωδικοποίησης. Έτσι υπολογίζεται ο συντελεστής συσχέτισης μεταξύ κάθε καναλιού ΗΕΓ σημάτων και του διανύσματος εξόδου (δηλαδή οι τρεις συντεταγμένες κίνησης) και επιλέγονται τα κανάλια με τον υψηλότερο συντελεστή (σχήμα 4.13).



Σχήμα 4.13: Η αυτόματη επιλογή καναλιών χρησιμοποιώντας το συντελεστή συσχέτισης.

$$\rho_{ij} = \frac{\text{Covariance}(EEG_i, P_j)}{\sigma_{EEG_i} \sigma_{P_j}} = \cos\theta_{ij}, \text{ if } E[EEG_i] = E[P_j] = 0 \quad (4.7)$$

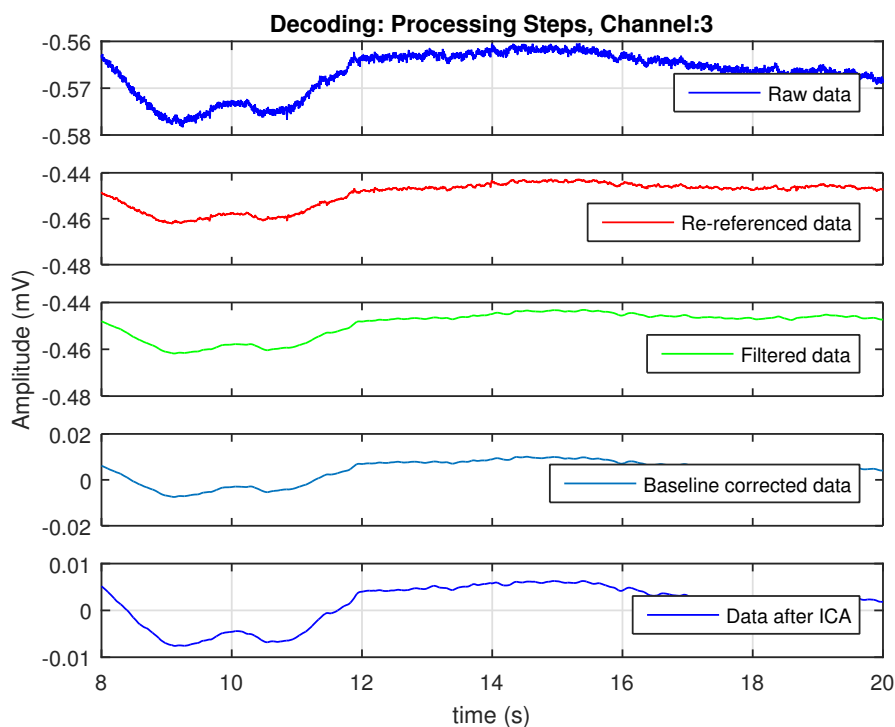
όπου P_j είναι το διάνυσμα εξόδου.

Στον παρακάτω αλγόριθμο περιγράφονται περιληπτικά τα βήματα της διαδικασίας:

Στην εικόνα 4.14 φαίνονται λεπτομερώς τα παραπάνω βήματα για κάποιο τυχαίο χρονικό διάστημα του πειράματος stop1. Για την αναπαράσταση επιλέχθηκε το κανάλι 3.

Algorithm 1 EEG Decoding Processing

Re-reference to Cz:	$eeg'_i(n) \leftarrow eeg_i(n) - eeg_{32}(n), i \in [1, 2, \dots, 30, 31]$
Resampling	
IIR lowpass:	$eeg'_i(n) \leftarrow \frac{1}{a_0} (\sum_{j=0}^2 b_j eeg_i(n-j) - \sum_{j=1}^2 a_j eeg'_i(n-j))$
Mean subtraction:	$eeg'_i(n) \leftarrow eeg_i(n) - E[eeg_i(n \in [1, 2, \dots,])]$
ICA	
Automatic Channel Selection	



Σχήμα 4.14: Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 1 (πείραμα stop1).

4.2.2 Απομόνωση σημάτων κίνησης των ματιών για κατηγοριοποίηση κίνησης

Πέρα από την αποκωδικοποίηση της κίνησης σε τρεις διαστάσεις, δημιουργήθηκε ένας κατηγοριοποιητής (classifier) για την εύρεση της στασιμότητας του χεριού κατά την κίνηση. Η έξοδος αυτού του κατηγοριοποιητή χρησιμοποιήθηκε στη δημιουργία του μοντέλου που περιγράφεται στο κεφάλαιο 5. Τα πρώτα στάδια της επεξεργασίας των σημάτων είναι ίδια με την προηγούμενη περίπτωση, δηλαδή: Αρχικά γίνεται re-reference ως προς το κανάλι Cz όπως περιγράφεται στην εξίσωση 4.2. Έπειτα ακολουθεί resampling με χρήση ενός anti-aliasing, IIR Butterworth βαθυπερατού φίλτρου πρώτης τάξης με συχνότητα αποκοπής 44 Hz και φιλτράρισμα IIR butterworth βαθυπερατό φίλτρο 2ης τάξης, με συχνότητα αποκοπής 3.5 Hz όπως νωρίτερα. Στη συνέχεια αφαιρέθηκε η μέση τιμή των καναλιών και έγινε ICA. Η

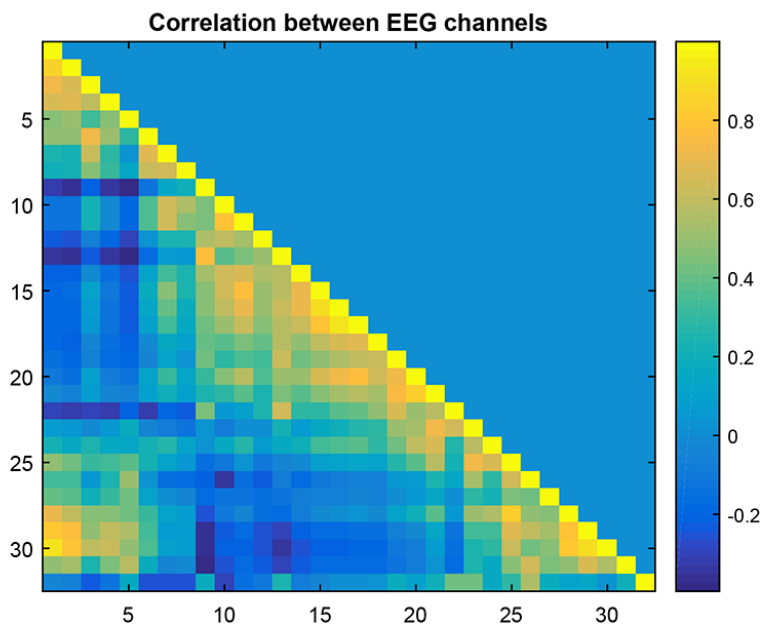
διαφορά με την προηγούμενη επεξεργασία έγκειται στην προσθήκη ενός σταδίου διαφορίσης των σημάτων ως:

$$eeg'_i(n) \leftarrow \frac{eeg_i(n) - eeg_i(n-1)}{T} \quad (4.8)$$

όπου T είναι η περίοδος δειγματοληψίας δηλαδή 1 προς 500. Επιπλέον, η επιλογή των καναλιών σε αυτή την περίπτωση γίνεται διαφορετικά, χρησιμοποιώντας απευθείας αυτά που αντιστοιχίζονται στο μετωπιαίο λοβό:

$$frontal_j = eeg_i : i \in [1, 2, 3, 4, 27, 28, 29, 30, 31] \quad (4.9)$$

Όπως φαίνεται στην εικόνα 4.15 υπάρχει μεγάλη συσχέτιση γύρω από την κύρια διαγώνιο του πίνακα, αφού τα κανάλια βρίσκονται αρκετά κοντά μεταξύ τους, και υψηλή συσχέτιση ανάμεσα στα πρώτα 5 και τα τελευταία 5 κανάλια. Πρόκειται για αυτά που βρίσκονται στο μπροστινό μέρος του κεφαλιού όπως φαίνεται και στο σχήμα 4.6. Τελικά ο νέος αλγόριθμος

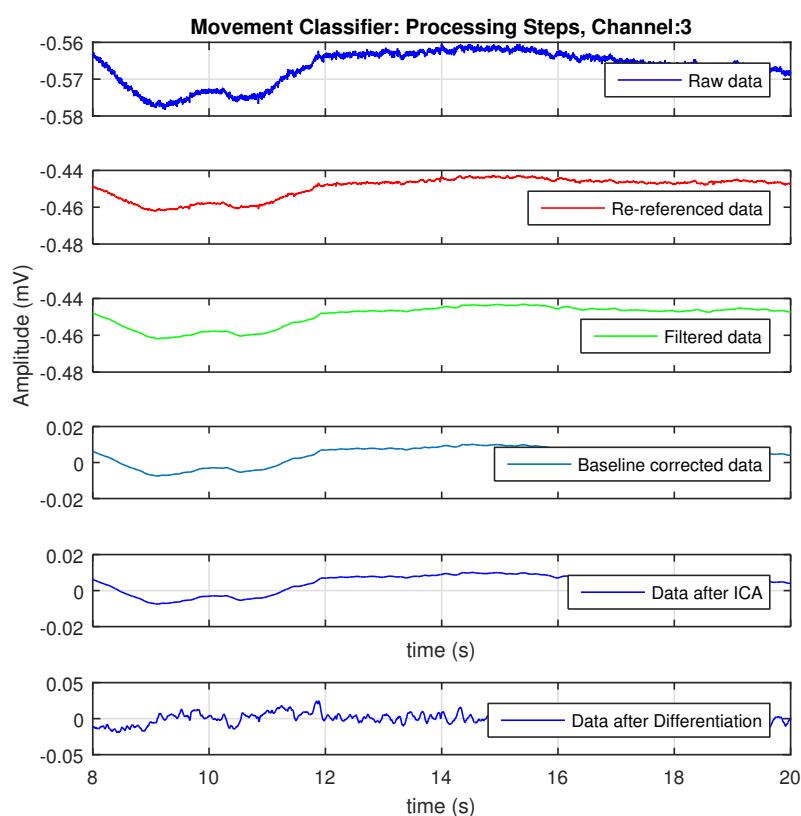


Σχήμα 4.15: Οι συντελεστές συσχέτισης CC για τα 32 κανάλια.

επεξεργασίας είναι:

Algorithm 2 EEG Steadiness Processing

Re-reference to Cz:	$eeg'_i(n) \leftarrow eeg_i(n) - eeg_{32}(n), i \in [1, 2, \dots, 30, 31]$
Resampling	
IIR lowpass:	$eeg'_i(n) \leftarrow \frac{1}{a_0} \left(\sum_{j=0}^2 b_j eeg_i(n-j) - \sum_{j=1}^2 a_j eeg'_i(n-j) \right)$
Mean subtraction:	$eeg'_i(n) \leftarrow eeg_i(n) - E[eeg_i(n \in [1, 2, \dots,])]$
ICA	
Numerical Differentiation:	$eeg'_i(n) \leftarrow \frac{eeg_i(n) - eeg_i(n-1)}{T}$
Frontal Channels Selection	



Σχήμα 4.16: Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 2 (πείραμα stop1).

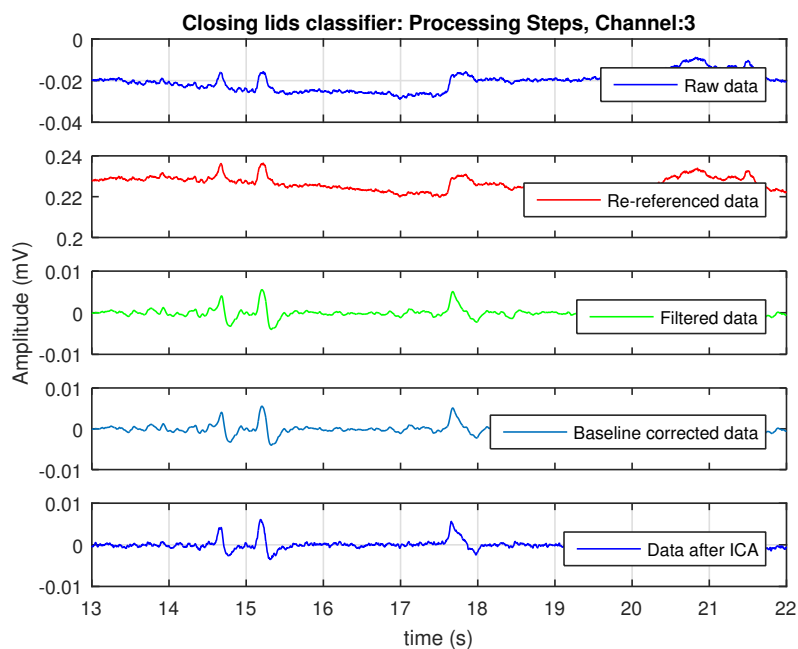
4.2.3 Απομόνωση σημάτων κίνησης των βλεφάρων

Η τελευταία χρήση των ΗΕΓ σημάτων στην εργασία γίνεται για την εύρεση των κυματομορφών σε περίπτωση κλεισίματος των ματιών. Σε αυτή την περίπτωση ακολουθείται παρόμοια διαδικασία με πριν. Αρχικά γίνεται re-reference ως προς το κανάλι Cz και ύστερα γίνεται re-sampling με χρήση ενός anti-aliasing, IIR Butterworth βαθυπερατού φίλτρου πρώτης τάξης με συχνότητα αποκοπής 44 Hz. Στη συνέχεια το φιλτράρισμα στηρίζεται στην ανάλυση που

παρουσιάστηκε νωρίτερα (σχήμα 4.8), με αποτέλεσμα να επιλεγθεί ζωνοπερατό φίλτρο IIR butterworth φίλτρο 2ης τάξης, με συχνότητα αποκοπής 2 και 8 Hz. Στη συνέχεια γίνεται baseline correction και ανάλυση σε ανεξάρτητες συνιστώσες. Η επιλογή των καναλιών σε αυτή την περίπτωση γίνεται όπως στον αλγόριθμο 2, δηλαδή με την επιλογή των καναλιών που ανήκουν στο μετωπιαίο λοβό. Η περίληψη του αλγόριθμου φαίνεται παρακάτω:

Algorithm 3 EEG Blinking Processing

Re-reference to Cz:	$eeg'_i(n) \leftarrow eeg_i(n) - eeg_{32}(n), i \in [1, 2, \dots, 30, 31]$
Resampling	
IIR bandpass:	$eeg'_i(n) \leftarrow \frac{1}{a_0} (\sum_{j=0}^2 b_j eeg_i(n-j) - \sum_{j=1}^2 a_j eeg'_i(n-j))$
Mean subtraction:	$eeg'_i(n) \leftarrow eeg_i(n) - E[eeg_i(n \in [1, 2, \dots,])]$
ICA	
Fp1 Channel Selection	



Σχήμα 4.17: Τα αποτελέσματα της διαδικασίας για κάθε βήμα του αλγόριθμου 3 (πείραμα volblink1).

Κεφάλαιο 5

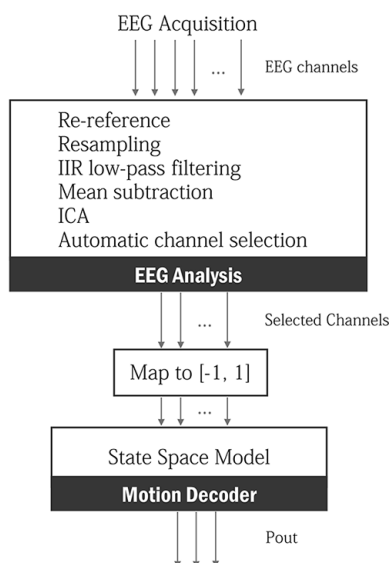
Μοντέλο ακινητοποίησης χεριού για επίτευξη αδράγματος

Σε αυτό το κεφάλαιο παρουσιάζεται ένα μοντέλο ακινητοποίησης ενός ρομποτικού βραχίονα για την επίτευξη αδράγματος. Βασίζεται στη συνεχή αποκωδικοποίηση τρισδιάστατης τροχιάς κίνησης, μέσω των HEG σημάτων των ματιών (artifacts) που παρουσιάστηκαν στο κεφάλαιο 4. Τα σήματα αυτά χρησιμοποιούνται για να προσδιορίσουν την τελική θέση ενός ρομποτικού βραχίονα στο χώρο, δηλαδή τις συντεταγμένες x, y, z . Στο τελικό σημείο δράσης υπάρχει κάποιο ρομποτικό χέρι. Στόχος είναι ένας οποιοσδήποτε χρήστης να μπορεί να μετακινήσει το τελικό σημείο δράσης αρκετά κοντά σε ένα αντικείμενο, με σκοπό να το πιάσει.

5.1 Αποκωδικοποίηση τροχιάς κίνησης στο χώρο με χρήση HEG σημάτων

Στο μοντέλο αποκωδικοποίησης γίνεται η αποκωδικοποίηση της κίνησης των ματιών σε κίνηση του τελικού σημείου δράσης ενός ρομποτικού βραχίονα. Για την αποκωδικοποίηση συνεχούς, τρισδιάστατης τροχιάς χρησιμοποιείται η ανάλυση που έγινε στην υποενότητα 4.2.1. Χρησιμοποιώντας HEG σήματα μπορούν να δημιουργηθούν μοντέλα μηχανικής μάθησης για την εκτίμηση της τροχιάς. Σημειώνεται ότι οι απαιτήσεις του προβλήματος για συνεχή τροχιά επιβάλλουν τη χρήση μοντέλων παλινδρόμησης. Για την αποκωδικοποίηση χρησιμοποιήθηκαν διάφορων ειδών μοντέλα, όπως νευρωνικά δίκτυα και μοντέλα μεταβλητών κατάστασης (State Space Models). Τελικά επιλέχθηκε τα μοντέλα μεταβλητών κατάστασης, αφού είχε την καλύτερη επίδοση. Η διαδικασία που ακολουθήθηκε πριν από την εκπαίδευση φαίνεται στο σχήμα 5.1.

Για την εκπαίδευση χρησιμοποιήθηκαν πραγματικά δεδομένα από πειράματα. Κατά τη διάρκεια των πειραμάτων οι χρήστες (subjects) κλήθηκαν να παρακολουθούν με τα μάτια τους κινήσεις που έκαναν, είτε οι ίδιοι με το χέρι τους, είτε ένας τρίτος με κάποιο αντικείμενο. Τα μοντέλα εκπαιδεύτηκαν σε διάφορα είδη κινήσεων χρησιμοποιώντας δεδομένα από 6 διαφορετικά άτομα (3). Το State Space Model είναι αλγόριθμος επιβλεπόμενης μάθησης, και άρα για την εκπαίδευση χρειάζεται να είναι γνωστό το επιθυμητό διάλυμα εξόδου, δηλαδή η



Σχήμα 5.1: Η διαδικασία που ακολουθείται για την αποκωδικοποίηση.


επιθυμητή τροχιά. Αυτό εξασφαλίστηκε με τη χρήση ενός μαγνητικού tracker θέσης.

	CC_x	CC_y	CC_z	$RmsE_x$	$RmsE_y$	$RmsE_z$	$MaxE_x$	$MaxE_y$	$MaxE_z$
PCA	0.724	0.821	0.825	2.98	10.25	7.80	7.82	23.58	19.81
ICA	0.671	0.921	0.833	4.47	7.21	6.72	9.76	17.87	21.48
None	0.712	0.669	0.735	4.24	13.77	8.02	9.8	31.47	23.08

Πίνακας 5.1: Σύγκριση των μεθόδων ICA και PCA για την αποκωδικοποίηση. Οι τιμές των σφαλμάτων είναι σε εκατοστά

Κατά την επεξεργασία μπορεί να χρησιμοποιηθεί είτε η PCA είτε η ICA. Αποτελέσματα και των δύο μεθόδων συγκρίνονται στον πίνακα 5.1 και στα σχήματα 5.3, 5.4. Μετά την επεξεργασία γίνεται η αναπαράσταση των σημάτων στο εύρος $[-1,1]$, κάτι που συνηθίζεται σε αλγόριθμους μηχανικής μάθησης. Επειδή πρόκειται για συνεχή αποκωδικοποίηση, ως χαρακτηριστικό επιλέγεται αυτούσιο το επεξεργασμένο σήμα. Η έξοδος του μοντέλου μεταβλητών κατάστασης είναι οι συντεταγμένες του τελικού σημείου δράσης στο χώρο, δηλαδή ένα διάνυσμα $P_{out} = [p_x, p_y, p_z]^T$. Τα αποτελέσματα του μοντέλου που χρησιμοποιήθηκε παρουσιάζονται στα σχήματα 5.2, 5.3 και 5.4:

Απο τα αποτελέσματα που παρουσιάζονται μπορεί να θεωρηθεί ότι η χρήση ICA βελτιώνει την απόδοση του αποκωδικοποιητή, αν και η PCA μέθοδος δίνει καλύτερα αποτελέσματα όσον αφορά τη συντεταγμένη x . Το σφάλμα ανάμεσα στην πραγματική και επιθυμητή τροχιά ξεπερνάει πολλές φορές το επιθυμητό όριο, κάτι το οποίο μπορεί να προκαλεί πρόβλημα όσον αφορά το άδραγμα. Αν και ιδανικά θα ήταν επιθυμητό να γίνεται άριστη αποκωδικοποίηση της τροχιάς, κάτι τέτοιο δεν είναι αναγκαίο. Χρειάζεται, όμως, κατά τη διάρκεια ακινητοποίησης το χέρι να παραμένει όσο το δυνατόν πιο σταθερό και να βρίσκεται αρκετά κοντά για να



Σχήμα 5.2: Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model χωρίς τη χρήση ICA ή PCA για δεδομένα δοκιμής.


επιτευχθεί το άδραγμα. Το τελευταίο μπορεί να εξασφαλιστεί από τον ίδιο το χρήστη σε πραγματικό χρόνο, και το πρώτο εξασφαλίζεται από το μοντέλο που περιγράφεται στην επόμενη υποενότητα.

5.2 Περιγραφή μοντέλου ακινητοποίησης χεριού

Επειδή η κίνηση για το άδραγμα ενός αντικειμένου είναι μη συνεχής, δημιουργούνται αρκετά προβλήματα κατά την αποκωδικοποίηση. Τα προβλήματα αυτά εντοπίζονται κατά τη διάρκεια, και έπειτα από την ακινητοποίηση του χεριού. Κατά την ακινητοποίηση χρειάζεται το end effector να παραμένει σταθερό ώστε να επιτευχθεί το άδραγμα, και κατά την επανεκκίνηση της κίνησης χρειάζεται να εξασφαλίζεται η λεία τροχιά του τελικού σημείου δράσης. Για να είναι όσο το δυνατόν πιο λεία η τροχιά κατά τις μεταβάσεις από κίνηση σε ακινησία, και αντίστροφα, χρησιμοποιούνται κάποια χρονικά μεταβαλλόμενα βάρη που εμποδίζουν τις απότομες μεταβολές των συντεταγμένων σε τέτοιες περιπτώσεις. Το μοντέλο περιγράφεται στο σχήμα 5.5 και βασίζεται στην ιδέα σταθεροποίησης των τιμών των συντεταγμένων όταν δεν υπάρχει κίνηση. Για την επεξεργασία των δεδομένων ακολουθείται η διαδικασία που περιγράφηκε νωρίτερα στο κεφάλαιο 4. Ως Αποκωδικοποιητής 1 (Decoder 1) θεωρείται η έξοδος του μοντέλου μεταβλητών κατάστασης (βλ. υποενότητα 5.1), και ως Αποκωδικοποιητής 2 (Decoder 2) το μοντέλο που περιγράφεται στο σχήμα 5.6. Είναι:

$$output[n] = weight_1[n] \cdot out_1[n] + weight_2[n] \cdot out_2[n] \quad (5.1)$$

όπου $weight_1, weight_2 \in [0, 1]$ και $weight_1 + weight_2 = 1$



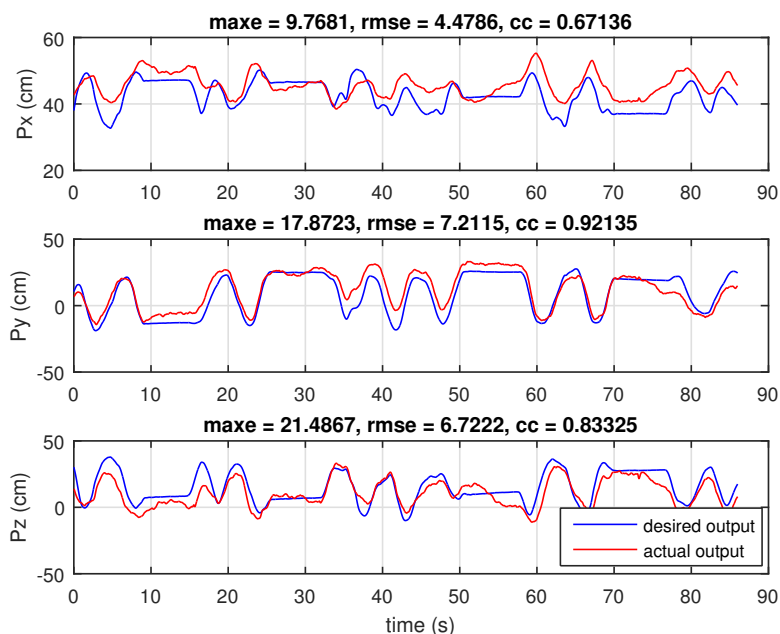
Σχήμα 5.3: Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model με χρήση PCA για δεδομένα δοκιμής.

Τελικά, η έξοδος του μοντέλου στηρίζεται στην αποκωδικοποίηση της κίνησης, κρατώντας σταθερές τις τιμές των συντεταγμένων σε περιόδους ακινησίας. Ο τρόπος που χρησιμοποιείται για την εύρεση αυτών των περιόδων και ο τρόπος υπολογισμού των βαρών $weight_1$, $weight_2$ περιγράφεται στη συνέχεια, στις ενότητες 5.2.1 και 5.2.2.

5.2.1 Δυαδικός Κατηγοριοποιητής κίνησης των ματιών

Στην παρούσα εργασία, η εύρεση των περιόδων ακινησίας πραγματοποιείται με τη χρήση ενός δυαδικού κατηγοριοποιητή (Binary Classifier). Ο κατηγοριοποιητής χρησιμοποιεί ως είσοδο ΗΕΓ σήματα ώστε να αποφασίσει σχετικά με το είδος της κίνησης. Για την επεξεργασία των σημάτων της εισόδου ακολουθείται η διαδικασία που περιγράφεται στην ενότητα 4.2.2 της εργασίας. Ως χαρακτηριστικά εισόδου χρησιμοποιούνται τα επεξεργασμένα σήματα που ανήκουν στα κανάλια του μετωπιαίου λοβού (5.7). Η έξοδος του κατηγοριοποιητή είναι 1 όταν δεν υπάρχει κίνηση, και 0 όταν υπάρχει.

Για την εκπαίδευση του κατηγοριοποιητή χρειάζεται, επιπλέον, και το επιθυμητό διάνυσμα εξόδου, το οποίο μπορεί να βρεθεί από δεδομένα του magnetic tracker. Ο tracker τοποθετείται στο σημείο παρακολούθησης του χρήστη, που συνήθως είναι το χερι του. Μέσω ανάλυσης των δεδομένων που προκύπτουν από τον tracker μπορεί να βρεθεί η ταχύτητα του σημείου αυτού, και να εξαχθεί το τελικό επιθυμητό διάνυσμα εξόδου (σχήμα 5.8). Γενικά, δοκιμάστηκαν διάφορα μοντέλα κατηγοριοποίησης στο περιβάλλον του MATLAB™ και παρακάτω παρουσιάζονται οι έξοδοι ενός νευρωνικού δικτύου, και ενός SVM που έδωσαν τα καλύτερα αποτελέσματα (σχήμα 5.9). Σημειώνεται πως στο SVM χρησιμοποιήθηκε ως πυρήνας η συ-



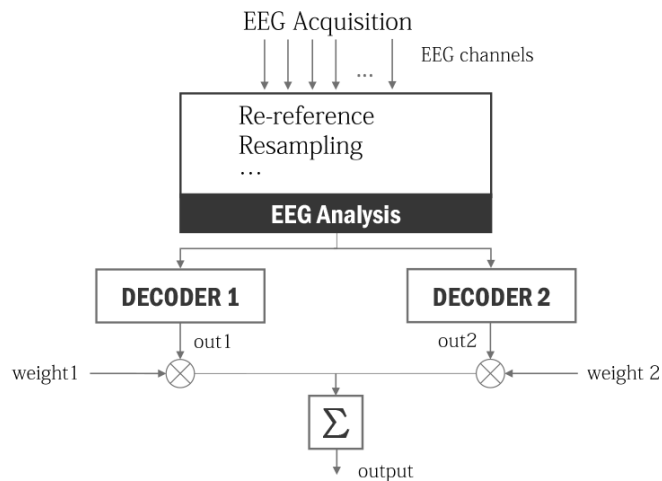
Σχήμα 5.4: Η επιθυμητή (μπλε) και η πραγματική (κόκκινη) τροχιά κίνησης από το State Space Model με χρήση ICA για δεδομένα δοκιμής.

	<i>Accuracy</i>	<i>Specificity</i>	<i>Sensitivity</i>
PCA	0.8247	0.8531	0.7534
ICA	0.8314	0.8724	0.7286


Πίνακας 5.2: Σύγκριση των μεθόδων ICA και PCA για την κατηγοριοποίηση ακινησίας σε Νευρωνικό Δίκτυο.

νάρτηση ακτινικής βάσης (rbf) και ότι κατά την επεξεργασία των σημάτων χρησιμοποιήθηκε η μέθοδος ICA.

Το νευρωνικό δίκτυο φάνηκε να έχει καλύτερη επίδοση σε όλες τις δοκιμές, και γι' αυτό προτιμήθηκε η χρήση του σε όλες τις επιπλέον αναλύσεις που ακολουθούν. Η εκπαίδευσή του έγινε με τη μέθοδο Bayesian regularization backpropagation, κατά την οποία γίνεται ελαχιστοποίηση ενός συνδυασμού από τετραγωνικά σφάλματα και βάρη. Η μέθοδος είναι μια παραλλαγή του αλγόριθμου Levenberg-Marquadt [40], και μεταβάλλει το γραμμικό συνδυασμό των σφαλμάτων και βαρών, ώστε να μπορεί να έχει μεγαλύτερη ικανότητα γενίκευσης [16]. Κατά την επεξεργασία των σημάτων που χρησιμοποιούνται για την είσοδο του κατηγοριοποιητή, δοκιμάστηκε τόσο η μέθοδος ICA όσο και η PCA, η σύγκριση των οποίων φαίνεται στον πίνακα 5.2. Σύμφωνα με τη βιβλιογραφία, όπως αναφέρθηκε και στο κεφάλαιο 4, η πρώτη μέθοδος χρησιμοποιείται συχνότερα γιατί υπερτερεί της δεύτερης. Στις προσομοιώσεις που έγιναν, όμως, και οι δύο μέθοδοι έδωσαν εξίσου καλά αποτελέσματα. Τελικά προτιμήθηκε η χρήση της μεθόδου ICA.



Σχήμα 5.5: Το μοντέλο ακινητοποίησης του χεριού κατά την αποκωδικοποίηση.




Σχήμα 5.6: Τα επιμέρους στοιχεία του μοντέλου που παρουσιάστηκε στο σχήμα 5.5.

5.2.2 Υπολογισμός χρονικά μεταβλητών βαρών

Η έξοδος του προηγούμενου κατηγοριοποιητή χρησιμοποιείται για τον υπολογισμό των βαρών του μοντέλου. Τα βάρη που προκύπτουν είναι, έτσι, χρονικά μεταβαλλόμενα και προσαρμόζονται σε πραγματικό χρόνο με την κίνηση. Ιδανικά, τα βάρη πρέπει να έχουν μορφή παρόμοια με αυτή που φαίνεται στο σχήμα 5.10, εξασφαλίζοντας τη λεία μετάβαση από το 0 στο 1 στις περιόδους μετάβασης από κίνηση σε ακινησία. Για την εξαγωγή των βαρών, η έξοδος του κατηγοριοποιητή θεωρείται ως συνάρτηση του χρόνου, με τα missclassifications να θεωρούνται ως "θόρυβος". Στόχος είναι η εξάλειψη αυτού του "θόρυβου", χρησιμοποιώντας τεχνικές που μπορούν να εφαρμοστούν σε εφαρμογές πραγματικού χρόνου.

Το πρώτο βάρος του μοντέλου προέρχεται από την έξοδο του κατηγοριοποιητή, και το δεύτερο εξάγεται από το πρώτο. Κατά την περιγραφή του μοντέλου, δόθηκαν κάποιοι περιορισμοί για το εύρος των βαρών και τη σχέση μεταξύ τους, οι οποίοι πρέπει να ισχύουν πάντοτε. Ο περιορισμός των βαρών να ανήκουν στο εύρος $[0,1]$ ικανοποιείται εύκολα αφού προκύπτουν από την έξοδο του δυαδικού κατηγοριοποιητή, με τις κλάσεις να αντιστοιχίζονται σε τιμές 0 και 1. Η σχέση μεταξύ των βαρών $weight_1 + weight_2 = 1$ ικανοποιείται επίσης πολύ εύκολα με τον υπολογισμό του δεύτερου βάρους ως:

$$weight_2 = 1 - weight_1$$




Σχήμα 5.7: Τα 9 κανάλια ως χαρακτηριστικά εισόδου στον κατηγοριοποιητή (μπλε χρώμα), και τα τμήματα που αντιστοιχίζονται σε περιόδους ακινησίας (κόκκινο χρώμα) των δεδομένων δοκιμής.

Για τον υπολογισμό των βαρών ακολουθήθηκε μια παραλλαγή του φιλτραρίσματος moving average. Στη συνέχεια περιγράφεται ο αλγόριθμος υπολογισμού του πρώτου βάρους, και ο τρόπος σκέψης πίσω από τη σύλληψή του.

Η έξοδος του κατηγοριοποιητή είναι μία συνάρτηση χρόνου με τιμές 0 ή 1. Ένας πολύ απλός τρόπος εξάλειψης των missclassifications είναι ο χωρισμός του σήματος σε παραθύρα και η προσαρμογή των επιμέρους τιμών χρησιμοποιώντας τον αριθμητικό μέσο των παραθύρων. Ιδανικά, το μήκος του παραθύρου σε δείγματα πρέπει να είναι αρκετά μεγάλο, ώστε να περιέχει μεγάλης διάρκειας χρονική πληροφορία. Κάτι τέτοιο όμως είναι απαγορευτικό για εφαρμογές πραγματικού χρόνου, επειδή το μήκος των παραθύρων εισάγει χρονική καθυστέρηση. Τελικά, μια συμβιβαστική λύση είναι ο χωρισμός της διαδικασίας σε δύο επίπεδα, εισάγοντας έναν επιπλέον buffer που κρατά τις τιμές παλιότερων χρόνων, επιτρέποντας έτσι το μήκος των παραθύρων να είναι αρκετά μικρό. Προφανώς το μέγεθος των θέσεων του buffer επηρεάζει κατά πολύ το τελικό αποτέλεσμα. Ο τελικός αριθμός που επιλέχθηκε προέκυψε από τις προσομοιώσεις ευριστικά. Η διαδικασία περιγράφεται στον αλγόριθμο 4.

Θεωρούμε ότι ο κατηγοριοποιητής δίνει επαρκή αποτελέσματα, ώστε τα missclassifications να είναι λιγότερα από τα corrected classified. Σε περιπτώσεις, όμως, που κάτι τέτοιο δε συμβαίνει, τότε ο αριθμητικός μέσος μπορεί να επηρεάσει πολύ τα βάρη. Ένας τρόπος να λυθεί αυτό το πρόβλημα είναι να περιοριστούν οι αυξομειώσεις των τιμών του μέσου όρου, ώστε να μην επιτρέπονται οι απότομες μεταβολές του. Γι' αυτό το λόγο εισάγεται στο μοντέλο ένας μηχανισμός που, αρχικά κβαντίζει (quantization) τις τιμές M γύρω από κάποιες τιμές ή κλίμακες (scales), και στη συνέχεια περιορίζει τις μεταβάσεις μεταξύ των κλιμάκων. Η διαδικασία



Σχήμα 5.8: Εύρεση της επιθυμητής εξόδου του κατηγοριοποιητή για τα δεδομένα δοκιμής.

Algorithm 4 Weight Calculation using mean #1

$i = 1$

START

$M \leftarrow \text{mean}(eeg(n \in \text{win}_i)),$ $n : \text{samples}$

$\text{pushBuffer}(M)$ {Keep last m values}

$\text{weights}(n \in \text{win}_i) \leftarrow \text{mean}(\text{buffer})$


$i = i + 1$

return to START

περιγράφεται στον αλγόριθμο 5. Οι τιμές γύρω από τις οποίες γίνεται η στρογγυλοποίηση φαίνονται στον πίνακα 5.3.

Για να απαγορευτούν οι απότομες μεταβολές των τιμών M , χρησιμοποιείται το Finite State Machine - FSM της εικόνας 5.12 που επιβάλλει η επόμενη τιμή M να κυμαίνεται στο ± 0.25 της προηγούμενης. Επιβάλλει, δηλαδή, η τιμή M να ανεβαίνει ή να κατεβαίνει το πολύ ένα σκαλοπάτι τη φορά, μην επιτρέποντας τις απότομες μεταβολές. Στην εικόνα 5.13 φαίνονται τα παραγόμενα βάρη με τις δύο αυτές μεθόδους, χρησιμοποιώντας αριθμητικό μέσο και την έξοδο του νευρωνικού που φαίνεται στο σχήμα 5.9.

Όπως αναφέρθηκε ήδη, ο αριθμητικός μέσος δε δίνει πάντοτε τα επιθυμητά αποτελέσματα επειδή επηρεάζεται πολύ από τις ακραίες τιμές. Επομένως, ο αριθμητικός μέσος μπορεί να αντικατασταθεί από μια διαφορετική, πιο κατάλληλη μετρική. Εξαιτίας της ιδιαιτερότητας των τιμών εξόδου του κατηγοριοποιητή (0 ή 1) πολλές γνωστές μετρικές κεντρικής τάσης δίνουν ίδιο αποτέλεσμα ή δεν ορίζονται (π.χ. αρμονικό μέσος). Μία αρκετά καλή μετρική, που απορρίπτει ακραίες τιμές, είναι αυτή του Interquartile Mean - IQM που αποδέχεται δεδομένα



Σχήμα 5.9: Σύγκριση εξόδου ενός SVM και ενός NN.


Algorithm 5 Weight Calculation using mean #2 $i = 1$ **START** $M \leftarrow \text{mean}(\text{eeg}(n \in \text{win}_i)),$ $n : \text{samples}$ rounding of M pushBuffer(M) {Keep last m values}weights($n \in \text{win}_i$) $\leftarrow \text{mean}(\text{buffer})$ $i = i + 1$ **return to START**

μόνο του δεύτερου και τρίτου τεταρτημορίου και ορίζεται ως:

$$x_{IQM} = \frac{2}{n} \sum_{i=\frac{n}{4}+1}^{\frac{3n}{4}} x_i \quad (5.2)$$

υποθέτοντας ότι οι τιμές x_i είναι ταξινομημένες.


Αν στους προηγούμενους δύο αλγόριθμους ως μέσος θεωρηθεί ο IQM τότε προκύπτουν τα αποτελέσματα που φαίνονται στο σχήμα 5.14. Το τελικό μοντέλο φαίνεται συνολικά, στο σχήμα 5.15 με κάθε λεπτομέρεια για τα επιμέρους βήματα. Ο υπολογισμός των βαρών μπορεί να γίνει με έναν από τους δύο αλγορίθμους που παρουσιάστηκαν νωρίτερα.




Σχήμα 5.10: Με μπλε χρώμα το βάρος weight1 που θα έπρεπε ιδανικά να χρησιμοποιηθεί, και με πράσινο χρώμα το ιδανικό βάρος που μπορεί να υπολογιστεί από την έξοδο του κατηγοριοποιητή

Index	Mean Value Interval	Final Value
1	$(-\infty, 0.125]$	0.00
2	$(0.125, 0.375]$	0.25
3	$(0.375, 0.625]$	0.50
4	$(0.625, 0.875]$	0.75
5	$(0.875, +\infty)$	1.00


Πίνακας 5.3: Οι τιμές κβαντοποίησης των τιμών M.




Σχήμα 5.13: Τα βάρη όπως υπολογίζονται σύμφωνα με τους αλγόριθμους #1 και #2 για αριθμητικό μέσο



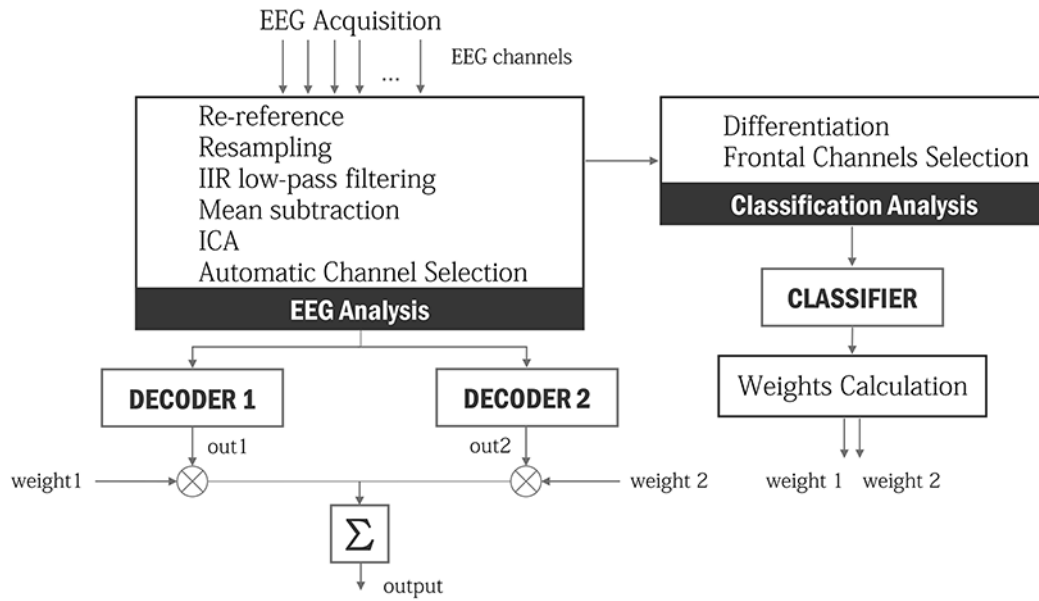
Σχήμα 5.11: Η διαδικασία διαχωρισμού τυχαίου σήματος σε παράθυρα.




Σχήμα 5.12: Οι επιτρεπόμενες μεταβάσεις ανάμεσα στις 5 κλίμακες.



Σχήμα 5.14: Τα βάρη όπως υπολογίζονται σύμφωνα με τους αλγόριθμους #1 και #2 για IQM



Σχήμα 5.15: Το μοντέλο ακινητοποίησης χεριού με βάρη, για την επίτευξη αδράγματος




Σχήμα 5.16: Τα επιμέρους βήματα της επεξεργασίας, του κατηγοριοποιητή και του υπολογισμού των βαρών του μοντέλου


5.3 Αποτελέσματα και συμπεράσματα

Παρακάτω παρουσιάζονται τα αποτελέσματα του μοντέλου ακινητοποίησης του χεριού κατά την αποκωδικοποίηση. Η διαδικασία που ακολουθήθηκε για την εξαγωγή αυτών των αποτελεσμάτων περιγράφεται στο σχήμα 5.15. Κατά την επεξεργασία των ΗΕΓ σημάτων μπορεί να χρησιμοποιηθεί τόσο η ICA όσο και η PCA αφού και οι δύο δίνουν καλά αποτελέσματα. Τελικά επιλέχθηκε η ICA επειδή υπήρξε ελάχιστα καλύτερη επίδοση στις μετρικές αξιολόγησης, και επειδή συνιστάται στη βιβλιογραφία ως ιδανικότερη μέθοδος [24] [15] [34]. Για τον υπολογισμό των βαρών του μοντέλου προτιμήθηκε ο αλγόριθμος 5 με χρήση του μέσου IQM, με τα βάρη που φαίνονται στο σχήμα 5.16. Τα βάρη συγκρίνονται στην επίδοση με τα ιδανικά βάρη του σχήματος 5.10.


Στα σχήματα 5.17, 5.18, 5.19 παρουσιάζεται η έξοδος αποκωδικοποίησης για μοντέλο μεταβλητών κατάστασης 4ης τάξης χωρίς βάρη, χρησιμοποιώντας ιδανικά βάρη, και χρησιμοποιώντας πραγματικά βάρη αντίστοιχα. Από τις μετρικές αξιολόγησης που φαίνονται στα σχήματα αυτά μπορεί κάποιος να διακρίνει ότι υπάρχει βελτίωση όσον αφορά την αποκωδικοποίηση.



Σχήμα 5.17: Η έξοδος του αποκωδικοποιητή Decoder 1 χωρίς χρήση του μοντέλου ακινητοποίησης




Σχήμα 5.18: Η έξοδος του μοντέλου ακινητοποίησης για ιδανικά βάρη




Σχήμα 5.19: Η έξοδος του μοντέλου ακινητοποίησης για πραγματικά βάρη

Μέσω της οπτικής επιθεώρησης συμπεραίνεται ότι υπάρχουν κάποιες περιπτώσεις που η διαφορά είναι εμφανής, ενώ άλλες που αν και η σταθεροποίηση γύρω από την τιμή έχει επιτευχθεί, το τελικό σφάλμα ανάμεσα στην επιθυμητή και πραγματική τιμή αυξάνεται. Κάτι τέτοιο δεν επηρεάζει την πραγματική επίδοση του μοντέλου, αφού στόχος του είναι η θέση του τελικού στοιχείου δράσης (διανύσματα P_x, P_y, P_z) να παραμένουν σταθερά σε περιόδους ακινησίας. Το σφάλμα που φαίνεται να υπάρχει δεν ενοχλεί ουσιαστικά, αφού θεωρείται ότι σε πειράματα πραγματικού χρόνου ο χρήστης θα μπορεί να διορθώνει ο ίδιος το σφάλμα θέσης. Για την πραγματική αξιολόγηση του μοντέλου απομονώθηκαν τα τμήματα ακινησίας που φαινόνται στα παραπάνω σχήματα, και αφαιρέθηκε το offset ώστε όλες οι τιμές να σταθεροποιούνται γύρω από το μηδέν (σχήματα 5.20 και 5.21). Έπειτα μετρήθηκε ουσιαστικά η διακύμανση των τιμών γύρω από το μηδέν ώστε να αξιολογηθεί η επίδοση του μοντέλου ακινητοποίησης.



Σχήμα 5.20: Σύγκριση του μοντέλου στις χρονικές περιόδους ακινησίας για ιδανικά βάρη

Παρατηρείται ότι στην περίπτωση των ιδανικών βαρών υπάρχει ουσιαστική βελτίωση όσον αφορά τη σταθεροποίηση γύρω από τις τιμές, κάτι που φαίνεται και οπτικά, αλλά και από τις μετρικές αξιολόγησης. Στην περίπτωση των πραγματικών βαρών σημειώνεται επίσης βελτίωση όσον αφορά την σταθεροποίηση, αλλά όχι στα ίδια επίπεδα με την προηγούμενη περίπτωση των ιδανικών βαρών, όπως ήταν και αναμενόμενο.



Σχήμα 5.21: Σύγκριση της μεθόδου στις χρονικές περιόδους ακινησίας για πραγματικά βάρη

	RMSE (cm)		
	State Space	Ideal Weights	Real Weights
Px	0.7343	0.1762	0.2558
Py	1.6011	0.3791	0.4601
Pz	2.5778	0.6812	0.7823

Πίνακας 5.4: Επίδοση του μοντέλου ακινητοποίησης για σταθεροποίηση της εξόδου αποκωδικοποίησης κατά την ακινησία

Κεφάλαιο 6

Το κλείσιμο των βλεφάρων ως μέσο εκδήλωσης πρόθεσης για άδραγμα

Όπως έχει ήδη αναφερθεί, για την επίτευξη αδράγματος ενός αντικειμένου με τη χρήση ΗΕΓ σημάτων υπάρχουν κάποιες προϋποθέσεις. Θεωρούμε ότι το πρόβλημα της σταθεροποίησης του ρομποτικού χεριού κατά τη διάρκεια του αδράγματος εξασφαλίζεται με το μοντέλο ακινητοποίησης που περιγράφηκε στο κεφάλαιο 5. Ένα επιπλέον στοιχείο που απαιτείται είναι ο προσδιορισμός του χρόνου που πρέπει να πραγματοποιηθεί το άδραγμα. Στη συνέχεια της υποενότητας προτείνεται ένας τρόπος προσδιορισμού της χρονικής στιγμής από τον ίδιο το χρήστη, χρησιμοποιώντας για μια ακόμη φορά ΗΕΓ σήματα.

6.1 Εισαγωγή

Υπάρχουν διάφορες οδοί που θα μπορούσε να ακολουθήσει κάποιος για τον προσδιορισμό της επιθυμητής στιγμής αδράγματος σε ένα σύστημα όπως αυτό που έχει σχεδιαστεί και παρουσιάζεται στην παρούσα εργασία. Μια προσέγγιση αφορά τον προσδιορισμό του χρόνου από ένα εξ ολοκλήρου αυτόματο σύστημα, το οποίο μπορεί να χρησιμοποιεί αισθητήρες και οπτική ανάδραση (visual feedback) από κάμερες. Σε μια τέτοια περίπτωση το σύστημα μπορεί να αναγνωρίζει τη θέση του χεριού και του αντικειμένου και να ξεκινά τη διαδικασία αδράγματος αυτόματα, όταν το χέρι φτάσει αρκετά κοντά. Ένα τέτοιο σύστημα, όμως, είναι αρκετά περίπλοκο, απαιτεί σωστό σχεδιασμό, και δε λαμβάνει καθόλου υπόψιν το χρήστη, με αποτέλεσμα να είναι επιρρεπές σε λάνθασμένες αποφάσεις (False Positives).

Μια διαφορετική προσέγγιση δίνει περισσότερη έμφαση στον άνθρωπο, ο οποίος καλείται να δώσει ο ίδιος με κάποιο τρόπο την εντολή. Όταν επιλέγεται η δεύτερη προσέγγιση, η έρευνα επικεντρώνεται πλέον στην εύρεση του καλύτερου τρόπου εκδήλωσης της επιθυμίας του χρήστη. Σχετικά με το άδραγμα, υπάρχουν πολλοί τρόποι εκδήλωσης της πρόθεσης, όπως με motor imagery σήματα του εγκεφάλου, που σχετίζονται με τη φαντασία κίνησης άκρου [7] ή χρησιμοποιώντας Ηλεκτρομυογραφικά - ΗΜΓ σήματα καταγεγραμμένα από το

χέρι του χρήστη [47], [11] αναγνωρίζοντας έτσι πότε ο χρήστης κλείνει το χέρι του.

Τέτοιες εφαρμογές όμως, έχουν αρκετά μειονεκτήματα αφού τα σήματα του εγκεφάλου που σχετίζονται με τη φαντασία κίνησης είναι αρκετά δύσκολο να ανιχνευθούν, με αποτέλεσμα αντίστοιχοι κατηγοριοποιητές να έχουν μέτρια ποσοστά ακρίβειας, και συστήματα που χρησιμοποιούν ΗΜΓ σήματα δε μπορούν να χρησιμοποιηθούν από άτομα με παράλυση. Στην παρούσα εργασία επιλέχθηκε ως σύμβαση η χρήση των ΗΕΓ artifacts που οφείλονται στην κίνηση των βλεφάρων. Τα σήματα αυτά είναι διαφορετικά από αυτά που χρησιμοποιούνται κατά την αποκωδικοποίηση της κίνησης των ματιών, αφού προέρχονται από την κίνηση των μυών γύρω από τα μάτια, και όχι των ίδιων των ματιών. Στο σύστημα που προτείνεται ο χρήστης δηλώνει την πρόθεσή του για άδραγμα κλείνοντας εκούσια τα βλέφαρα των ματιών για 1-2 περίπου δευτερόλεπτα. Το μοντέλο βασίζεται πάνω σε έναν κατηγοριοποιητή που ανιχνεύει το κλείσιμο των ματιών και ο οποίος περιγράφεται παρακάτω.


6.2 Ο κατηγοριοποιητής ανίχνευσης κλειστών βλεφάρων

Η κίνηση των βλεφάρων των ματιών επηρεάζει με συγκεκριμένο τρόπο τα ΗΕΓ σήματα. Στόχος του κατηγοριοποιητή είναι να μπορεί να ανιχνεύει συγκεκριμένες κυματομορφές που προκύπτουν από το κλείσιμο των βλεφάρων. Στη βιβλιογραφία υπάρχει πλήθος ερευνών που σχετίζονται με την ανίχνευση τέτοιων κυματομορφών, κυρίως με σκοπό την αφαίρεσή τους από το σύνολο των δεδομένων.

Χρησιμοποιώντας τη μέθοδο επεξεργασίας των σημάτων που περιγράφεται στο κεφάλαιο 4 δημιουργούνται διάφοροι classifiers για την ανίχνευση των κυματομορφών που προέρχονται από το κλείσιμο των ματιών.

Η κυματομορφή προς ανίχνευση έχει τη μορφή Β που φαίνεται στο σχήμα 6.1 και μπορεί εύκολα να ξεχωρίσει από τις άλλες. Τα δεδομένα που χρησιμοποιήθηκαν για την εκπαίδευση και δοκιμή των κατηγοριοποιητών προέκυψαν έπειτα από πειράματα, τα οποία περιγράφονται στο κεφάλαιο 3. Το άκουσμα του ήχου θεωρείται ως το συμβάν (event) και τοποθετείται στη χρονική στιγμή μηδέν σε κάθε δοκιμή (trial). Κατά τη διάρκεια των μετρήσεων σημειώνονται αυτόματα μέσω προγραμμάτων σε γλώσσα python οι χρονικές στιγμές των συμβάντων. Ως είσοδος του κατηγοριοποιητή χρησιμοποιήθηκε μόνο το κανάλι fp1 αφού κρίθηκε ότι είναι επαρκές για τη σωστή ανίχνευση. Από οπτική επιθεώρηση των επεξεργασμένων σημάτων διαπιστώθηκε ότι οι ζητούμενες κυματομορφές έχουν εύρος 300 ms περίπου. Για την εξακριβωμένη ανίχνευση των κυματομορφών χρησιμοποιήθηκαν επικαλυπτόμενα παράθυρα (overlapping windows) του σήματος, μήκους 500 ms, με 50% επικάλυψη, όπως φαίνεται στο σχήμα 6.3.

Κατά τα πειράματα χρησιμοποιήθηκαν 3 διαφορετικοί χρήστες, και προέκυψαν συνολικά 220 εποχές (epochs). Οι εποχές περιλαμβάνουν το εύρος [-1,2] sec από τη στιγμή του συμβάντος (event). Η ERP Image των εποχών αυτών όπως προκύπτει μέσα από το EEGLAB παρουσιάζεται στο σχήμα 6.4. Η εικόνα αυτή περιγράφει ουσιαστικά τη δραστηριότητα σε κάθε εποχή, που χρωματίζεται και κωδικοποιείται σε μία πιο κατανοητή μορφή για τη διασθητική αντίληψη των αποτελεσμάτων. Πρόκειται για μια σχετική αλλά πιο γενική διδιάστατη



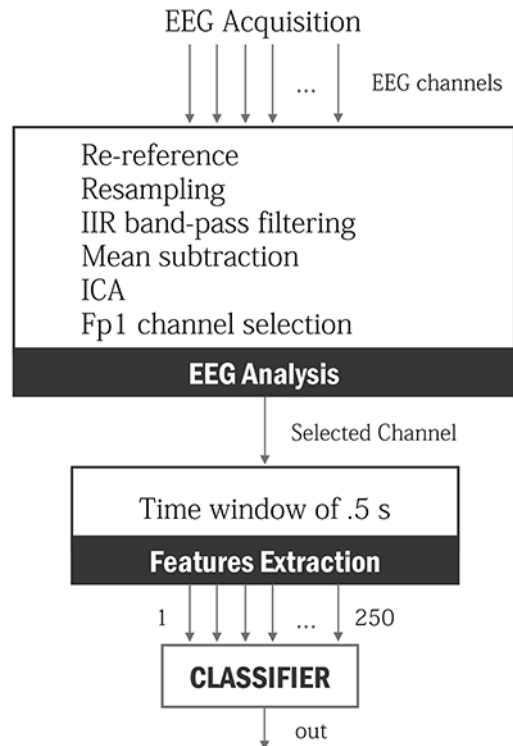
Σχήμα 6.1: Τμήμα του καναλιού fp1 έπειτα από επεξεργασία. Η κατακόρυφη γραμμή σηματοδοτεί τη χρονική στιγμή που ο χρήστης καλείται να κλείσει εθελούσια τα μάτια του. Στο σχήμα παρατηρούνται οι κυματομορφές A που αντιστοιχεί σε ακούσια βλεφάρισμα, B που αντιστοιχεί στο κλείσιμο των ματιών και C που αντιστοιχεί στο άνοιγμα των βλεφάρων.

απεικόνιση των event-related δεδομένων των εποχών.


Στο σχήμα 6.4 διακρίνουμε μια ομοιομορφία ως προς τη συμπεριφορά όλων των δοκιμών, που παρουσιάζουν υψηλή δραστηριότητα 200-250 ms έπειτα από τη στιγμή του συμβάντος (χρονική στιγμή μηδέν). Κάτι τέτοιο είναι ιδιαίτερα ενθαρρυντικό αφού δείχνει ότι η ανίχνευση είναι δυνατή. Τέλος, όπως φαίνεται και στο σχήμα 6.5 η δραστηριότητα έχει κοινή συμπεριφορά σε όλους τους χρήστες, και άρα δεν υπάρχει πρόβλημα γενίκευσης.

6.3 Εξαγωγή χαρακτηριστικών

Για την καλύτερη ανίχνευση αρκεί να γίνει η σωστή επιλογή των χαρακτηριστικών. Μία περίπτωση επιλογής χαρακτηριστικών είναι αυτούσια η χρονική σειρά σήματος (time-series) σε παράθυρα των 0.5 δευτερολέπτων. Μία άλλη περίπτωση είναι η επιλογή των παραμέτρων αυτο-παλίνδρομου μοντέλου (auto-regressive parameters - AR) για τα ίδια χρονικά παράθυρα. Σε αυτή την περίπτωση ως χαρακτηριστικά επιλέγονται οι παράμετροι που περιγράφουν το αυτό-παλίνδρομο μοντέλο και μπορούν να βρεθούν με χρήση ειδικών αλγορίθμων όπως με χρήση της εκτίμησης μέγιστης πιθανοφάνειας (Maximum Likelihood Estimation) [61] [31]. Η



Σχήμα 6.2: Το μοντέλο για την κατηγοριοποίηση για εκδήλωση της πρόθεσης για άδραγμα.

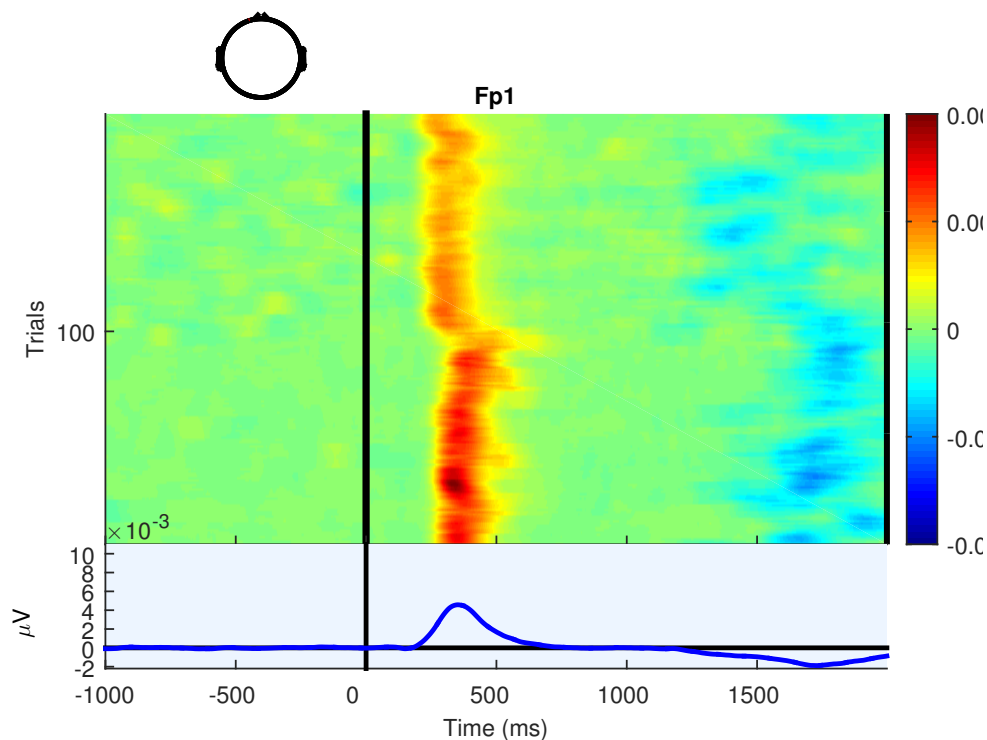


Σχήμα 6.3: Τρόπος διαχωρισμού του σήματος σε επικαλυπτόμενα παράθυρα κατά την είσοδο στον κατηγοριοποιητή.

χρήση AR μοντέλων υποθέτει τη δυνατότητα μοντελοποίησης των ΗΕΓ σημάτων ως γραμμικοί συνδυασμοί των σημάτων σε προηγούμενα χρονικά σημεία ως:

$$y(t) = \sum_{i=1}^p \alpha_i y(t-i) + \epsilon_t \quad (6.1)$$

όπου p η τάξη του μοντέλου, ϵ_t μια κατανομή μηδενικού μέσου και διακύμανσης σ^2 , και α_i οι παράμετροι που περιγράφουν το μοντέλο και χρησιμοποιούνται ως χαρακτηριστικά. Η χρήση τέτοιων μοντέλων στα ΗΕΓ σήματα είναι αρκετά συχνή. Πέρα από αυτές τις προσεγγίσεις, μπορούν να χρησιμοποιηθούν ως χαρακτηριστικά παράμετροι που προκύπτουν από την ανάλυση στο πεδίο της συχνότητας [2]. Όπως προέκυψε από την ανάλυση της παρούσας εργασίας, η χρήση των χαρακτηριστικών της πρώτης περίπτωσης είναι επαρκής για τη δημιουργία κατηγοριοποιητών με ακρίβεια που ξεπερνάει το 98%, και γι' αυτό προτιμήθηκε για την επίδειξη των αποτελεσμάτων.

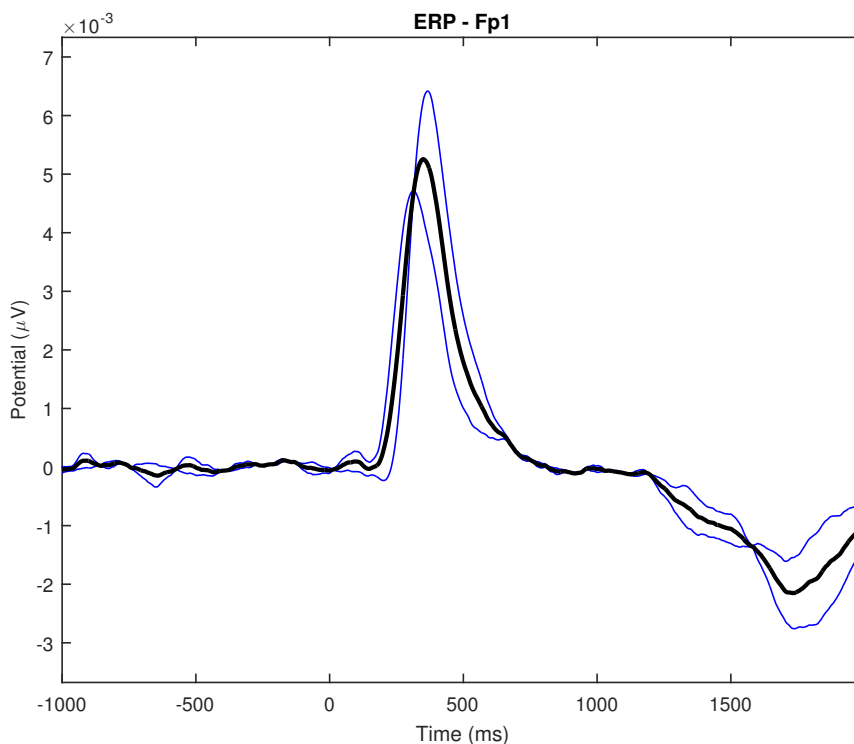


Σχήμα 6.4: Η ERP Image για το κανάλι Fp1 με τις 220 εποχές που προέκυψαν από τις πειραματικές μετρήσεις.

6.4 Αποτελέσματα και συμπεράσματα

Πρακάτω παρουσιάζονται τα αποτελέσματα των πειραματικών μετρήσεων. Ως δεδομένα εκπαίδευσης επιλέχθηκαν τυχαία το 30% των εποχών, ενώ τα υπόλοιπα χρησιμοποιήθηκαν για τη δοκιμή των κατηγοριοποιητών. Κατά την κατηγοριοποίηση δοκιμάστηκε πλήθος μοντέλων, όπως η μέθοδος του τυχαίου δάσους (Random Forest - RF) [33] και του Naive Bayes classifier, καθώς και τα νευρωνικά δίκτυα. Η μέθοδος RF βασίζεται στη δημιουργία ενός πλήθους από δένδρα απόφασης (Decision Trees), τα οποία χρησιμοποιούνται για την κατηγοριοποίηση. Ο κατηγοριοποιητής Naive Bayes ανήκει σε μία κατηγορία απλών πιθανοτικών ταξινομητών που βασίζονται στο θεώρημα του Bayes με ισχυρές (naive) υποθέσεις για τα χαρακτηριστικά, και χρησιμοποιείται σε πλήθος περιπτώσεων στη μηχανική μάθηση ακόμα και σήμερα [32]. Στα σχήματα που παρουσιάζονται σε αυτή την υποενότητα συγκρίνονται τρία είδη κατηγοριοποιητών για τα δεδομένα δοκιμής, χρησιμοποιώντας ως χαρακτηριστικά αυτούσια τη χρονική σειρά του σήματος. Στον άξονα y βρίσκεται η έξοδος του κατηγοριοποιητή 0 ή 1, και στον άξονα x είναι ο αριθμός των χρονικών παραθύρων στα οποία χωρίζεται στο σήμα. Με κόκκινο χρώμα σημειώνεται η πραγματική έξοδος των κατηγοριοποιητών, ενώ με μπλε η ιδανική έξοδος.

Όπως διακρίνεται και στα αποτελέσματα στα σχήματα 6.6, 6.7 και 6.8 όλοι οι κατηγοριοποιητές παρουσιάζουν υψηλά ποσοστά ακρίβειας. Την καλύτερη επίδοση, όμως, παρουσιάζει το νευρωνικό δίκτυο, αφού σε όλες τις προσπάθειες κατάφερε να επιτύχει σταθερά ποσοστό μεγαλύτερο του 98%. Οι υπόλοιποι δύο κατηγοριοποιητές, αν και παρουσίασαν επίσης πολύ υ-




Σχήμα 6.5: Η μέση δραστηριότητα ERP όλων των εποχών για όλους χρήστες (κανάλι Fp1).


ψηλά ποσοστά ακρίβειας, παρουσιάζουν πολλές φορές εσφαλμένη θετική έξοδο (false positive) σε διαδοχικά παράθυρα, με αποτέλεσμα να μη μπορούν να χρησιμοποιηθούν στο σύστημα.

	<i>Accuracy</i>	<i>Specificity</i>	<i>Sensitivity</i>
Random Forest	0.9917	0.9957	0.9130
Neural Network	0.9924	0.9970	0.9131
Naive Bayes	0.9615	0.9600	0.9855


Πίνακας 6.1: Σύγκριση των μεθόδων μεταξύ των τριών κατηγοριοποιητών.



Σχήμα 6.6: Η έξοδος ενός Naive Bayes κατηγοριοποιητή για τα δεδομένα δοκιμής.



Σχήμα 6.7: Η έξοδος ενός Random Forest κατηγοριοποιητή για τα δεδομένα δοκιμής.




Σχήμα 6.8: Η έξοδος ενός Τεχνητού Νευρωνικού δικτύου για τα δεδομένα δοκιμής.

Κεφάλαιο 7


Επίλογος

7.1 Τελικό πείραμα

Στην παρούσα υποενότητα παρουσιάζεται το πείραμα πραγματικού χρόνου για την επιβεβαίωση της ορθής λειτουργίας του μοντέλου ανίχνευσης του κλείσιμου των βλεφάρων που περιγράφηκε νωρίτερα στο κεφάλαιο 6. Κατά το τελικό πείραμα, ο χρήστης τοποθετείται σε ένα κάθισμα μπροστά από ένα γραφείο. Πάνω στο γραφείο υπάρχει το ρομποτικό χέρι της εικόνας 3.4 το οποίο ελέγχεται με έναν μικροελεγκτή Arduino μέσα από το πρόγραμμα ROS. Όταν ο χρήστης κλείσει για ένα μικρό διάστημα τα μάτια του, τότε το ρομποτικό χέρι κλείνει τη λαβή και ακούγεται ένας χαρακτηριστικός ήχος επιβεβαίωσης. Για το άνοιγμα της λαβής ο χρήστης καλείται απλώς να ξανακλείσει τα μάτια του με τον ίδιο τρόπο. Στο ενδιάμεσο, μπορεί με άνεση να κουνάει τα μάτια ή να βλεφαρίζει χωρίς να επηρεάσει την κατάσταση του χεριού. Οι διαδικασίες φαίνονται στα παρακάτω σχήματα.



Σχήμα 7.1: Στιγμιότυπο 1 του πειράματος



Σχήμα 7.2: Στιγμιότυπο 2 του πειράματος



Σχήμα 7.3: Στιγμιότυπο 3 του πειράματος

7.2 Συμπεράσματα

Στην παρούσα εργασία περιγράφεται η δημιουργία μίας νέας μορφής διασύνδεσης εγκεφάλου-υπολογιστή (Brain-Computer Interface) για την άμεση και εύκολη επικοινωνία ανθρώπου-ρομπότ. Στόχος είναι η συνεχής αποκωδικοποίηση της κίνησης των ματιών σε κίνηση ενός ρομποτικού βραχίονα, με σκοπό το άδραγμα ενός αντικειμένου. Η επιθυμητή τροχιά του

βραχίονα καθορίζεται από βιο-σήματα που σχετίζονται με την κίνηση των ματιών και καταγράφονται από πραγματικούς χρήστες μέσω της μεθόδου της Ηλεκτροεγκεφαλογραφίας. Στο προτεινόμενο σύστημα, χρησιμοποιείται, επιπλέον, ένα μοντέλο ακινητοποίησης του τελικού σημείου δράσης του ρομποτικού βραχίονα, ώστε να επιτευχθεί ευκολότερα το άδραγμα. Ακόμα, προτείνεται ένας εύκολος τρόπος εκδήλωσης της επιθυμίας του χρήστη για άδραγμα με υψηλή ακρίβεια ανίχνευσης. Ένα τέτοιο σύστημα μπορεί να χρησιμοποιηθεί από άτομα με απώλεια κίνησης στα άνω άκρα ή παράλυση. Μπορεί, ιδανικά, να χρησιμοποιηθεί και στο μέλλον για την ταχύτερη αλληλεπίδραση υγιών ανθρώπων με το περιβάλλον τους, χωρίς την χρήση φωνητικών εντολών ή μοχλών.

Η αποκωδικοποίηση της κίνησης παρουσιάζει ιδιαίτερο ενδιαφέρον, αφού φαινομενικά δίνεται η δυνατότητα τρισδιάστατης αποκωδικοποίησης κίνησης. Αν και τα αποτελέσματα είναι ενθαρρυντικά, η χρήση της προτεινόμενης μεθοδολογίας έχει αρκετές ελλείψεις, οι οποίες φαίνονται κυρίως με τη χρήση διαφορετικών χρηστών. Σε αυτές τις περιπτώσεις το σύστημα αποκωδικοποίησης αδυνατεί να δώσει επαρκή αποτελέσματα, και άρα φαίνεται να υπάρχει πρόβλημα γενίκευσης. Επιπλέον, το είδος της τροχιάς της κίνησης φαίνεται να επηρεάζει κατά πολύ τα αποτελέσματα της αποκωδικοποίησης, ιδιαίτερα όταν πρόκειται για μη συνεχείς κινήσεις. Φαίνεται, ακόμα, να υπάρχει πρόβλημα όσον αφορά το σημείο εστίασης των ματιών κατά την αποκωδικοποίηση της συντεταγμένης βάθους, κάτι το οποίο μπορεί να ξεπεραστεί με την εισαγωγή ενός αυτόνομου συστήματος εντοπισμού αντικειμένων. Γενικά, ο αυστηρός καθορισμός της τροχιάς κίνησης προκαλεί κόπωση στους χρήστες έπειτα από κάποιο χρονικό διάστημα, με αποτέλεσμα να μην μπορούν να συνεχίσουν τη διαδικασία για πολύ ώρα.

Όσον αφορά το μοντέλο ακινητοποίησης του ρομποτικού χεριού, βασίζεται κατά κύριο λόγο στην αποκωδικοποίηση. Η επεξεργασία των σημάτων φαίνεται να είναι επαρκής για τον κατηγοριοποιητή. Ο τρόπος υπολογισμού των βαρών εισάγει μια μικρή καθυστέρηση που θεωρητικά δε θα πρέπει να εμποδίζει σε εφαρμογές πραγματικού χρόνου.

Τέλος, η μέθοδος του κλείσιμου των ματιών ως σύμβαση για την εκδήλωση της πρόθεσης για άδραγμα, δίνει ενθαρρυντικά αποτελέσματα, όπως φαίνεται και από τα πειράματα που έγιναν σε πραγματικό χρόνο. Η καθυστέρηση που εισάγεται είναι η μικρότερη δυνατή και δε ξεπερνά τα 0.3 δευτερόλεπτα. Τα ποσοστά ακρίβειας της ανίχνευσης αγγίζουν το 99% σε όλες τις περιπτώσεις, και ο κατηγοριοποιητής ξεχωρίζει εύκολα το βλεφάρισμα από το κλείσιμο των ματιών. Πρέπει, επίσης, να σημειωθεί ότι στο τελικό σύστημα το κλείσιμο των ματιών θεωρητικά δεν επηρεάζει την αποκωδικοποίηση. Η αποκωδικοποίηση στηρίζεται σε σήματα που έχουν διαφορετική προέλευση (κίνηση ματιών) από το κλείσιμο των βλεφάρων (κίνηση μυών των βλεφάρων) και γίνεται επεξεργασία σε διαφορετικές συχνότητες. Αυτό επιβεβαιώνεται και σε μετρήσεις που έγιναν, που φαίνεται ότι το βλεφάρισμα αγνοείται στην αποκωδικοποίηση.

7.3 Μελλοντικές επεκτάσεις

Το σύστημα που παρουσιάστηκε μπορεί να βελτιωθεί σε πολλούς τομείς, είτε προσθέτοντας επιπρόσθετα στοιχεία σε αυτό, είτε βελτιώνοντας τα υπάρχοντα. Αρχικά, απαιτείται περαιτέρω διερεύνηση όσον αφορά την επεξεργασία των ΗΕΓ σημάτων και την επιλογή των

χαρακτηριστικών για αποκωδικοποίηση. Μία ιδέα, που στηρίζεται στην πρόσφατη εργασία του Schirrmeister et al. [50], χρησιμοποιεί συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Networks) για την αυτόματη προεπεξεργασία των δεδομένων και εξαγωγή χαρακτηριστικών που χρησιμοποιούνται για την αποκωδικοποίηση. Κάτι τέτοιο θα έλυne το πρόβλημα που υπάρχει στη γενίκευση, αφού μπορεί να εισαχθεί ως στάδιο εκπαίδευσης κάθε φορά που αλλάζει ο χρήστης.

Επιπλέον, για τον καλύτερο εντοπισμό του αντικειμένου ή του τελικού σημείου δράσης, μπορεί να χρησιμοποιηθεί ένα αυτόματο σύστημα εντοπισμού με κάμερες ή tracker θέσης. Σε τέτοια περίπτωση, ο χρήστης μπορεί απλώς να καθορίζει το επιθυμητό αντικείμενο απλώς κοιτώντας το αρχικά με τα μάτια. Φαίνεται, ότι ο απόλυτος καθορισμός της τροχιάς δεν είναι πάντοτε απαραίτητος, αφού κάτι τέτοιο μπορεί να το αναλάβει μια αυτόματη διαδικασία. Στόχος, επομένως, είναι η δημιουργία ενός ημι-αυτόνομου συστήματος κοινού ελέγχου (shared control) μεταξύ ανθρώπου-ρομπότ, κατά το οποίο ο άνθρωπος μπορεί να επεμβαίνει ώστε να αναλαμβάνει το χειροκίνητο χειρισμό (manual tele-operation) του ρομπότ σε περιπτώσεις που το αυτόματο σύστημα αδυνατεί. Μπορεί, επιπλέον, να επεμβαίνει ώστε να καθορίζει μια τροχιά με χονδροειδή τρόπο, ώστε να μπορεί να αποφεύγεται κάποιο ενδιάμεσο εμπόδιο που δεν έχει μπορέσει να αντιληφθεί το αυτόματο σύστημα. Υποθετικά, κάτι τέτοιο μπορεί να γίνει με τη χρήση δυναμικών λάθους ή αλλιώς Error Potentials τα οποία δημιουργούνται σε περίπτωση που ο χρήστης αντιληφθεί ότι υπάρχει κάποιο σφάλμα.

Τέλος, σε περίπτωση που τα μαλακά ρομποτικά χέρια δεν μπορούν να αδράξουν σωστά ένα αντικείμενο, μπορεί να χρησιμοποιηθεί τοπική κάμερα τοποθετημένη στο τελικό σημείο δράσης για visual servoing και τον καθορισμό του κατάλληλου configuration για άδραγμα.

Γλωσσάριο

Ελληνικός όρος

αβεβαιότητα
άδραγμα
αθροιστική πυκνότητα πιθανότητας
ακρίβεια
αλληλεπίδραση ανθρώπου μηχανής
αναγνώριση προτύπων
αναδειγματοληψία
ανάδραση
ανεξάρτητες συνιστώσες
ανίχνευση
αποδεκατισμός
αποκωδικοποίηση
αποσύνθεση ιδιοτιμών
άρθρωση
αυτο-παλίνδρομο μοντέλο
βαθμός ελευθερίας
βάρος
βιοσήματα
βλεφάρισμα
δεδομένα δοκιμής
δεδομένα εκπαίδευσης
δειγματοληψία
δεικτοδότηση
διακύμανση
διαστατικότητα
Διασύνδεση Ανθρώπου Μηχανής
διάταξη
διαφόριση
διαχωρισμός αγνώστων πηγών
Διεπαφή Εγχεφάλου-Υπολογιστή
διεργασία

Αγγλικός όρος

uncertainty
grasping
cumulative density function
accuracy
human-machine interaction
pattern recognition
resampling
feedback
independent components
detection
decimation
decoding
singular value decomposition
joint
auto-regressive model
degree of freedom
weight
bio-signals
blinking
testing data
training data
sampling
indexing
variance
dimensionality
Human-Machine Interface
configuration
differentiation
blind source separation
Brain-Computer Interface
task

διόρθωση βάσης	baseline correction
δυναμικό	potential
δυναμικό συμβάντος	event-related potential
δυναμικό σφάλματος	error potential
εγκεφαλικό φλοιός	cerebral cortex
ειδίκευση	specificity
ενδοτεταρτημοριακός μέσος	interquartile mean
εκτιμητής μέγιστης πιθανοφάνειας	maximum likelihood estimator
εξαγωγή χαρακτηριστικών	features extraction
εξίσωση διαφορών	difference equation
εμπρόσθιος λοβός	frontal lobe
ενισχυτική μάθηση	reinforcement learning
επεξεργασία	processing
επιβλεπόμενη μάθηση	supervised learning
ευαισθησία	sensitivity
ευριστικός	heuristic
ηλεκτρόδιο	electrode
ηλεκτροεγκεφαλογραφία	electroencephalography
ιδιομορφία	singularity
νιακός λοβός	occipital lobe
καθυστέρηση φάσης	phase delay
κανάλι	channel
κατηγοριοποιητής	classifier
κβάντιση	quantization
κλίμακα	scale
κινηματική αλυσίδα	kinematic chain
κρανίο	scalp
λόγος απόρριψης κοινού σήματος	common mode rejection ratio
μέσο διασύνδεσης	interface
μετασυναπτικό δυναμικό	post-synaptic potential
μετωπιαίος λοβός	frontal lobe
μη επιβλεπόμενη μάθηση	unsupervised learning
μη επιθυμητό σήμα	artifact
μηχανή διανυσμάτων υποστήριξης	support vector machines
μηχανική μάθηση	machine Learning
μοντελο μεταβλητών κατάστασης	state space model
νευρο-ρομποτική	neuro-robotics
νευρώνας	neuron
νευρωνική δραστηριότητα	neural activity
ορθογωνικός	orthogonal
οπτική επιθεώρηση	visual inspection

παλινδρόμηση	regression
παράθυρο	window
πολυστρωματικό επίπεδο νευρώνων	multilayer perceptron
πυρήνας	kernel
ρίζα μέσου τετραγωνικού σφάλματος	root-mean squared error
ρομποτικός βραχίονας	robotic arm
σημείο δράσης	end effector
σταθερότητα	steadiness
συνάρτηση μεταφοράς	transfer function
συνάρτηση πυκνότητας πιθανότητας	probability density function
συνελικτικό νευρωνικό δίκτυο	convolutional neural net
συνιστώσα	component
συντελεστής συσχέτισης	correlation coefficient
συσχέτιση	correlation
τεχνητή νοημοσύνη	artificial intelligence
τεχνητό νευρωνικό δίκτυο	artificial neural network
τηλε-χειρισμός	tele-operation
τυχαίο δάσος	random forest
υβριδικός	hybrid
υπερ-επίπεδο	hyper-plane
φάσμα	spectrum
φασματικός χάρτης	spectral map
χρήστης	subject
φασματική πυκνότητα ισχύος	power spectral density
ψηφιακή επεξεργασία σήματος	digital signal processing
ψηφιακό φίλτρο	digital filter

Bibliography

- [1] S. M. Abdelfattah, K. E. Merrick, and H. A. Abbass. Eye movements as information markers in eeg data. In *Computational Intelligence (SSCI), 2016 IEEE Symposium Series on*, pages 1–7. IEEE, 2016.
- [2] M. Alipoor, M. Pooyan, and A. A. Suratgar. Classification of eeg signals in four groups, including healthy subjects with open/closed eyes and epilepsy subjects with/without seizure by psd estimate (using the multitaper method) and ann. In *Health Informatics and Bioinformatics (HIBIT), 2010 5th International Symposium on*, pages 98–103. IEEE, 2010.
- [3] E. Alpaydin. *Introduction to machine learning*. MIT press, 2014.
- [4] P. Artemiadis. *Neuro-Robotics: From Brain Machine Interfaces to Rehabilitation Robotics*. Springer Publishing Company, Incorporated, 2016.
- [5] A. J. Bell and T. J. Sejnowski. An information-maximization approach to blind separation and blind deconvolution. *Neural computation*, 7(6):1129–1159, 1995.
- [6] H. Berger. Über das elektrenkephalogramm des menschen. *European Archives of Psychiatry and Clinical Neuroscience*, 87(1):527–570, 1929.
- [7] S. Bhattacharyya, A. Konar, and D. Tibarewala. Motor imagery, p300 and error-related eeg-based robot arm movement control for rehabilitation purpose. *Medical & biological engineering & computing*, 52(12):1007–1017, 2014.
- [8] C. M. Bishop. *Pattern recognition and machine learning*. springer, 2006.
- [9] S. Bozinovski, M. Sestakov, and L. Bozinovska. Using eeg alpha rhythm to control a mobile robot. In *Engineering in Medicine and Biology Society, 1988. Proceedings of the Annual International Conference of the IEEE*, pages 1515–1516. IEEE, 1988.
- [10] J. Britton, L. Frey, J. Hopp, P. Korb, M. Koubeissi, W. Lievens, E. Pestana-Knight, and L. E. St. Electroencephalography (eeg): An introductory text and atlas of normal and abnormal findings in adults, children, and infants. 2016.
- [11] J. M. Carmena, M. A. Lebedev, R. E. Crist, J. E. O’Doherty, D. M. Santucci, D. F. Dimitrov, P. G. Patil, C. S. Henriquez, and M. A. Nicolelis. Learning to control

- a brain-machine interface for reaching and grasping by primates. *PLoS biology*, 1(2):e42, 2003.
- [12] B. Chambayil, R. Singla, and R. Jha. Eeg eye blink classification using neural network. In *Proceedings of the World Congress on Engineering*, volume 1, pages 2–5, 2010.
- [13] P. Comon. Independent component analysis, a new concept? *Signal processing*, 36(3):287–314, 1994.
- [14] C. Cortes and V. Vapnik. Support-vector networks. *Machine learning*, 20(3):273–297, 1995.
- [15] A. Delorme and S. Makeig. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of neuroscience methods*, 134(1):9–21, 2004.
- [16] H. B. Demuth, M. H. Beale, O. De Jess, and M. T. Hagan. *Neural network design*. Martin Hagan, 2014.
- [17] S. R. Eddy. Hidden markov models. *Current opinion in structural biology*, 6(3):361–365, 1996.
- [18] R. Galambos and S. Makeig. Dynamic changes in steady-state responses. *Springer series in brain dynamics*, 1:103–122, 1988.
- [19] R. García-Hernández, E. N. Sanchez, V. Santibáñez, and J. Ruz-Hernandez. Decentralized neural block control for an industrial pa10-7ce robot arm. In *Neural Networks (IJCNN), The 2011 International Joint Conference on*, pages 2787–2794. IEEE, 2011.
- [20] P. V. Golden. Low noise, low power instrumentation amplifier, Feb. 1 2011. US Patent 7,880,541.
- [21] R. S. Hartenberg and J. Denavit. *Kinematic synthesis of linkages*. McGraw-Hill, 1964.
- [22] S. Haykin. *Neural networks: a comprehensive foundation*. Prentice Hall PTR, 1994.
- [23] H. H. JASPER and H. L. Andrews. Electro-encephalography: Iii. normal differentiation of occipital and precentral regions in man. *Archives of Neurology & Psychiatry*, 39(1):96–115, 1938.
- [24] T.-P. Jung, S. Makeig, C. Humphries, T.-W. Lee, M. J. Mckeown, V. Iragui, and T. J. Sejnowski. Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(2):163–178, 2000.
- [25] E. Kaniusas. *Biomedical signals and sensors I: Linking physiological phenomena and biosignals*. Springer Science & Business Media, 2012.

- [26] S. Kanoga, M. Nakanishi, and Y. Mitsukura. Assessing the effects of voluntary and involuntary eyeblinks in independent components of electroencephalogram. *Neurocomputing*, 193:20–32, 2016.
- [27] C. A. Klein and C.-H. Huang. Review of pseudoinverse control for use with kinematically redundant manipulators. *IEEE Transactions on Systems, Man, and Cybernetics*, (2):245–250, 1983.
- [28] D. Koller and N. Friedman. *Probabilistic graphical models: principles and techniques*. MIT press, 2009.
- [29] G. P. Kontoudis, M. V. Liarokapis, A. G. Zisimatos, C. I. Mavrogiannis, and K. J. Kyriakopoulos. Open-source, anthropomorphic, underactuated robot hands with a selectively lockable differential mechanism: Towards affordable prostheses. In *Intelligent Robots and Systems (IROS), 2015 IEEE/RSJ International Conference on*, pages 5857–5862. IEEE, 2015.
- [30] R. Lamothe and G. Stroink. Orthogonal expansions: Their applicability to signal extraction in electrophysiological mapping data. *Medical and Biological Engineering and Computing*, 29(5):522–528, 1991.
- [31] V. Lawhern, W. D. Hairston, K. McDowell, M. Westerfield, and K. Robbins. Detection and classification of subject-generated artifacts in eeg signals using autoregressive models. *Journal of neuroscience methods*, 208(2):181–189, 2012.
- [32] D. D. Lewis. Naive (bayes) at forty: The independence assumption in information retrieval. In *European conference on machine learning*, pages 4–15. Springer, 1998.
- [33] A. Liaw, M. Wiener, et al. Classification and regression by randomforest. *R news*, 2(3):18–22, 2002.
- [34] S. Makeig, A. J. Bell, T.-P. Jung, and T. J. Sejnowski. Independent component analysis of electroencephalographic data. In *Advances in neural information processing systems*, pages 145–151, 1996.
- [35] C. Mavridis. Electroencephalography and electromyography signals in neuro-robotic systems. Bachelor thesis, National Technical University of Athens, March 2017.
- [36] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [37] D. J. McFarland and J. R. Wolpaw. Brain-computer interfaces for communication and control. *Communications of the ACM*, 54(5):60–66, 2011.
- [38] J. L. McKinstry, G. M. Edelman, and J. L. Krichmar. A cerebellar model for predictive motor control tested in a brain-based device. *Proceedings of the National Academy of Sciences of the United States of America*, 103(9):3387–3392, 2006.

- [39] H. Miyamoto, M. Kawato, T. Setoyama, and R. Suzuki. Feedback-error-learning neural network for trajectory control of a robotic manipulator. *Neural networks*, 1(3):251–265, 1988.
- [40] J. J. Moré. The levenberg-marquardt algorithm: implementation and theory. In *Numerical analysis*, pages 105–116. Springer, 1978.
- [41] K. Muelling, A. Venkatraman, J.-S. Valois, J. E. Downey, J. Weiss, S. Javdani, M. Hebert, A. B. Schwartz, J. L. Collinger, and J. A. Bagnell. Autonomy infused teleoperation with application to brain computer interface controlled manipulation. *Autonomous Robots*, pages 1–22, 2017.
- [42] N. M. Nasrabadi. Pattern recognition and machine learning. *Journal of electronic imaging*, 16(4):049901, 2007.
- [43] E. Niedermeyer and F. L. da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins, 2005.
- [44] K. Pearson. Liii. on lines and planes of closest fit to systems of points in space. *The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science*, 2(11):559–572, 1901.
- [45] J. G. Proakis and D. G. Manolakis. Digital signal processing 3 rd edition, 1996.
- [46] R. Ramli, H. Arof, F. Ibrahim, M. Y. I. Idris, and A. Khairuddin. Classification of eyelid position and eyeball movement using eeg signals. *Malaysian Journal of Computer Science*, 28(1), 2015.
- [47] M. B. I. Reaz, M. Hussain, and F. Mohd-Yasin. Techniques of emg signal analysis: detection, processing, classification and applications. *Biological procedures online*, 8(1):11, 2006.
- [48] A. F. Salazar-Gomez, J. DelPreto, S. Gil, F. H. Guenther, and D. Rus. Correcting robot mistakes in real time using eeg signals. *ICRA. IEEE*, 2017.
- [49] S. Sanei and J. A. Chambers. *EEG signal processing*. John Wiley & Sons, 2013.
- [50] R. T. Schirrmeister, J. T. Springenberg, L. D. J. Fiederer, M. Glasstetter, K. Eggenberger, M. Tangermann, F. Hutter, W. Burgard, and T. Ball. Deep learning with convolutional neural networks for brain mapping and decoding of movement-related information from the human eeg. *arXiv preprint arXiv:1703.05051*, 2017.
- [51] W. Schultz, P. Dayan, and P. R. Montague. A neural substrate of prediction and reward. *Science*, 275(5306):1593–1599, 1997.
- [52] L. Sciavicco and B. Siciliano. *Modelling and control of robot manipulators*. Springer Science & Business Media, 2012.

-
- [53] B. Siciliano, L. Sciavicco, L. Villani, and G. Oriolo. *Introduction*. Springer, 2009.
- [54] B. Siciliano, L. Sciavicco, L. Villani, and G. Oriolo. *Kinematics*. Springer, 2009.
- [55] P. L. Silbert, K. Radhakrishnan, J. Johnson, and D. W. Klass. The significance of the phi rhythm. *Electroencephalography and clinical Neurophysiology*, 95(2):71–76, 1995.
- [56] M. A. Sovierzoski, F. I. Argoud, and F. M. de Azevedo. Identifying eye blinks in eeg signal analysis. In *Information Technology and Applications in Biomedicine, 2008. ITAB 2008. International Conference on*, pages 406–409. IEEE, 2008.
- [57] M. Sterman, L. MacDonald, and R. K. Stone. Biofeedback training of the sensorimotor electroencephalogram rhythm in man: effects on epilepsy. *Epilepsia*, 15(3):395–416, 1974.
- [58] C. Stevenson, T.-P. Jung, and G. Cauwenberghs. Estimating direction and depth of visual fixation using electrooculography. In *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, pages 841–844. IEEE, 2015.
- [59] R. S. Sutton and A. G. Barto. *Reinforcement learning: An introduction*, volume 1. MIT press Cambridge, 1998.
- [60] M. N. Tibdewal, R. R. Fate, M. Mahadevappa, A. K. Ray, and M. Malokar. Classification of artifactual eeg signal and detection of multiple eye movement artifact zones using novel time-amplitude algorithm. *Signal, Image and Video Processing*, 11(2):333–340, 2017.
- [61] S. Weisberg. *Applied linear regression*, volume 528. John Wiley & Sons, 2005.
- [62] J. R. Wolpaw and D. J. McFarland. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, 101(51):17849–17854, 2004.

