



Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών

Τομέας Συστημάτων Μετάδοσης Πληροφορίας και
Τεχνολογίας Υλικών

**ERP Classification of fatigue states in multiple cognitive
experiments**

**Ταξινόμηση προκλητών δυναμικών καταστάσεων κόπωσης
σε διαφορετικά γνωσιακά πειράματα**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΔΑΝΙΗΛ Β. ΧΡΙΣΤΟΔΟΥΛΟΠΟΥΛΟΣ

Επιβλέπων : Γεώργιος Ματσόπουλος
Καθηγητής Ε.Μ.Π.

Αθήνα, Νοέμβριος 2020



Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών
και Μηχανικών Υπολογιστών

Τομέας Συστημάτων Μετάδοσης Πληροφορίας και
Τεχνολογίας Υλικών

ERP Classification of fatigue states in multiple cognitive experiments

Ταξινόμηση προκλητών δυναμικών καταστάσεων κόπωσης
σε διαφορετικά γνωσιακά πειράματα

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΔΑΝΙΗΛ Β. ΧΡΙΣΤΟΔΟΥΛΟΠΟΥΛΟΣ

Επιβλέπων : Γεώργιος Ματσόπουλος
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 2η Νοεμβρίου 2020.

.....
Γεώργιος Ματσόπουλος
Καθηγητής Ε.Μ.Π.

.....
Δημήτριος-Διονύσιος Κουτσούρης
Καθηγητής Ε.Μ.Π.

.....
Παναγιώτης Τσανάκας
Καθηγητής Ε.Μ.Π.

Αθήνα, Νοέμβριος 2020

.....
Δανιήλ Β. Χριστοδουλόπουλος

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

Copyright © Δανιήλ Β. Χριστοδουλόπουλος, 2020.
Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Στην παρούσα εργασία μελετήθηκε η νοητική κόπωση και παρακολούθηθηκαν οι καταστάσεις του εγκεφάλου σε διάφορες γνωστικές εργασίες συνεχούς απόδοσης λειτουργικής μνήμης, συγκεκριμένα χωροχρονικό N-Back και Ακουστική Δοκιμασία Σειριακής Πρόσθεσης (PASAT).

Αρχικά στα πρώτα τρία κεφάλαια εισάγουμε βασικές και θεμελιώδεις έννοιες για τον ανθρώπινο εγκέφαλο, το ηλεκτροεγκεφαλογράφημα και το μαθηματικό υπόβαθρο που χρειάστηκαν για την εκπόνηση της διπλωματικής εργασίας καθώς παρουσιάζονται αναλυτικά μέθοδοι, αλγόριθμοι και εργαλεία που χρειάστηκαν προκειμένου να αναλυθούν όλα τα πειραματικά δεδομένα.

Για αυτή την μελέτη αρχικά χρειάστηκε να χρησιμοποιηθούν μέθοδοι εκτίμησης της φασματική πυκνότητας ισχύος δημιουργήθηκαν μοντέλα ταξινόμησης με χαρακτηριστικά αυτές τις φασματικές πυκνότητες ισχύος στις 5 μπάντες, δέλτα, θήτα, άλφα, βήτα, γάμμα εφαρμόζοντας αρχικά αλγόριθμους Επιλογής Χαρακτηριστικών.

Η παρούσα εργασία περιλαμβάνει Ηλεκτροεγκεφαλικές καταγραφές με χρήση ηλεκτροεγκεφαλογραφήματος (HEΓ) κατά την εκτέλεση νοητικών εργασιών σε καταστάσεις νοητικής κόπωσης των γιατρών και νοσηλευτικού προσωπικού του 401 Γενικού Στρατιωτικού Νοσοκομείου Αθηνών, λόγω στέρησης ύπνου (εφημερία), σε συνεργασία με το Εργαστήριο Βιοϊατρικής Οπτικής και Εφαρμοσμένης Βιοφυσικής του Εθνικού Μετσόβιου Πολυτεχνείου.

Λέξεις κλειδιά

Ηλεκτροεγκεφαλογράφημα, HEΓ, Προκλητά δυναμικά, N-Back, Ακουστική Δοκιμασία Σειριακής Πρόσθεσης, Φασματική Πυκνότητα Ισχύος, Ταξινόμηση, γνωστική λειτουργία, νοητική κόπωση

Abstract

The present paper studies and monitors the mental fatigue the states of the brain in various cognitive tasks continuous performance of working memory, specifically N-Back and Paced Auditory Serial Addition Test (PASAT).

In the first three chapters we are introducing basic and fundamental terms for the human brain, the electroencephalograph and the student background that were needed for the elaboration of the thesis paper, as methods, algorithms and tools needed in order to analyze all the experimental data are presented in depth.

For this study initially used methods for estimating the density of the power spectral density, classification models were created with features those densities of the power in the 5 bands: delta, theta, alpha, beta, gamma by initially applying Feature Selection algorithms.

This paper includes Electroencephalic recordings using Electroencephalograph (EEG) during the execution of mental tasks in mentally exhausting situations by doctors and nursing staff of the 401 General Military Hospital of Athens, due to lack of sleep (on-call time), in association with the Laboratory of Biomedical Optics and Applied Biophysics of the National Technical University of Athens.

Key words

Electroencephalography, EEG, ERP, N-Back, PASAT, Power Spectral Density, Classification, cognitive, fatigue

Ευχαριστίες

Για την εκπόνηση αυτής της διπλωματικής εργασίας θα ήθελα να ευχαριστήσω ιδιαίτερα των επιβλέποντα καθηγητή κ. Γιώργο Ματσόπουλο για την ευκαιρία που μου έδωσε να ασχοληθώ με ένα τόσο ενδιαφέρον θέμα. Τέλος θα ήθελα να ευχαριστήσω θερμά την οικογένειά μου που με στήριξε όλα αυτά τα χρόνια και συνεχίζει να στηρίζει όλες μου τις προσπάθειες.

Δανιήλ Β. Χριστοδουλόπουλος,

Αθήνα, 2η Νοεμβρίου 2020

Περιεχόμενα

Περίληψη	5
Abstract	7
Ευχαριστίες	9
Περιεχόμενα	11
Κατάλογος πινάκων	13
Κατάλογος σχημάτων	15
1. Εισαγωγή	17
1.1 Ανθρώπινος Εγκέφαλος	17
1.2 Ανατομία του εγκεφάλου	17
1.3 Φυσιολογία Εγκεφάλου	17
2. Το Ηλεκτροεγκεφαλογράφημα (EEG)	21
2.1 Ιστορική Αναδρομή	21
2.2 Σημασία του Ηλεκτροεγκεφαλογράφου	21
2.3 Λειτουργία του ηλεκτροεγκεφαλογράφου	22
2.4 Προκλητά Δυναμικά - Event-Related Potentials	23
2.4.1 Προκλητά Δυναμικά και εξαγωγή από το Ηλεκτροεγκεφαλογράφημα	23
2.4.2 Μερικά χαρακτηριστικά παραδείγματα ERPs	26
3. Θεωρητικό Υπόβαθρο	29
3.1 Μηχανική Μάθηση	29
3.1.1 Εισαγωγή	29
3.1.2 Κατηγοριοποίηση προβλημάτων Μηχανικής Μάθησης και Εξόρυξης Δεδομένων	29
3.1.3 Ταξινόμηση	30
3.1.4 Ταξινομητής Support Vector Machine	31
3.1.5 Ταξινομητής K-Nearest Neighbor	35
3.2 Φασματική πυκνότητα ισχύος	37
3.2.1 Τα Βασικά Στοιχεία της Φασματικής Πυκνότητας Ισχύος	37
3.2.2 Η μη παραμετρική μέθοδος του Welch	40
4. Πειραματική Διαδικασία και Μεθοδολογία Επεξεργασίας και Ανάλυσης Δεδομένων	41
4.1 Βιβλιογραφική Ανασκόπηση	41
4.2 Πειραματική Διαδικασία και Μεθοδολογία Επεξεργασίας και Ανάλυσης Δεδομένων	42
4.2.1 Πειραματική Διαδικασία	42
4.2.2 Εξαγωγή Χαρακτηριστικών - Feature Extraction	46
4.2.3 Επιλογή χαρακτηριστικών και Ταξινόμηση	47

5. Παρουσίαση Αποτελεσμάτων	51
5.1 N-Back	51
5.2 PASAT	56
6. Συμπεράσματα	63
Βιβλιογραφία	65
Παράρτημα	71
A. Διαγράμματα Αποτελεσμάτων N-Back	71
B. Διαγράμματα Αποτελεσμάτων PASAT	81

Κατάλογος πινάκων

5.1	Πείραμα N-Back με Linear SVM για όλη τη χρονοσειρά	51
5.2	Πείραμα N-Back με KNN για όλη τη χρονοσειρά	51
5.3	Πείραμα N-Back με Linear SVM για όλη τη χρονοσειρά και Relatives PSD	52
5.4	Πείραμα N-Back KNN για όλη τη χρονοσειρά και Relatives PSD	52
5.5	Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms	52
5.6	Πείραμα N-Back KNN για το χρονικό παράθυρο 187.5 - 312.5 ms	52
5.7	Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 250 - 375 ms	53
5.8	Πείραμα N-Back KNN για το χρονικό παράθυρο 250 - 375 ms	53
5.9	Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 312,5 - 437,5 ms	53
5.10	Πείραμα N-Back KNN για το χρονικό παράθυρο 312,5 - 437,5 ms	53
5.11	Πείραμα N-Back LinearSVM για το χρονικό παράθυρο 375-500 ms	53
5.12	Πείραμα N-Back KNN για το χρονικό παράθυρο 375-500 ms	54
5.13	Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5-312.5 ms	54
5.14	Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 187.5-312.5 ms	54
5.15	Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 250-375 ms	55
5.16	Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 250-375 ms	55
5.17	Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms	55
5.18	Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms	55
5.19	Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 375-500 ms	56
5.20	Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 375-500 ms	56
5.21	Πείραμα PASAT Linear SVM για όλη τη χρονοσειρά	56
5.22	Πείραμα PASAT KNN για όλη τη χρονοσειρά	56
5.23	Πείραμα PASAT Linear SVM με Relatives PSD για όλη τη χρονοσειρά	56
5.24	Πείραμα PASAT KNN με Relatives PSD για όλη τη χρονοσειρά	57
5.25	Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms	57
5.26	Πείραμα PASAT KNN με για το χρονικό παράθυρο 187.5 - 312.5 ms	57
5.27	Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 250 - 375 ms	57
5.28	Πείραμα PASAT KNN για το χρονικό παράθυρο 250 - 375 ms	58
5.29	Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms	58
5.30	Πείραμα PASAT KNN για το χρονικό παράθυρο 312.5 - 437.5 ms	58
5.31	Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 375 - 500 ms	58
5.32	Πείραμα PASAT KNN για το χρονικό παράθυρο 375 - 500 ms	59
5.33	Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	59
5.34	Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	59
5.35	Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	60
5.36	Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	60
5.37	Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	60
5.38	Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	60

5.39	Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms	61
5.40	Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms . . .	61

Κατάλογος σχημάτων

1.1	Ανατομία του εγκεφάλου.	18
1.2	Δομή του νευρώνα.	19
1.3	Διαφορά δυναμικού εσωκυτταρικού - εξωκυτταρικού δυναμικού συναρτήσει του χρόνου σε ένα σημείο της μεμβράνης.	20
2.1	Ένα τυπικό ηλεκτροεγκεφαλογράφημα.	22
2.2	Τυποποιημένες απαγωγές στην επιφάνεια του κεφαλιού με το Σύστημα 10-20.	23
2.3	Παράδειγμα απόκρισης EEG ERP σε ηχητικά ερεθίσματα.	24
2.4	Ένα τυπικό μοντέλο καταγραφής EEG και ERPs που προκαλούνται από οπτικά ερεθίσματα. Στο δεξί μέρος της εικόνας παρουσιάζονται οι κυματομορφές και σημειώνονται οι κυριότερες κορυφές ενός ERP	25
3.1	Κατηγοριοποίηση Εξόρυξης Δεδομένων.	30
3.2	Υπερεπίπεδα διαχωρισμού. Το H_1 δεν διαχωρίζει τις δύο κατηγορίες. Το H_2 χωρίζει αλλά με πολύ μικρό περιθώριο μεταξύ των τάξεων και το H_3 χωρίζει τις δύο τάξεις με πολύ καλύτερο περιθώριο από το H_2	32
3.3	Παράδειγμα διαχωρισμού υπερεπιπέδου (σε δύο διαστάσεις), αποστάσεων και περιθωρίων.	33
3.4	(a) Ο κανόνας απόφασης 1-NN: το σημείο ? έχει ανατεθεί στην τάξη στα αριστερά. (b) ο κανόνας απόφασης kNN, με $k = 4$: το σημείο ? έχει ανατεθεί στην αριστερή τάξη επίσης	36
3.5	Παράδειγμα kNN για διάφορα k	37
4.1	PVT, Η απόκριση μετρείται συνεχώς, σημειώνοντας τον χρόνο αντίδρασης, τη συχνότητα που πατιέται το κουμπί, την καθυστέρηση και τις περιπτώσεις λανθασμένων απαντήσεων.	44
4.2	PVT, Η απόκριση μετρείται συνεχώς, σημειώνοντας τον χρόνο αντίδρασης, τη συχνότητα που πατιέται το κουμπί, την καθυστέρηση και τις περιπτώσεις λανθασμένων απαντήσεων.	45
4.3	Παράδειγμα εργασίας PASAT. Ο συμμετέχων καλείται να απαντήσει για το άθροισμα των δύο αριθμών που προηγήθηκαν.	45
4.4	Τοπολογία των ηλεκτροδίων που χρησιμοποιήθηκε	46
4.5	Το EEG ενός subject. Στον οριζόντιο άξονα φαίνονται οι χρονικές στιγμές και στον κατακόρυφο τα 63 ηλεκτρόδια με τις αντίστοιχες απαγωγές ανά χρονική στιγμή.	47
4.6	Ο αλγόριθμος υπολογισμού Φασματικής Πυκνότητας Ισχύος	47
4.7	Φασματική Πυκνότητας Ισχύος του ηλεκτροδίου Cz ανελυμένο στα 4Hz.	48
A.1	N-Back Linear SVM για όλη τη χρονοσειρά	71
A.2	N-Back KNN για όλη τη χρονοσειρά	71
A.3	N-Back Linear SVM με Relatives PSD για όλη τη χρονοσειρά	72
A.4	N-Back KNN με Relatives PSD για όλη τη χρονοσειρά	72
A.5	N-Back Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms	73
A.6	N-Back KNN για το χρονικό παράθυρο 187.5 - 312.5 ms	73

A.7	N-Back Linear SVM για το χρονικό παράθυρο 250 - 375 ms	74
A.8	N-Back KNN για το χρονικό παράθυρο 250 - 375 ms	74
A.9	N-Back Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms	75
A.10	N-Back KNN για το χρονικό παράθυρο 312.5 - 437.5 ms	75
A.11	N-Back Linear SVM για το χρονικό παράθυρο 375 - 500 ms	76
A.12	N-Back KNN για το χρονικό παράθυρο 375 - 500 ms	76
A.13	N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	77
A.14	N-Back KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	77
A.15	N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	78
A.16	N-Back KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	78
A.17	N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	79
A.18	N-Back KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	79
A.19	N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms	80
A.20	N-Back KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms	80
B.1	PASAT Linear SVM για όλη τη χρονοσειρά	81
B.2	PASAT KNN για όλη τη χρονοσειρά	81
B.3	PASAT Linear SVM με Relatives PSD για όλη τη χρονοσειρά	82
B.4	PASAT KNN με Relatives PSD για όλη τη χρονοσειρά	82
B.5	PASAT Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms	83
B.6	PASAT KNN για το χρονικό παράθυρο 187.5 - 312.5 ms	83
B.7	PASAT Linear SVM για το χρονικό παράθυρο 250 - 375 ms	84
B.8	PASAT KNN για το χρονικό παράθυρο 250 - 375 ms	84
B.9	PASAT Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms	85
B.10	PASAT KNN για το χρονικό παράθυρο 312.5 - 437.5 ms	85
B.11	PASAT Linear SVM για το χρονικό παράθυρο 375 - 500 ms	86
B.12	PASAT KNN για το χρονικό παράθυρο 375 - 500 ms	86
B.13	PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	87
B.14	PASAT KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms	87
B.15	PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	88
B.16	PASAT KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms	88
B.17	PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	89
B.18	PASAT KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms	89
B.19	PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms	90
B.20	PASAT KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms	90

Κεφάλαιο 1

Εισαγωγή

1.1 Ανθρώπινος Εγκέφαλος

Ο εγκέφαλος είναι το όργανο που ελέγχει όλες τις λειτουργίες του ανθρώπινου σώματος και αποτελεί το μεγαλύτερο όργανο του Κεντρικού Νευρικού Συστήματος (ΚΝΣ). Είναι υπεύθυνο δηλαδή για τις ζωτικές και νοητικές λειτουργίες του ανθρώπου, για τον έλεγχο των κινήσεων και επεξεργασία ερεθισμάτων από το περιβάλλον. Βρίσκεται στην κορυφή του σώματος και ζυγίζει περί τα 1,4-1,5 kg αποτελούμενος από 100×10^9 νευρώνες.

1.2 Ανατομία του εγκεφάλου

Ο εγκέφαλος βρίσκεται μέσα στο κρανίο, καλύπτεται από τις μήνιγγες που χρησιμεύουν στην προστασία από κρανιακά χτυπήματα και περιβάλλεται από το εγκεφαλονωτιαίο υγρό. Χωρίζεται σε τρία κύρια μέρη. Τον φλοιό (cerebrum), την παρεγκεφαλίδα (cerebellum) και το εγκεφαλικό στέλεχος (brainstem).


Ο εγκεφαλικός φλοιός αποτελείται από δύο ημισφαίρια, το δεξί και το αριστερό, όπου συνδέονται με μια δέσμη νευροαξόνων που ονομάζεται μεσολόβιο. Το αριστερό ημισφαίριο ελέγχει την ομιλία, αντίληψη, αριθμητική και γραφή. Ενώ το δεξί ημισφαίριο είναι υπεύθυνο για την χωρική αντίληψη, τις τέχνες και την κατανόηση συναισθημάτων. Κάθε ημισφαίριο χωρίζεται σε 4 λοβούς. Τον Μετωπιαίο λοβό (Frontal lobe), τον Βρεγματικό λοβό (Parietal lobe), τον Κροταφικό λοβό (Temporal lobe) και τον Ινιακό λοβό (Occipital lobe). Ο κάθε λοβός δεν λειτουργεί ανεξάρτητα αλλά υπάρχει αλληλεπίδραση μεταξύ των λοβών του ίδιου ημισφαιρίου αλλά και μεταξύ λοβών του δεξιού και αριστερού ημισφαιρίου.

Η παρεγκεφαλίδα βρίσκεται στο πίσω μέρος του εγκεφάλου και ο κύριος ρόλος της είναι να ρυθμίζει την κίνηση και την ισορροπία. Επίσης είναι υπεύθυνη και για κάποιες γνωστικές λειτουργίες όπως η γλώσσα.

Το εγκεφαλικό στέλεχος βρίσκεται στο κατώτερο μέρος του εγκεφάλου και αποτελείται από το νωτιαίο μυελό, το μυελό, την προεξοχή και τον μεσογέφαλο. Ελέγχει βασικές λειτουργίες του ανθρώπου συμπεριλαμβανομένου την ρύθμιση του καρδιακού παλμού, αναπνοής, ύπνου και φαγητού. Όλες οι πληροφορίες που μεταδίδονται από το σώμα στον εγκεφαλικό φλοιό ή στην παρεγκεφαλίδα και αντιστρόφως πρέπει να διασχίσουν το εγκεφαλικό στέλεχος [1].

1.3 Φυσιολογία Εγκεφάλου

Όπως αναφέραμε ο εγκέφαλος αποτελείται από περισσότερα από 100 τρισεκατομμύρια νευρώνες. Οι νευρώνες είναι βασικές δομικές και λειτουργικές μονάδες του νευρικού συστήματος και ο ρόλος



Σχήμα 1.1: Ανατομία του εγκεφάλου.

τους είναι να λαμβάνουν, επεξεργάζονται και να μεταδίδουν πληροφορίες μεταξύ διαφορετικών περιοχών του εγκεφάλου και στα υπόλοιπα μέρη του νευρικού συστήματος. Επίσης μια άλλη βασική δομή του εγκεφάλου είναι και τα νευρογλοία ή νευρογλοιακά κύτταρα που στόχο έχουν την δομική υποστήριξη των νευρώνων.

Οι νευρώνες χωρίζονται σε τρία βασικά μέρη:

1. Το κυτταρικό σώμα
2. Το νευράξονα
3. Τους δενδρίτες

1. Στο **κυτταρικό σώμα** βρίσκεται ο πυρήνας, που ελέγχει τις δραστηριότητες του κυττάρου και περιέχει το γενετικό του υλικό.

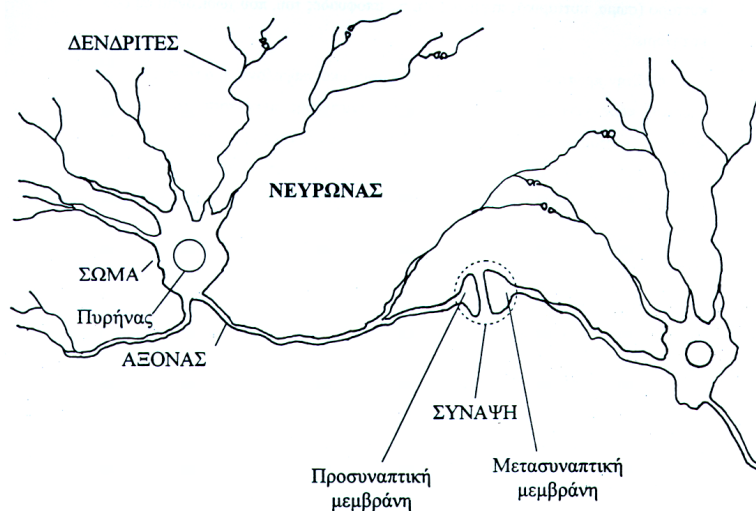
2. Ο **νευροάξονας** είναι μια νηματοειδής προέκταση που βγαίνει από το κυτταρικό σώμα και επιτελεί τον ρόλο της "εξόδου" του κυττάρου. Καταλήγει στην προσυναπτική μεμβράνη όπου βρίσκονται οι συνάψεις που αποτελούν μέσα επικοινωνίας με άλλους νευρώνες μέσω ηλεκτροχημικών ερεθισμάτων.

3. Οι **δενδρίτες** είναι νευρικές απολήξεις που βγαίνουν από το κυτταρικό σώμα και διακλαδίζονται με τη μορφή ενός δέντρου. Είναι τα στοιχεία που λαμβάνουν από τις συνάψεις τα ερεθίσματα, τα μεταφέρουν στο κυτταρικό σώμα και καθορίζουν εάν θα δημιουργηθούν δυναμικά δράσης.

Οι συνάψεις είναι τα σημεία που οι νευρώνες μεταβιβάζουν μεταξύ τους τις νευρικές ώσεις. Δεν είναι απαραίτητο οι νευρώνες να έρχονται σε άμεση επαφή καθώς η πληροφορία μπορεί να μεταφερθεί μέσω ηλεκτρικών ή χημικών διαδικασιών από μια λεπτή σχισμή που ονομάζεται συναπτικό χάσμα. Επιπλέον υπάρχουν διάφοροι τύποι συνάψεων ανάλογα με το σημεία που οι νευρώνες ακουμπάνε μεταξύ τους.

Οι νευρικές ώσεις ή νευρικά ερεθίσματα είναι σαν μια στιγμιαία ηλεκτρική δραστηριότητα που παράγεται στο νευρικό κύτταρο και διαδίδεται στον άξονά του. Για την ακρίβεια είναι η διαφορά τάσης που εμφανίζεται στην κυτταρική μεμβράνη του νευρώνα.

Η κυτταρική μεμβράνη αποτελείται από δύο στρώματα φωσφολιπιδίων, τα οποία έχουν υδρόφιλη κεφαλή και υδρόφοβο τμήμα μορίου. Η υδρόφιλη κεφαλή των μορίων έρχεται σε επαφή με το ενδοκυτταρικό υγρό και με την ύπαρξη πρωτεϊνών κάνει τη μεμβράνη ημιπερατή για ορισμένες ουσίες.



Σχήμα 1.2: Δομή του νευρώνα.

Οι πρωτεΐνες δηλαδή λειτουργούν ως διόδους ιόντων που χωρίζονται σε τρεις κατηγορίες. Τις διόδους ελεγχόμενες από τάση που εξαρτώνται από την τάση που επιβάλλεται διαμεμβρανικά, τις χημικά ελεγχόμενες διόδους που εξαρτώνται από την παρουσία χημικών ουσιών και χημικών φαινομένων και τις μη ελεγχόμενες διόδους που δεν ελέγχονται από εξωτερικές συνθήκες.


Έχει παρατηρηθεί ότι σε κατάσταση ηρεμίας κατά μήκος της μεμβράνης υπάρχει ένα δυναμικό που ονομάζεται δυναμικό ηρεμίας. Έχει εύρος τιμών -60 ως -100 mV και για νευρικά κύτταρα περί τα -70 mV. Αυτό προκαλείται από την άνιση κατανομή ιόντων αλλά το δυναμικό ηρεμίας δεν διατηρείται σταθερό αλλά εξαρτάται από τα ερεθίσματα που λαμβάνει ο νευροάξονας από τα άλλα νευρικά κύτταρα. Κατά κανόνα το εσωτερικό του κυττάρου έχει αρνητικό δυναμικό, ενώ το εξωτερικό έχει θετικό δυναμικό.

Εκτός από το δυναμικό ηρεμίας, συναντάμε άλλα δύο είδη δυναμικών. Το Δυναμικό Δράσης (Action Potential) και το Μετασυναπτικό Δυναμικό (Post Synaptic Potential).

Το **Δυναμικό Δράσης** είναι θεμελιώδης μονάδα επικοινωνίας μεταξύ των νευρών. Παράγεται στον νευροάξονα και καθιστά το κύτταρο ως "ενεργό". Ένα δυναμικό δράσης διαδίδεται κατά μήκος του άξονα και προκαλεί την απελευθέρωση των νευροδιαβιβαστών στη σύναψη. Ουσιαστικά δημιουργείται από το άθροισμα των νευρικών ερεθισμάτων που αναγκάζουν το δυναμικό της κυτταρικής μεμβράνης από την κατάσταση ηρεμίας να ξεπεράσει ένα **κατώφλι** των -50 mV και να συγκλίνει προς το 0. Αυτή η διαδικασία ονομάζεται **Αποπόλωση**. Το εσωτερικό του κυττάρου γίνεται όλο και πιο θετικό ώστε να φτάσει το δυναμικό να ισούται με τα $+30$ mV. Έπειτα έρχεται η φάση της **Επαναπόλωσης**, όπου το κύτταρο τείνει να έρθει σε κατάσταση ηρεμίας έως ότου το δυναμικό της μεμβράνης του κυττάρου να είναι πιο αρνητικό από το δυναμικό ηρεμίας που σημαίνει ότι ο νευρώνας είναι στην φάση της **Υπερπόλωσης**.

Όταν το δυναμικό δράσης ξεπεράσει την προσυναπτική μεμβράνη, προκαλεί την απελευθέρωση νευροδιαβιβαστών, την ενεργοποίηση του προσυναπτικού νευρώνα, την μετάδοση ερεθισμού μέσω του συναπτικού χάσματος, που σημαίνει ότι θα δημιουργηθεί ένα **Μετασυναπτικό Δυναμικό**. Υπάρχουν δύο είδη μετασυναπτικού δυναμικού, το **Διεγερτικό (EPSP)** και το **Ανασταλτικό (IPSP)**. Τόσο το EPSP όσο και το IPSP διαφέρουν από τα δυναμικά δράσης, δεδομένου ότι είναι αποκρίσεις με περιορισμένο χώρο και χαμηλότερη τιμή. Το μετασυναπτικό δυναμικό διέγερσης (EPSP), δημιουργεί αποπόλωση καθώς το εσωτερικό του κυττάρου φορτίζεται θετικά και το δυναμικό της μεμβράνης τείνει στο κατώφλι που προκαλεί το δυναμικό δράσης. Αντίθετα το μετασυναπτικό δυναμικό αναστολής

(IPSP), τείνει να διατηρεί το δυναμικό της μεμβράνης του μετασυναπτικού νευρώνα κάτω από αυτό το κατώφλι. Τα αναστολικά μετασυναπτικά δυναμικά είναι σημαντικά καθώς μπορούν να εξουδετερώσουν τα διεγερτικά.



Σχήμα 1.3: Διαφορά δυναμικού εσωκυτταρικού - εξωκυτταρικού δυναμικού συναρτήσει του χρόνου σε ένα σημείο της μεμβράνης.

Κεφάλαιο 2

Το Ηλεκτροεγκεφαλογράφημα (EEG)


2.1 Ιστορική Αναδρομή

Το 1875, ο Βρετανός επιστήμονας Richard Caton ανακάλυψε τις ηλεκτρικές ιδιότητες του εγκεφάλου καταγράφοντας την ηλεκτρική δραστηριότητα από τον εγκέφαλο ζώων χρησιμοποιώντας ένα γαλβανόμετρο. Συμπέρανε ότι η δραστηριότητα των νευρών του Περιφερικού Νευρικού Συστήματος συνοδεύεται από μια καταγραφόμενη αλλαγή στο ηλεκτρικό δυναμικό. Το 1924, ο Γερμανός ψυχίατρος Hans Berger κατέγραψε το πρώτο ηλεκτροεγκεφαλογράφημα από άνθρωπο. Συγκεκριμένα σύλλεγε δεδομένα από ασθενείς με εγκεφαλικά ελαττώματα. Δημοσίευσε την πρώτη έρευνα για τα ηλεκτροεγκεφαλογραφήματα σε ανθρώπους το 1929 και αναφέρθηκε στους όρους "άλφα κύματα" και "βήτα κύματα" [2]. Το 1934, οι Fisher και Lowenback προσδιόρισαν τις κορυφές που σχετίζονται με την επιληψία και έπειτα, το 1935, οι Gibbs, Davis και Lennox περιέγραψαν τις κορυφές μεταξύ των επιληπτικών κρίσεων και το μοτίβο των 3-Hz κυμάτων κατά την διάρκεια κλινικών κρίσεων [3].

2.2 Σημασία του Ηλεκτροεγκεφαλογράφου

Το ηλεκτροεγκεφαλογράφημα είναι μια ηλεκτροφυσιολογική τεχνική για την καταγραφή της ηλεκτρικής δραστηριότητας που προκύπτει από τον ανθρώπινο εγκέφαλο. Δεδομένης της εξαιρετικής χρονικής ευαισθησίας του, η κύρια χρησιμότητα του ηλεκτροεγκεφαλογραφήματος είναι στην αξιολόγηση της δυναμικής εγκεφαλικής λειτουργίας. Το EEG είναι ιδιαίτερα χρήσιμο για την αξιολόγηση ασθενών με υποψίες επιληπτικών κρίσεων. Με ορισμένες εξαιρέσεις, σχεδόν όλοι οι ασθενείς με επιληψία θα παρουσιάσουν χαρακτηριστικές μεταβολές στο ηλεκτροεγκεφαλογράφημα κατά τη διάρκεια επιληπτικής κρίσης. Οι περισσότεροι ασθενείς με επιληψία εμφανίζουν επίσης χαρακτηριστικές εκκρίσεις μεταξύ των επιληπτικών κρίσεων που ονομάζονται αιχμές διάρκειας μικρότερης των 70 msec ή αιχμές διάρκειας 70 - 200 msec.

Το ηλεκτροεγκεφαλογράφημα χρησιμοποιείται επίσης για κλινικούς σκοπούς. Για παράδειγμα μπορεί να χρησιμοποιηθεί για την παρακολούθηση του βάθους της αναισθησίας κατά τη διάρκεια χειρουργικών επεμβάσεων. Δεδομένης της μεγάλης ευαισθησίας του στην εμφάνιση μικρών και γρήγορων αλλαγών στη νευρική λειτουργία, έχει αποδειχθεί αρκετά χρήσιμο στην παρακολούθηση πιθανών επιπλοκών όπως η ισχαιμία ή το έμφραγμα. Οι κυματομορφές EEG μπορεί επίσης να υπολογίζονται κατά μέσο όρο, προκαλώντας τα Προκλητά Δυναμικά (EP) και τα Βιοματικά Δυναμικά (ERP), δυναμικά τα οποία σχετίζονται με κάποιο ερέθισμα. Τα EP και ERP χρησιμοποιούνται στην κλινική έρευνα για ανάλυση οπτικής, ακουστικής, σωματοαισθητικής και γνωστικής λειτουργίας. Τέλος το ηλεκτροεγκεφαλογράφημα μπορεί επίσης να χρησιμοποιηθεί για να επιβεβαιώσει τον εγκεφαλικό θάνατο σε κάποιον που βρίσκεται σε κώμα.



Σχήμα 2.1: Ένα τυπικό ηλεκτροεγκεφαλογράφημα.


2.3 Λειτουργία του ηλεκτροεγκεφαλογράφου

Η λειτουργία του ηλεκτροεγκεφαλογράφου στηρίζεται στην καταγραφή των διαφορών δυναμικού πάνω στην εξωτερική δερματική επιφάνεια του ανθρώπινου κρανίου. Τα δυναμικά οφείλονται σε **ρευμάτα ιόντων** διαμέσου της κυτταρικής μεμβράνης των νευρώνων που συμμετέχουν στην εκάστοτε εγκεφαλική λειτουργία. Τα μετρούμενα ηλεκτρικά σήματα είναι ασθενή, $1\mu\text{V} - 100\mu\text{V}$. Υπάρχει λοιπόν η ανάγκη της όσο δυνατόν μεγαλύτερης ενίσχυσης των υπο εξέταση σημάτων, και μόνο αυτών, καθώς και της πυκνότερης κάλυψης του κεφαλιού με απαγωγά ηλεκτρόδια [4].

Για την εξαγωγή των σημάτων του ηλεκτροεγκεφαλογράφου χρησιμοποιούνται τα ηλεκτρόδια με διάμετρο περί τα $0.4\text{ cm} - 1.0\text{ cm}$. Αυτά είναι μικροί μεταλλικοί δίσκοι, συνήθως κατασκευασμένοι από ασήμι, χρυσό, κασσίτερο ή ανοξείδωτο ατσάλι και καλύπτονται με επίστρωση χλωριούχου αργύρου. Τα ηλεκτρόδια τοποθετούνται στο κρανίο και η επαφή με το δέρμα γίνεται μέσω μιας κολλώδους ουσίας ή μέσω ενός μικρού δακτυλιδιού, που από τη μια μεριά προσκολλάται στο δέρμα και από την άλλη στο κυρίως ηλεκτρόδιο. Στα σημεία στα οποία θα τοποθετηθούν τα ηλεκτρόδια, το δέρμα πρέπει να καθαριστεί καλά με οινόπνευμα για να επιτύχουμε χαμηλή αντίσταση επαφής, κάτω των $5\text{ k}\Omega$. Έτσι είναι δυνατή η κίνηση ιόντων μέσω του "συνόρου" ηλεκτροδίου - ηλεκτρολύτη μέχρι να επέλθει ισορροπία. Η ισορροπία αυτή είναι συνάρτηση της ιοντικής συγκέντρωσης που υπάρχει στις δύο πλευρές του συνόρου. Δημιουργούνται τελικά δύο φορτισμένα στρώματα στις δύο πλευρές του συνόρου, ένα στη μεταλλική επιφάνεια και ένα πάνω στις υγρές ουσίες γύρω από το ηλεκτρόδιο, εμφανίζοντας έτσι μια διαφορά δυναμικού η οποία εμποδίζει τη συνέχιση της κίνησης των ιόντων, άλλα είναι ταυτόχρονα ευαίσθητη στις μεταβολές των συγκεντρώσεων των ιόντων. Όταν μέσα στον εγκέφαλο υπάρξει σήμα, αυτό θα προκαλέσει μεταβολή της ιοντικής συγκέντρωσης και αυτόματα μεταβολή της διαφοράς δυναμικού των στρωμάτων, άρα και ροή ηλεκτρονίων από την πλευρά του αγώγιμου ηλεκτροδίου.

Υπάρχουν διάφοροι τρόποι να τοποθετηθούν τα ηλεκτρόδια πάνω στο κεφάλι, ωστόσο το δημο-

φιλέστερο πρότυπο είναι το **Διεθνές Σύστημα 10-20**. Σύμφωνα με αυτό το σύστημα η απόσταση μεταξύ δύο ηλεκτροδίων είναι το 20% της απόστασης μεταξύ των δύο αυτιών και η απόσταση από το αυτί στο κοντινότερο προς αυτό ηλεκτρόδιο είναι το 10% της απόστασης μεταξύ των δύο αυτιών.



Σχήμα 2.2: Τυποποιημένες απαγωγές στην επιφάνεια του κεφαλιού με το Σύστημα 10-20.


2.4 Προκλητά Δυναμικά - Event-Related Potentials

2.4.1 Προκλητά Δυναμικά και εξαγωγή από το Ηλεκτροεγκεφαλογράφημα

Τα τελευταία 40 χρόνια, ο τομέας της νευροεπιστήμης της γλώσσας σημείωσε σαφή πρόοδο με την εισαγωγή μη επεμβατικών τεχνικών έρευνας στον εγκέφαλο. Μεταξύ αυτών, τα **Προκλητά Δυναμικά (ERPs)** σχετίζεται με μια πολύ έμπιστη γνωστική μέτρηση που είναι χαμηλού κόστους και σχετικά εύκολη στη χρήση. Αυτή η μέτρηση συνεπάγεται συνήθως τη δημιουργία μιας διεπιστημονικής ομάδας ερευνητών, συμπεριλαμβανομένων γλωσσολόγων, μηχανικών επεξεργασίας σήματος, λογοθεραπευτών, ψυχολόγων, νευροεπιστημόνων, μεταξύ άλλων [5].

Τα **Προκλητά Δυναμικά** είναι πολύ μικρές τάσεις που δημιουργούνται στον εγκέφαλο ως απόκριση σε συγκεκριμένα γεγονότα ή ερεθίσματα [6]. Πρόκειται για αλλαγές EEG στο χρόνο που παρατηρούνται σε αισθητήρια, κινητικά ή γνωστικά γεγονότα που παρέχουν ασφαλή και μη επεμβατική προσέγγιση για τη μελέτη ψυχοφυσιολογικών συσχετισμών ψυχικών διεργασιών. Τα προκλητά δυναμικά μπορούν να προκληθούν από ένα μεγάλο αριθμό γεγονότων που προκαλούνται από αισθητήρες ή γνωστικά γεγονότα. Πιστεύεται ότι αντικατοπτρίζουν την αθροιστική δραστηριότητα των μετασυναπτικών δυναμικών που παράγονται όταν ένας μεγάλος αριθμός φλοιών νευρώνων πυροδοτούνται συγχρονισμένα κατά την επεξεργασία πληροφοριών [7].

Τα ERP στους ανθρώπους μπορούν να χωριστούν σε 2 κατηγορίες. Τα πρώτα κύματα, ή τις συνιστώσες που κορυφώνονται περίπου στα πρώτα 100 χιλιοστά του δευτερολέπτου (msec) μετά από το



Σχήμα 2.3: Παράδειγμα απόκρισης EEG ERP σε ηχητικά ερεθίσματα.

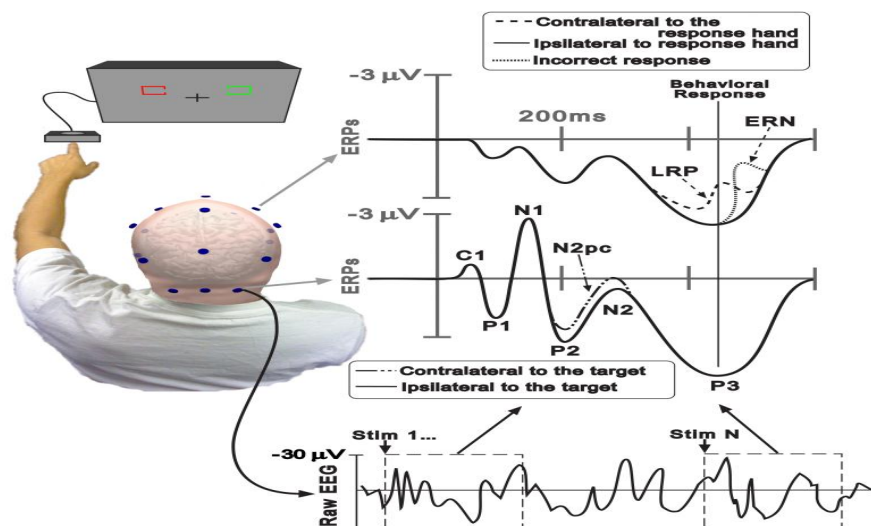
ερέθισμα, ονομάζονται «αισθητήρια» ή «εξωγενή» καθώς εξαρτώνται σε μεγάλο βαθμό από τις φυσικές παραμέτρους του ερεθίσματος. Αντίθετα, τα ERP που δημιουργούνται σε μεταγενέστερα μέρη αντικατοπτρίζουν τον τρόπο με τον οποίο το άτομο αξιολογεί το ερέθισμα και ονομάζονται «γνωστικά» ή «ενδογενή» ERP καθώς εξετάζουν την επεξεργασία πληροφοριών. Οι κυματομορφές περιγράφονται σύμφωνα με την καθυστέρηση και το πλάτος [8]. Τα ERP έχουν μια χρονική ανάλυση που επιτρέπει τη μέτρηση της εγκεφαλικής δραστηριότητας από το ένα χιλιοστό του δευτερολέπτου στο άλλο, και πολλές πτυχές της προσοχής και της αντίληψης φαίνεται να λειτουργούν σε μια κλίμακα δεκάδων χιλιοστών του δευτερολέπτου. Καθώς ο εγκέφαλος είναι ουσιαστικά μια υγρή ηλεκτρική συσκευή, αυτές οι ηλεκτροφυσιολογικές εγγραφές παρέχουν ένα άμεσο μέτρο του συγκεκριμένου συστήματος που μελετάμε. Επίσης, δεδομένης της φύσης της ηλεκτρικής δραστηριότητας και του ιστού στον οποίο δημιουργούνται και διαδίδονται ERP, δεν υπάρχει μετρήσιμη καθυστέρηση αγωγής μεταξύ της εγκεφαλικής δραστηριότητας που παράγεται στο κεφάλι και των δυνατοτήτων που καταγράφονται από το τριχωτό της κεφαλής [9].

Για να δημιουργηθούν ηλεκτρικά πεδία αρκετά μεγάλα για να διαδοθούν μέσω του εγκεφάλου, του κρανίου και του δέρματος, ένας μεγάλος αριθμός νευρώνων πρέπει να είναι ταυτόχρονα ενεργοί [10, 11]. Επιπλέον, αυτή η μεγάλη ομάδα νευρώνων όχι μόνο πρέπει να είναι ενεργή ταυτόχρονα αλλά και να έχει μια γεωμετρία που είναι κάθετη σε σχέση με την επιφάνεια του κρανίου και να μην ακυρώνεται από άλλα νευρωνικά σύνολα ενεργά ταυτόχρονα και με αντίθετο προσανατολισμό [12]. Οι ταυτόχρονα ενεργοί νευρώνες πρέπει να έχουν περίπου τον ίδιο προσανατολισμό για τις δυνατότητες αθροίσματος και αυτό σημαίνει ότι τα ERP παράγονται κυρίως από τα μετασυναπτικά δυναμικά των φλοιών των κυττάρων (τα οποία είναι κάθετα στην φλοιώδη επιφάνεια). Δεδομένης της θέσης και του προσανατολισμού μιας συγκεκριμένης νευρικής πηγής στον εγκέφαλο, μπορούμε να προβλέψουμε το μοτίβο της τάσης που θα παρατηρηθεί στο κεφάλι. Αυτό είναι γνωστό ως ευθύ πρόβλημα και επιλύεται εύκολα, σε αντίθεση με το αντίστροφο πρόβλημα. Το αντίστροφο πρόβλημα δηλώνει ότι εάν μας δοθεί μια κατανομή ηλεκτρικού δυναμικού σε έναν αγωγό όγκου, όπως το ανθρώπινο κρανίο, τότε δεν μπορούμε να γνωρίζουμε πού δημιουργείται εάν δεν γνωρίζουμε τον αριθμό των ταυτόχρονα ενεργών πηγών [13]. Πρακτικά, αυτό σημαίνει ότι δεν μπορούμε να εντοπίσουμε οριστικά τις νευρικές πηγές ERP μέσα στο κεφάλι από τα δεδομένα που έχουν καταγραφεί έξω από αυτό.

Η αδυναμία επίλυσης της δραστηριότητας των μεμονωμένων νευρώνων μπορεί να φαίνεται σαν ένα μεγάλο μειονέκτημα του ERP, φαίνεται ότι η λειτουργική μονάδα ανάλυσης που μετράει ERP τυχαία αντιστοιχεί στις γνωστικές διαδικασίες για τις οποίες συχνά υποθέτουν οι ψυχολόγοι. Συγκεκριμένα, τα ERP μας επιτρέπουν να παρατηρούμε μια σειρά γνωστικών επεμβάσεων που λαμβάνουν χώρα πριν από την παράδοση των αισθητηριακών πληροφοριών στο περιφερικό νευρικό σύστημα έως και μετά την απόκριση συμπεριφοράς. Οι πρώτες μελέτες έδειξαν ότι οι στερεοτυπικές διακυμάνσεις

στο δυναμικό προήλθαν από την παρουσίαση των αισθητηριακών ερεθισμάτων [14]. Ωστόσο, μια μελέτη έδειξε ότι η γνωστική δραστηριότητα που σχετίζεται με την προετοιμασία μιας δραστηριότητας θα μπορούσε να μετρηθεί. Η ενδεχόμενη αρνητική μεταβολή (CNV) φάνηκε να συσσωρεύεται πριν από την έναρξη ενός ερεθίσματος στο οποίο οι συμμετέχοντες έπρεπε να ανταποκριθούν [15]. Αυτό ήταν το πρώτο αναμενόμενο αποτέλεσμα από τις συνιστώσες του ERP που κατατάσσονται στις γνωστικές διαδικασίες που ανακαλύφθηκαν στη σύγχρονη εποχή [16].

Οι κορυφές και οι κοιλότητες μιας κυματομορφής ERP μας επιτρέπουν να οπτικοποιήσουμε τη γνωστική επεξεργασία του εγκεφάλου καθώς δημιουργούνται κατά τη διάρκεια μιας δοκιμής. Το 2.4 δείχνει εξιδανικευμένες κυματομορφές που προκαλούνται από οπτικά ερεθίσματα κατά τη διάρκεια μιας διαδικασίας στόχου διάκρισης. Αρχικά παρατηρούμε ότι η τάση σχεδιάζεται με αρνητική αύξηση, δηλαδή στο πάνω ημιπέδο υπάρχουν τα αρνητικά σημεία και στο κάτω θετικά. Οι ιστορίες σχετικά με την προέλευση αυτής της σύμβασης αφορούν. Είναι σαφές ότι αυτή η μέθοδος παρουσίας υπήρξε, και συνεχίζει να είναι, ένα αμφιλεγόμενο ζήτημα καθώς έχουν καταβληθεί προσπάθειες ανατροπής του άξονα τάσης. Συγκεκριμένα, η συντριπτική πλειονότητα των υπαρχόντων εγγράφων ERP σχεδίασε τις κυματομορφές τους με αρνητική αύξηση και η αντιληπτική μάθηση έχει καταστήσει αυτές τις κυματομορφές πολύ πιο εύκολο να ερμηνευθούν από εκείνες με αρνητικές γραφικές παραστάσεις [17].



Σχήμα 2.4: Ένα τυπικό μοντέλο καταγραφής EEG και ERPs που προκαλούνται από οπτικά ερεθίσματα. Στο δεξί μέρος της εικόνας παρουσιάζονται οι κυματομορφές και σημειώνονται οι κυριότερες κορυφές ενός ERP

Τα ERP μας επιτρέπουν να γνωρίζουμε τα χρονικά και χωρικά όρια των χαρακτηριστικών της νευρικής δραστηριότητας που σχετίζονται με τις συνιστώσες, διαδικασίες συμπεριφορών όπως επιλεκτική προσοχή, κωδικοποίηση πληροφοριών, επιλογή απόκρισης, ανασταλτικός έλεγχος και παρακολούθηση απόδοσης, που αντικατοπτρίζονται συνήθως αντίστοιχα από κάποιο ERP στοιχείο με ειδικές χρονικές-χωρικές κατανομές. Παρέχοντας ένα «μικροσκόπιο» στις αισθητηριακές, συναισθηματικές και γνωστικές διαδικασίες, τα ERP παρέχουν ένα βαθύτερο και πιο αντικειμενικό επίπεδο ανάλυσης πέρα από τα προφανή μέτρα συμπεριφοράς και απόδοσης εργασίας, επιτρέποντας την εξέταση τυπικών (π.χ. αναπτυξιακών) και άτυπων διαδικασιών (π.χ. κλινική σε σύγκριση με υγιείς ομάδες). Επιπλέον, η διάγνωση που παρέχεται από το ERP είναι μια διάγνωση διαδικασίας, δηλαδή μπορεί να πει σε ποιο στάδιο της συναισθηματικής και γνωστικής διαδικασίας του συμμετέχοντα είναι μη κανονική.

2.4.2 Μερικά χαρακτηριστικά παραδείγματα ERPs

Στα πρώτα χρόνια της μελέτης των ERPs, το επίκεντρο ήταν η ανακάλυψη και η κατανόηση των συνιστωσών του ERP και όχι η χρήση τους για την αντιμετώπιση ζητημάτων ευρείας επιστημονικής γνώσης. Γύρω στα μέσα της δεκαετίας του 1980, η τεχνική του ERP χρησιμοποιήθηκε ευρέως για να απαντήσει σε διάφορες ερωτήσεις στη γνωστική νευροεπιστήμη, η οποία έχει αναπτυχθεί εκρηκτικά από τότε. Το ERP δηλαδή, δεν χρησιμοποιείται μόνο για τη διερεύνηση της διαδικασίας της γενικής γνώσης, αλλά εφαρμόζεται επίσης στον τομέα της κλινικής διάγνωσης, της αλληλεπίδρασης μεταξύ ανθρώπου και μηχανής κ.λπ. Παρακάτω παρουσιάζουμε μερικά χαρακτηριστικά παραδείγματα ERPs.

N100

Το N100 είναι ένα αρνητικό προκλητό δυναμικό που εμφανίζεται περίπου στα 100 ms μετά την έναρξη του ερεθίσματος. Αυτό το δυναμικό δημιουργείται στον υπερχρονικό ακουστικό φλοιό και προκαλείται από οποιοδήποτε διακριτό ακουστικό ερέθισμα και το πλάτος του επηρεάζεται από διάφορους παράγοντες όπως την ένταση της διέγερσης, το επίπεδο και το διάκενο του διαλείμματος [18, 19].

N1

Το οπτικό προκλητό δυναμικό N1 εμφανίζεται περίπου στα 150 - 200 ms μετά το ερέθισμα και ονομάζεται N1 διότι είναι το πρώτο αρνητικό δυναμικό που παρατηρείται. Το N1 προκαλείται από οπτικά ερεθίσματα και είναι μέρος του οπτικού δυναμικού που προκαλείται - μια σειρά από παραμορφώσεις τάσης που παρατηρούνται σε απόκριση σε οπτικές αλλαγές [20].

N170

Το προκλητό δυναμικό N170 εμφανίζεται περίπου περίπου στα 130 - 200 ms μετά το ερέθισμα και ανήκει και αυτό όπως το N1 στα οπτικά προκλητά δυναμικά. Παρουσιάζεται κυρίως στο δεξί ημισφαίριο και συνδέεται με την διαδικασία κωδικοποίησης προσώπων [21, 22].

N200

Το προκλητό δυναμικό N200 εμφανίζεται 180 - 325 ms μετά από ένα οπτικό ή ακουστικό ερέθισμα [23]. Μπορεί να προκληθεί μέσω μιας εργασίας oddball στα οποία οι συμμετέχοντες εκτίθενται σε συνεχή διαδοχή δύο τύπων ερεθισμάτων ενός τακτικού και ενός σποραδικού.

N400

Το προκλητό δυναμικό N400 είναι ένα αρνητικό δυναμικό που παρουσιάζεται περί 400 ms μετά το οπτικό ή ακουστικό ερέθισμα και εμφανίζεται σε περιοχές γύρω από τα αυτιά [24, 25].

P200

Το προκλητό δυναμικό P200 εμφανίζεται περίπου μετά τα 200 ms από την ύπαρξη ενός ακουστικού ερεθίσματος και είναι ένα θετικό δυναμικό [25]. Το πλάτος αυτού του δυναμικού εξαρτάται από φυσικά χαρακτηριστικά ενός ακουστικού ερεθίσματος όπως την ένταση [26] και την συχνότητα [27].

N2pc

Το προκλητό δυναμικό N2pc εμφανίζεται περί τα 200 - 350 ms μετά το ερέθισμα. Ο χαρακτηρισμός "pc" προέρχεται από την περιοχή εγκεφάλου που προκαλείται "posterior-contralateral" (οπίσθια - αντίπλευρη) συνδέεται με την επιλεκτική προσοχή του ανθρώπου [28].

P300

Η κορυφή P300, δηλαδή Positive 300 msec (θετική ακμή στα 300 msec), εμφανίζεται συνήθως περίπου 300 έως 400 msec μετά την παρουσίαση ερεθίσματος. Ωστόσο, η διάρκεια αυτής της συνιστώσας μπορεί να κυμαίνεται ευρέως από 250 έως 900 msec, με το πλάτος να κυμαίνεται συνήθως από 5 έως 20 μV για ακουστικά και οπτικά ερεθίσματα. Οι τρόποι ερεθισμάτων με τους οποίους προκαλείται η κορυφή P300 είναι:

- μονή διέγερση
- oddball
- τριπλή διέγερση

Τέλος η συνιστώσα P300 χωρίζεται σε δύο τμήματα, την συνιστώσα P3a και την συνιστώσα P3b [29].

P3a και P3b

Το προκλητό δυναμικό P3a εντοπίζεται περισσότερο στο μετωπικό σημείο του εγκεφάλου σε σχέση με το P3b [25]. Επίσης το P3a προκαλείται από ακούσια προσοχή σε μια εργασία oddball στο οποίο δεν απαιτούνται αποκρίσεις της συμπεριφοράς στα ερεθίσματα. Το P3b συνδέεται έντονα με την εκούσια προσοχή σε μια εργασία oddball που απαιτεί αποκρίσεις της συμπεριφοράς. Το πλάτος του P3b ποικίλλει και εξαρτάται με την ποσότητα των σχετικών ερεθισμάτων αλλά και την συνάφεια αυτών [30].

Late Positive Component

Το Late Positive Component είναι ένα θετικό προκλητό δυναμικό που είναι σημαντικό σε μελέτες αναγνώρισης μνήμης [31]. Εντοπίζεται στα πλάγια σημεία του εγκεφάλου και εμφανίζεται περί τα 400 - 500 ms μετά το ερέθισμα και διαρκεί μερικές εκατοντάδες χιλιοστά του δευτερολέπτου.

P600

Το προκλητό δυναμικό P600 εμφανίζεται περίπου 500 ms μετά το ερέθισμα και διαρκεί μερικές εκατοντάδες χιλιοστά του δευτερολέπτου και προκαλείται από τα κεντρικά, πλάγια και μερικές φορές τα εμπρόσθια σημεία του εγκεφάλου. Πολλές φορές ξεπερνά και τα 600 ms. Σχετίζεται κυρίως με την γλωσσική κατανόηση και το πλάτος του εξαρτάται από την δυσκολία μιας λέξης, την ύπαρξη ορθογραφικού ή συντακτικού λάθους [32]. Μπορεί να προκληθεί και από οπτικά και ακουστικά πειράματα.

Στο επόμενο κεφάλαιο θα γίνει μια εισαγωγή στις βασικές έννοιες που χρειάστηκαν ώστε να υλοποιηθεί η παρούσα διπλωματική εργασία.

Κεφάλαιο 3

Θεωρητικό Υπόβαθρο

3.1 Μηχανική Μάθηση

3.1.1 Εισαγωγή

Η Μηχανική Μάθηση (Machine Learning) είναι ένας από τους ταχύτερα αναπτυσσόμενους τομείς της επιστήμης των υπολογιστών, με εκτεταμένες εφαρμογές. Αναφέρεται στην αυτοματοποιημένη ανίχνευση σημαντικών προτύπων στα δεδομένα. Τα εργαλεία μηχανικής μάθησης ασχολούνται με προγράμματα που έχουν την ικανότητα να μάθουν και προσαρμογής [33]. Η Μηχανική Εκμάθηση έχει γίνει ένας από τους βασικούς άξονες της Πληροφορικής και με αυτό, ένα μάλλον κεντρικό, αν και συνήθως κρυμμένο, μέρος της ζωής μας. Με τη διαρκώς αυξανόμενη ποσότητα δεδομένων να είναι διαθέσιμος, υπάρχει ένας καλός λόγος να πιστεύουμε ότι η έξυπνη ανάλυση δεδομένων θα γίνει ακόμη πιο διαδεδομένη ως απαραίτητο συστατικό για την τεχνολογική πρόοδο. Υπάρχουν πολλές εφαρμογές της Μηχανικής Μάθησης, η πιο σημαντική από τις οποίες είναι η εξόρυξη δεδομένων (Data Mining) [34].

Από την Εξόρυξη Δεδομένων και τη Μηχανική Μάθηση μπορούν να αντληθούν αρκετές γνώσεις μέσω κατάλληλων αλγορίθμων μάθησης. Η συγχώνευση στατιστικών, μηχανικής μάθησης, θεωρίας πληροφοριών και υπολογιστών έχει δημιουργήσει μια σταθερή επιστήμη, με μια σταθερή μαθηματική βάση και με πολύ ισχυρά εργαλεία [35].

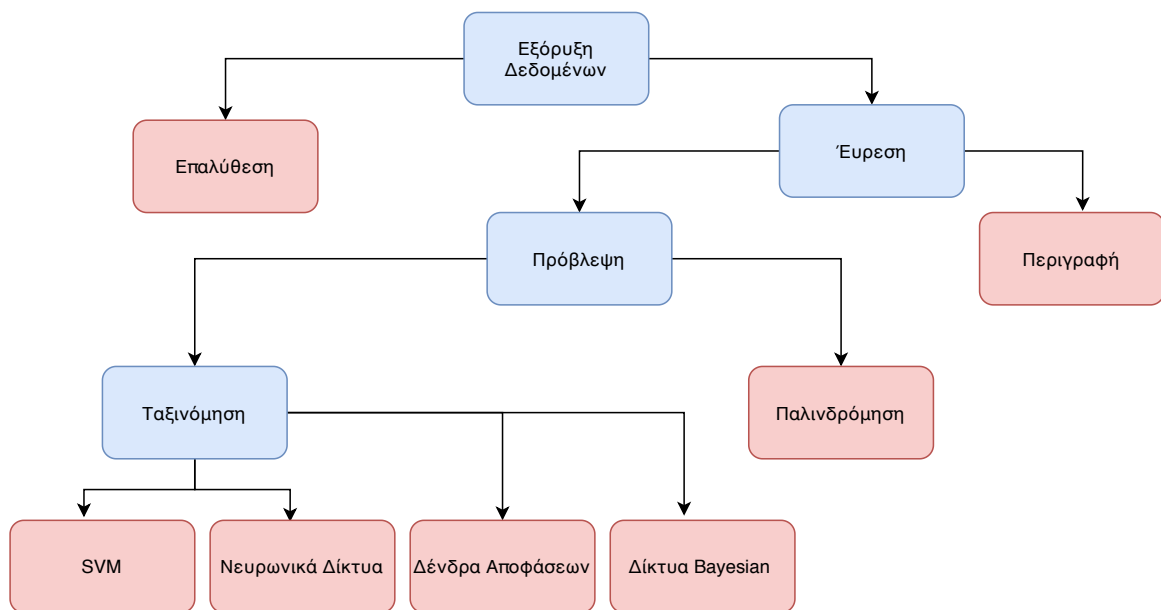
3.1.2 Κατηγοριοποίηση προβλημάτων Μηχανικής Μάθησης και Εξόρυξης Δεδομένων

Η εξόρυξη δεδομένων συνίσταται στη λήψη οποιασδήποτε μορφής δεδομένων και την εφαρμογή αλγορίθμων ανάλυσης σε αυτήν, προκειμένου να αποκαλυφθούν μοτίβα ή μοντέλα στο σύνολο δεδομένων και να χρησιμοποιηθούν αυτές οι δομές για την ταξινόμηση των δεδομένων σε διαφορετικές κατηγορίες (ετικέτες). Περιλαμβάνει έναν αριθμό ερευνητικών τομέων όπως συστήματα βάσεων δεδομένων, στατιστικές και αναγνώριση προτύπων. Οι εργασίες εξόρυξης δεδομένων διαφοροποιούνται ανάλογα με τις γνώσεις που έχει ο αλγόριθμος σχετικά με τις υπάρχουσες τάξεις στο σύνολο δεδομένων [36].

- **Η Εποπτευόμενη μάθηση (Supervised learning)** περιλαμβάνει κάθε εργασία στην οποία ο αλγόριθμος έχει πρόσβαση σε τιμές εισόδου και εξόδου. Οι τιμές εισόδου ορίζονται ως οι εξωτερικές πληροφορίες που επιτρέπεται να χρησιμοποιεί ο αλγόριθμος, όπως τιμές χαρακτηριστικών και μετα-δεδομένα, ενώ οι τιμές εξόδου, είναι οι συγκεκριμένες ετικέτες του χαρακτηριστικού κλάσης. Αυτό σημαίνει ότι η δομή των δεδομένων είναι ήδη γνωστή και ο στόχος αυτών των προγραμμάτων είναι η εκχώρηση νέων δεδομένων στις σωστές τάξεις ή κατηγορίες. Στην παρούσα διπλωματική χρησιμοποιήθηκαν αλγόριθμοι εποπτευόμενης μάθησης. Μερικά παραδείγματα αλγορίθμων εποπτευόμενης μάθησης: Support Vector Machines (SVM), k-nearest neighbor (kNN) και Δένδρα Αποφάσεων (Decision Trees).

- Σε αντίθεση με την εποπτευόμενη μάθηση, η **μη Εποπτευόμενη μάθηση** περιλαμβάνει όλες τις διαδικασίες που δεν έχουν πρόσβαση σε τιμές εξόδου και επομένως προσπαθούν να βρουν δομές εντός των δεδομένων δημιουργώντας τάξεις μόνοι τους. Μερικά παραδείγματα αλγορίθμων μη εποπτευόμενης μάθησης: k-means (Clustering) και Νευρωνικά Δίκτυα (Neural Networks)

Η εξόρυξη δεδομένων μπορεί να διαφοροποιηθεί σε δύο βασικούς στόχους: επαλήθευση (verification) και εύρεση (discovery). Ενώ η επαλήθευση προσπαθεί να αποδείξει την υπόθεση του χρήστη, η εύρεση αναζητά ακόμη άγνωστα μοτίβα στα δεδομένα. Το βήμα εύρεσης χωρίζεται σε περιγραφή, όπου το σύστημα βρίσκει μοτίβα για να παρουσιάσει τα δεδομένα σε κατανοητή μορφή και πρόβλεψη, όπου το σύστημα προσπαθεί να προβλέψει τα μελλοντικά αποτελέσματα των δεδομένων από μοτίβα. Η πρόβλεψη της υποομάδας ή υποσυνόλου μπορεί περαιτέρω να διακριθεί σε εργασίες ταξινόμησης και παλινδρόμησης. Ενώ οι εργασίες ταξινόμησης έχουν σταθερές ετικέτες ή κλάσεις και κάθε εγγραφή δεδομένων έχει μία από αυτές τις ετικέτες ως τιμή χαρακτηριστικού κλάσης, οι εργασίες παλινδρόμησης έχουν συνεχείς τιμές ως έξοδο [37].



Σχήμα 3.1: Κατηγοριοποίηση Εξόρυξης Δεδομένων.

3.1.3 Ταξινόμηση

Η ταξινόμηση στη μηχανική μάθηση και στη στατιστική είναι μια εποπτευόμενη μαθησιακή προσέγγιση στην οποία ο αλγόριθμος μαθαίνει από τα δεδομένα που του δίνονται και κάνει νέες παρατηρήσεις ή ταξινομήσεις. Καθορίζει την κλάση στην οποία ανήκουν τα στοιχεία δεδομένων και χρησιμοποιείται καλύτερα όταν η έξοδος έχει πεπερασμένες και διακριτές τιμές. Προβλέπει επίσης την κλάση ή κατηγορία για μια μεταβλητή εισόδου. Ο κύριος στόχος είναι να προσδιοριστεί σε ποια κατηγορία θα εμπίπτουν τα νέα δεδομένα. Η ανίχνευση καρδιακών παθήσεων μπορεί να αναγνωριστεί ως πρόβλημα ταξινόμησης, είναι δυαδική ταξινόμηση, καθώς μπορεί να υπάρχουν μόνο δύο κατηγορίες, δηλαδή έχει καρδιακή νόσο ή δεν έχει καρδιακή νόσο. Ο ταξινομητής, σε αυτήν την περίπτωση, χρειάζεται εκπαιδευτικά δεδομένα για να κατανοήσει πώς οι δεδομένες μεταβλητές εισόδου σχετίζονται με την τάξη. Και όταν ο ταξινομητής εκπαιδευτεί με ακρίβεια, μπορεί να χρησιμοποιηθεί για να ανιχνεύσει εάν υπάρχει καρδιακή νόσος ή όχι για έναν συγκεκριμένο ασθενή. Δεδομένου ότι η ταξινόμηση είναι ένας τύπος εποπτευόμενης μάθησης, ακόμη και οι στόχοι παρέχονται επίσης με

τα δεδομένα εισόδου. Στα πλαίσια της διπλωματικής εργασίας χρειάστηκε να χρησιμοποιηθούν αλγόριθμοι ταξινόμησης προκειμένου να κατηγοριοποιηθούν τα ηλεκτροεγκεφαλογραφήματα σε δύο κατηγορίες: Υποκείμενα με κόπωση και υποκείμενα χωρίς κόπωση.

Παρακάτω αναφέρονται μερικές ορολογίες που χρησιμοποιούνται στη Μηχανική Μάθηση και συγκεκριμένα στη ταξινόμηση.


- **Ταξινομητής.** Είναι ένας αλγόριθμος που χρησιμοποιείται για τη χαρτογράφηση των δεδομένων εισόδου σε μια συγκεκριμένη κατηγορία.
- **Μοντέλο Ταξινόμησης.** Το μοντέλο προβλέπει ή καταλήγει σε ένα συμπέρασμα στα δεδομένα εισόδου που δίνονται για εκπαίδευση, θα προβλέψει την τάξη ή την κατηγορία για τα δεδομένα.
- **Χαρακτηριστικό.** Ένα χαρακτηριστικό είναι μια μεμονωμένη μετρήσιμη ιδιότητα του φαινομένου που παρατηρείται.
- **Λυαδική Ταξινόμηση.** Είναι ένας τύπος ταξινόμησης με δύο αποτελέσματα, για παράδειγμα - είτε αληθές είτε ψευδές.
- **Ταξινόμηση πολλαπλών τάξεων.** Ταξινόμηση με περισσότερες από δύο κατηγορίες, στην ταξινόμηση πολλαπλών τάξεων κάθε δείγμα αντιστοιχεί σε μία και μόνο μία ετικέτα.
- **Ταξινόμηση πολλαπλών ετικετών.** Αυτός είναι ένας τύπος ταξινόμησης όπου κάθε δείγμα αντιστοιχεί σε ένα σύνολο ετικετών ή στόχων.

3.1.4 Ταξινομητής Support Vector Machine

Τα Support Vector Machines (SVM) είναι μια χρήσιμη τεχνική για την ταξινόμηση δεδομένων. Παρόλο που θεωρείται ότι τα Νευρωνικά Δίκτυα είναι ευκολότερα στη χρήση από αυτό, ωστόσο, μερικές φορές επιτυγχάνονται μη ικανοποιητικά αποτελέσματα [38]. Μια εργασία ταξινόμησης συνήθως περιλαμβάνει την εκπαίδευση και τη δοκιμή δεδομένων που αποτελούνται από ορισμένες παρουσίες δεδομένων [39]. Κάθε παρουσία στο σύνολο εκπαίδευσης περιέχει μία τιμή στόχου και πολλά χαρακτηριστικά. Ο στόχος του SVM είναι να παράγει ένα μοντέλο που προβλέπει την τιμή-στόχο των παρουσιών δεδομένων στο σύνολο δοκιμών που δίνεται μόνο στα χαρακτηριστικά [40]. Αποτελούν υπολογιστικούς αλγόριθμους που κατασκευάζουν ένα υπερεπίπεδο σε άπειρο διαστατικό χώρο. Τα SVM μπορούν να χρησιμοποιηθούν για ταξινόμηση, παλινδρόμηση ή άλλες εργασίες. Διαισθητικά, ένας διαχωρισμός μεταξύ δύο γραμμικά διαχωρίσιμων τάξεων επιτυγχάνεται από οποιοδήποτε υπερεπίπεδο που δεν παρέχει κακή ταξινόμηση σε όλα τα σημεία δεδομένων οποιασδήποτε από τις θεωρούμενες κατηγορίες, δηλαδή, όλα τα σημεία που ανήκουν στην κατηγορία A επισημαίνονται ως +1, για παράδειγμα, και όλα τα σημεία που ανήκουν στην κατηγορία B φέρουν την ένδειξη -1 [41, 42].

Αυτή η προσέγγιση ονομάζεται γραμμική ταξινόμηση, ωστόσο υπάρχουν πολλά υπερεπίπεδα που μπορούν να ταξινομήσουν το ίδιο σύνολο δεδομένων όπως φαίνεται στο Σχήμα 3.2 παρακάτω. Το SVM είναι μια προσέγγιση όπου ο στόχος είναι να βρεθεί το καλύτερο υπερεπίπεδο διαχωρισμού, δηλαδή το υπερεπίπεδο που παρέχει την υψηλότερη απόσταση περιθωρίου μεταξύ των πλησιέστερων σημείων των δύο κατηγοριών (ονομάζεται λειτουργικό περιθώριο). Αυτή η προσέγγιση, γενικά, εγγυάται ότι όσο μεγαλύτερο είναι το περιθώριο τόσο χαμηλότερο είναι το σφάλμα γενίκευσης του ταξινομητή.

Εάν υπάρχει τέτοιο υπερεπίπεδο, είναι σαφές ότι παρέχει το καλύτερο όριο διαχωρισμού μεταξύ των δύο κατηγοριών και είναι γνωστό ως υπερεπίπεδο μέγιστου περιθωρίου και ένας τέτοιος γραμμικός ταξινομητής είναι γνωστός ως ταξινομητής μέγιστου περιθωρίου.



Σχήμα 3.2: Υπερεπίπεδα διαχωρισμού. Το H_1 δεν διαχωρίζει τις δύο κατηγορίες. Το H_2 χωρίζει αλλά με πολύ μικρό περιθώριο μεταξύ των τάξεων και το H_3 χωρίζει τις δύο τάξεις με πολύ καλύτερο περιθώριο από το H_2 .

Το επιφανειακό μοντέλο που χρησιμοποιείται από τον SVM για την εκτέλεση του διαχωρισμού είναι το υπερεπίπεδο. Έστω λοιπόν τα \mathbf{W} και b να είναι, αντίστοιχα, το κανονικό διάνυσμα του υπερεπιπέδου και η μετατόπισή του σε σχέση με την αρχή των αξόνων [43]. Έτσι, έχουμε ότι η συνάρτηση απόφασης για μια είσοδο x δίνεται από την εξίσωση 3.1.

$$D(x) = \vec{W} \bullet \vec{x} - b \quad (3.1)$$

όπου,


$$x \in \begin{cases} A & \text{if } D(x) > 0 \\ B & \text{if } D(x) < 0 \end{cases} \quad (3.2)$$

Όπως φαίνεται στο σχήμα 3.3 παρακάτω, η απόσταση από το x προς το υπερεπίπεδο δίνεται από την 3.3.

$$\frac{D(x)}{\|\mathbf{W}\|} \quad (3.3)$$

Έτσι, τα $D(x_1)$ και $D(x_2)$ θα έχουν αντίθετα πρόσημα (ανήκουν σε διαφορετικά σύνολα) εάν και μόνο εάν τα x_1 και x_2 βρίσκονται σε αντίθετες πλευρές του υπερεπιπέδου διαχωρισμού. Το σχήμα 3.3 δείχνει ότι το διάνυσμα \mathbf{W} είναι κάθετο στο υπερεπίπεδο και η παράμετρος $\frac{|b|}{\|\mathbf{W}\|}$ καθορίζει την μετατόπιση του υπερεπιπέδου από την αρχή των αξόνων κατά μήκος του κανονικού διανύσματος [44]. Είναι επιθυμητό να επιλεγθούν τα \mathbf{W} και b για μεγιστοποίηση του περιθωρίου (margin) M που αντιπροσωπεύει την απόσταση μεταξύ των παράλληλων υπερεπιπέδων που είναι όσο το δυνατόν πιο μακριά, ενώ ταυτόχρονα διαχωρίζουν και τα δύο σύνολα δεδομένων [45]. Αυτά τα δύο υπερεπίπεδα

μπορούν να περιγραφούν αντίστοιχα με τις ακόλουθες εξισώσεις 3.4.



Σχήμα 3.3: Παράδειγμα διαχωρισμού υπερεπιπέδου (σε δύο διαστάσεις), αποστάσεων και περιθωρίων.

$$\vec{W} \bullet \vec{x} - b = +1 \quad \text{and} \quad \vec{W} \bullet \vec{x} - b = -1 \quad (3.4)$$

Έστω το σύνολο σημείων δειγματοληψίας x_1, \dots, x_p και την αντίστοιχη ομάδα ταξινόμησης y_1, \dots, y_p όπου

$$y_i = \begin{cases} +1 & \text{if } x_i \in A \\ -1 & \text{if } x_i \in B \end{cases} \quad (3.5)$$

Εάν οι δύο ομάδες δειγμάτων στα δεδομένα εκπαίδευσης διαχωρίζονται γραμμικά, τότε είναι δυνατό να επιλεγθούν τα δύο υπερεπίπεδα με τρόπο που να μην υπάρχουν σημεία μεταξύ τους και στη συνέχεια να προσπαθήσουμε να μεγιστοποιήσουμε την απόσταση μεταξύ των δύο υπερεπιπέδων [46].

Η απόσταση μεταξύ αυτών των δύο υπερεπιπέδων δίνεται από $\frac{2}{\|\vec{W}\|}$ και για να μεγιστοποιηθεί αυτό σημαίνει ελαχιστοποίηση του \vec{W} και, προκειμένου να αποφευχθεί η πτώση των σημείων δεδομένων στο περιθώριο (margin) M , προσθέτουμε τον ακόλουθο περιορισμό σε κάθε εξίσωση 3.6:

$$\vec{W} \bullet \vec{x} - b \geq +1 \quad \forall i, \quad y_i = +1 \quad \text{and} \quad \vec{W} \bullet \vec{x} - b \leq -1 \quad \forall i, \quad y_i = -1 \quad (3.6)$$

Πολλαπλασιάζοντας κάθε εξίσωση με την αντίστοιχη y_i μετατρέπονται σε μία μόνο εξίσωση ως εξής 3.7:

$$y_i \bullet (\vec{W} \bullet \vec{x}_i - b) \geq 1 \quad \forall i, \quad i = 1 \dots p \quad (3.7)$$

Διαιρώντας τώρα και τις δύο πλευρές της εξίσωσης με το $\|w\|$ γίνεται όπως στην εξίσωση 3.8

$$\frac{y_i \bullet (\vec{W} \bullet \vec{x}_i - b)}{\|w\|} \geq \frac{1}{\|w\|} = M \quad \forall i, \quad i = 1 \dots p \quad (3.8)$$

Για να μεγιστοποιήσουμε το M , θα πρέπει να ελαχιστοποιήσουμε το $\|w\|$ σύμφωνα με τον ακόλουθο περιορισμό όπως φαίνεται στην 3.9.

$$\min(w, b) \quad \|w\| \quad \text{subject to} \quad \forall i, i = 1 \dots p \quad y_i \bullet (\vec{W} \bullet \vec{x}_i - b) - 1 \geq 0 \quad (3.9)$$

Το παραπάνω πρόβλημα βελτιστοποίησης είναι δύσκολο να επιλυθεί επειδή εξαρτάται από το $\|w\|$, τη νόρμα του w , που περιλαμβάνει μια τετραγωνική ρίζα. Μπορούμε όμως να θέσουμε όπου $\|w\|$ το $\frac{1}{2}\|w\|^2$ χωρίς να αλλάξει το αποτέλεσμα της λύσης. Το πρόβλημα τώρα ανήκει στη βελτιστοποίηση τετραγωνικού προγραμματισμού (QP) που είναι ευκολότερο να υπολογιστεί και αναφέρεται όπως στην εξίσωση 3.10.

$$\min(w, b) \quad \frac{1}{2}\|w\|^2 \quad \text{subject to} \quad \forall i, i = 1 \dots p \quad y_i \bullet (\vec{W} \bullet \vec{x}_i - b) - 1 \geq 0 \quad (3.10)$$

Ο συντελεστής $1/2$ χρησιμοποιείται για μαθηματική ευκολία και το πρόβλημα μπορεί τώρα να επιλυθεί με τυπικές τεχνικές τετραγωνικού προγραμματισμού. Η εφαρμογή μη αρνητικών πολλαπλασιαστών Lagrange a_i ($i = 1 \dots p$) στην αντικειμενική συνάρτηση μετατρέπει το πρόβλημα σε διπλή μορφή όπως στην εξίσωση 3.11.

$$L(w, b, a) = \frac{1}{2}\|w\|^2 - \sum_{i=1}^p a_i (y_i (\vec{w} \bullet \vec{x}_i - b) - 1) \quad \text{subject to} \quad a_i \geq 0 \quad \forall i, i = 1 \dots p \quad (3.11)$$

Λαμβάνοντας υπόψη τώρα ότι στο σημείο λύσης η κλίση του $L()$ είναι μηδενική, η εξίσωση μπορεί να αντιμετωπιστεί προκειμένου να επιτευχθεί ένα νέο πρόβλημα τετραγωνικού προγραμματισμού όπως στις εξισώσεις 3.12 και 3.13

$$\frac{\partial L}{\partial w} \Big|_{w=w^*} = w^* - \sum_{i=1}^p a_i y_i x_i = 0 \quad \Rightarrow \quad w^* = \sum_{i=1}^p a_i y_i x_i \quad (3.12)$$

$$\frac{\partial L}{\partial w} \Big|_{b=b^*} = - \sum_{i=1}^p a_i y_i = 0 \quad \Rightarrow \quad \sum_{i=1}^p a_i y_i = 0 \quad (3.13)$$

Σε αυτήν την περίπτωση, το ελάχιστο σημείο σε σχέση με τα w και b είναι το ίδιο με το μέγιστο σε σχέση με το α , και το πρόβλημα μπορεί να δηλωθεί όπως στην 3.14.

$$\max(a_i) \quad a^T \bullet \mathbf{1} - \frac{1}{2} a^T \bullet \vec{H} \bullet \vec{a} \quad \text{subject to} \quad \forall i, i = 1 \dots p \quad a_i \geq 0, \quad a^T \bullet y = 0 \quad (3.14)$$

όπου, $\alpha = (\alpha_1, \dots, \alpha_p)^T$, $y = (y_1, \dots, y_p)^T$, $\mathbf{0}$ και $\mathbf{1}$ έχουν μέγεθος p , και $H_{p \times p}$ είναι

$$\vec{H}_{i,j} = \overrightarrow{y_i y_j x_i^T \bullet x_j} \quad (3.15)$$

Ένας όρος που ορίζεται από το θεώρημα Kühn-Tucker είναι ότι

$$\alpha^*(y_i(\overrightarrow{w^* \bullet x_i} - b^*) - 1) = 0 \quad \forall i, i = 1 \dots p \quad (3.16)$$

έτσι αν $\alpha_i^* \neq 0$ τότε

$$y_i(\overrightarrow{w^* \bullet x_i} - b^*) - 1 = 0 \quad \forall i, i = 1 \dots p \quad (3.17)$$

που αυτό γίνεται

$$y_i(\overrightarrow{w^* \bullet x_i} - b^*) = 1 \quad \forall i, i = 1 \dots p \quad (3.18)$$


Οποιοδήποτε x_i που ικανοποιεί την εξίσωση 3.18 ονομάζεται **support vector** και οι εκπαιδεύσεις (training) των SVM μειώνονται στο σύνολο τέτοιων διανυσμάτων.

3.1.5 Ταξινόμητης K-Nearest Neighbor

Ο αλγόριθμος k-Nearest Neighbor (kNN) είναι μια μέθοδος για την ταξινόμηση αντικειμένων που βασίζεται στην "ομοιότητα" των πιο κοντινών αντικειμένων στο χώρο. Βασίζεται σε στιγμιότυπα για αυτό κατατάσσεται στις "τεμπέλικες" μεθόδους εκμάθησης (lazy learning), όπου η λειτουργία προσεγγίζεται τοπικά και όλοι οι υπολογισμοί αναβάλλονται έως την ταξινόμηση [47, 48]. Ο kNN είναι μια απλή τεχνική ταξινόμησης και χρησιμοποιείται όταν υπάρχει λίγη ή καθόλου γνώση σχετικά με την κατανομή δεδομένων [49]. Αυτός ο κανόνας απλώς διατηρεί το ολόκληρο το σύνολο δεδομένων που χρησιμοποιείται για εκπαίδευση (training set) και κατά τη διάρκεια της μάθησης εκχωρεί σε κάθε μια κλάση σε κάθε ερώτημα (query) την ετικέτα που αντιπροσωπεύει την πλειοψηφία των k πλησιέστερων γειτόνων της στο σύνολο εκπαίδευσης. Όταν $k = 1$ τότε έχουμε την απλούστερη μέθοδο πλησιέστερου γείτονα (NN). Σε αυτή τη μέθοδο κάθε δείγμα πρέπει να ταξινομείται παρόμοια με τα κοντινά δείγματά του. Επομένως, εάν η ταξινόμηση ενός δείγματος είναι άγνωστη, τότε θα μπορούσε να προβλεφθεί λαμβάνοντας υπόψη την ταξινόμηση των πλησιέστερων γειτονικών δειγμάτων του. Λαμβάνοντας υπόψη ένα άγνωστο δείγμα και ένα σύνολο εκπαίδευσης, μπορούν να υπολογιστούν όλες οι αποστάσεις μεταξύ του άγνωστου δείγματος και όλων των δειγμάτων στο σετ εκπαίδευσης. Η απόσταση με τη μικρότερη τιμή αντιστοιχεί στο δείγμα στο σετ εκπαίδευσης που βρίσκεται πλησιέστερα στο άγνωστο δείγμα. Επομένως, το άγνωστο δείγμα μπορεί να ταξινομηθεί με βάση την

ταξινόμηση αυτού του πλησιέστερου γείτονα [50].

Το 3.4 δείχνει τον κανόνα απόφασης k NN για $k = 1$ και $k = 4$ για ένα σύνολο δειγμάτων χωρισμένο σε 2 τάξεις. Στο 3.4 (α), ένα άγνωστο δείγμα ταξινομείται χρησιμοποιώντας μόνο ένα γνωστό δείγμα. Στο 3.4 (β) χρησιμοποιούνται περισσότερα από ένα γνωστά δείγματα. Στην τελευταία περίπτωση, η παράμετρος k ορίζεται σε 4, έτσι ώστε τα τέσσερα πλησιέστερα δείγματα να λαμβάνονται υπόψη για την ταξινόμηση του άγνωστου. Τρία από αυτά ανήκουν στην ίδια τάξη, ενώ μόνο ένα ανήκει στην άλλη τάξη. Και στις δύο περιπτώσεις, το άγνωστο δείγμα ταξινομείται ως ανήκει στην τάξη στα αριστερά [51].




Σχήμα 3.4: (α) Ο κανόνας απόφασης 1-NN: το σημείο ? έχει ανατεθεί στην τάξη στα αριστερά. (β) ο κανόνας απόφασης k NN, με $k = 4$: το σημείο ? έχει ανατεθεί στην αριστερή τάξη επίσης

Η απόδοση ενός ταξινομητή k NN καθορίζεται κυρίως από την επιλογή του k καθώς και από τη μέτρηση απόστασης που εφαρμόζεται [52, 53]. Η εκτίμηση επηρεάζεται από την ευαισθησία της επιλογής του μεγέθους γειτονιάς k , επειδή η ακτίνα της τοπικής περιοχής καθορίζεται από την απόσταση του πλησιέστερου k γείτονα στο ερώτημα και το διαφορετικό k αποδίδει διαφορετικές πιθανότητες κατηγορίας υπό όρους. Εάν το k είναι πολύ μικρό, η τοπική εκτίμηση τείνει να είναι πολύ φτωχή λόγω της αδυναμίας των δεδομένων και λανθασμένων σημείων. Προκειμένου να βελτιωθεί περαιτέρω η εκτίμηση, μπορούμε να αυξήσουμε το k και να λάβουμε υπόψη μια μεγάλη περιοχή γύρω από το ερώτημα, όπως φαίνεται στο σχήμα 3.5. Δυστυχώς, μια μεγάλη τιμή του k κάνει εύκολα την εκτίμηση της εξομάλυνσης και η απόδοση της ταξινόμησης υποβαθμίζεται με την εισαγωγή των ακραίων τιμών από άλλες κατηγορίες.

Όπως αναφέρθηκε προηγουμένως, ο k NN κάνει προβλέψεις με βάση το αποτέλεσμα των k γειτόνων που βρίσκονται πλησιέστερα σε αυτό το σημείο. Επομένως, για να κάνουμε προβλέψεις με το k NN, πρέπει να ορίσουμε μια μέτρηση για τη μέτρηση της απόστασης μεταξύ του σημείου ερωτήματος και των περιπτώσεων από τα υπάρχοντα σημεία. Μία από τις πιο δημοφιλείς επιλογές για τη μέτρηση αυτής της απόστασης είναι γνωστή ως **Ευκλείδεια Απόσταση** όπου παρουσιάζεται στην εξίσωση 3.19 .

$$D(x, p) = \sqrt{(x - p)^2} \quad (3.19)$$

Κάποια πλεονεκτήματα του k NN είναι ότι είναι απλός σαν αλγόριθμος , πετυχαίνει καλή ακρίβεια αλλά όχι συγκρίσιμη με καλύτερα μοντέλα εποπτευόμενης μάθησης και τέλος μπορεί να χρησιμοποιηθεί και για ταξινόμηση αλλά και για παλινδρόμηση. Ωστόσο είναι υπολογιστικά "ακριβό" επειδή ο αλγόριθμος αποθηκεύει όλα τα δεδομένα εκπαίδευσης, απαιτεί αρκετό χώρο στη μνήμη, αποθηκεύει



Σχήμα 3.5: Παράδειγμα kNN για διάφορα k

όλα τα δεδομένα εκπαίδευσης, το στάδιο της πρόβλεψης είναι αργό για μεγάλο πλήθος εισόδου και τέλος είναι ευαίσθητο για άσχετα χαρακτηριστικά.

3.2 Φασματική πυκνότητα ισχύος

3.2.1 Τα Βασικά Στοιχεία της Φασματικής Πυκνότητας Ισχύος

Στα πλαίσια της παρούσας εργασίας χρειάστηκε να εξάγουμε από τα σήματα ERPs την φασματική πυκνότητα ισχύος προκειμένου να χρησιμοποιηθούν ως χαρακτηριστικά στο στάδιο ταξινόμησης και στην δημιουργία ενός μοντέλου μηχανικής μάθησης. Το πρόβλημα εύρεσης πυκνότητας φάσματος ισχύος συνήθως σχετίζεται με σταθερά τα σήματα ευρείας έννοιας (WSS). Λόγω τυχαίων διακυμάνσεων στα σήματα, είναι απαραίτητο να διαχειριστούμε τα μέσα χαρακτηριστικά των τυχαίων σημάτων. Ο μετασχηματισμός Fourier μιας αλληλουχίας αυτοσυσχέτισης δίνει την πυκνότητα του φάσματος ισχύος. Υπάρχουν μερικά μειονεκτήματα αυτής της μεθόδου. Πρώτον, η ποσότητα των δεδομένων είναι περιορισμένη και μπορεί να είναι πολύ μικρή. Αυτό μπορεί να συμβεί λόγω των χαρακτηριστικών των δεδομένων. Ένα δεύτερο πρόβλημα είναι η ποσότητα θορύβου που αλλοιώνει τα εγγεγραμμένα δεδομένα [54, 55]. Επομένως, η εκτίμηση ενός προβλήματος πυκνότητας φάσματος ισχύος περιλαμβάνει έναν πεπερασμένο αριθμό θορυβώδους μετρήσεων ενός σήματος $x(n)$. Το πρόβλημα εκτίμησης πυκνότητας ισχύος περιλαμβάνει δύο προσεγγίσεις. Η μία είναι μη παραμετρικές μέθοδοι, ενώ η άλλη είναι παραμετρικές μέθοδοι. Οι μη παραμετρικές μέθοδοι απαιτούν εννοιολογικά τον υπολογισμό της αλληλουχίας αυτοσυσχέτισης από δεδομένα δεδομένα και ο μετασχηματισμός Fourier αυτής της εκτιμώμενης αλληλουχίας αυτοσυσχέτισης δίνει το φάσμα ισχύος. Οι παραμετρικές μέθοδοι περιλαμβάνουν μοντελοποίηση της διαδικασίας για την εκτίμηση του φάσματος ισχύος [56]. Μια πεπερασμένη εγγραφή δεδομένων επηρεάζει την ποιότητα εκτίμησης του φάσματος ισχύος. Όσο μεγαλύτερη είναι η εγγραφή δεδομένων, τόσο καλύτερη είναι η εκτίμηση του φάσματος ισχύος για στατιστικά σταθερά σήματα. Σε μη στατικά στατιστικά σήματα, το μήκος μιας εγγραφής δεδομένων καθορίζεται από χρονικές διακυμάνσεις στα στατιστικά σήματος.

Η δειγματοληψία συνεχούς σήματος χρόνου $x_a(t)$ με ρυθμό δειγματοληψίας F_s δίνει την ακολουθία $x(n)$. Εάν το $x_a(t)$ είναι μια εξίσωση πεπερασμένου ενεργειακού σήματος σύμφωνα με το 3.20, τότε ο μετασχηματισμός Fourier υπάρχει και δίνεται όπως στην εξίσωση 3.21

$$E = \int_{-\infty}^{\infty} |x_a(t)|^2 dt < \infty \quad (3.20)$$

$$X_a(F) = \int_{-\infty}^{\infty} x_a(t) e^{-j2\pi Ft} dt \quad (3.21)$$

Σύμφωνα με το θεώρημα του Parseval:

$$E = \int_{-\infty}^{\infty} |x_a(t)|^2 dt = \int_{-\infty}^{\infty} |X_a(F)|^2 dF \quad (3.22)$$

$|X_a(F)|^2$ είναι το φάσμα ενεργειακής πυκνότητας του σήματος, καθώς αυτός ο όρος αντιπροσωπεύει την κατανομή ενέργειας σήματος ως συνάρτηση της συχνότητας:

$$S_{xx}(F) = |X_a(F)|^2 \quad (3.23)$$

Το τμήμα κάτω από το $S_{xx}(F)$ αντιπροσωπεύει τη συνολική ενέργεια του σήματος. Το $S_{xx}(F)$ είναι ο μετασχηματισμός Fourier της συνάρτησης αυτοσυσχέτισης $R_{xx}(\tau)$ του σήματος πεπερασμένης ενέργειας:

$$R_{xx}(\tau) = \int_{-\infty}^{\infty} x_a^*(t) x_a(t + \tau) dt \quad (3.24)$$

$$S_{xx}(F) = \int_{-\infty}^{\infty} R_{xx}(\tau) e^{-j2\pi F\tau} d\tau = |X_a(F)|^2 \quad (3.25)$$

Η εξίσωση 3.25 δείχνει ότι $S_{xx}(F)$ και $R_{xx}(\tau)$ είναι ένα ζεύγος μετασχηματισμού Fourier.

Το σήμα προ-φιλτράρεται και το εύρος ζώνης του είναι B Hertz που δίνει συχνότητα δειγματοληψίας $F_s > 2B$. Αυτή η ακολουθία δείγματος $x(n)$ έχει μετασχηματισμό Fourier:

$$X(f) = \sum_{n=-\infty}^{\infty} x(n) e^{-j2\pi fn} \quad (3.26)$$

Η αυτοσυσχέτιση του δείγματος σήματος μπορεί να δοθεί ως:

$$\gamma_{xx}(k) = \sum_{n=-\infty}^{\infty} x^*(n) x(n+k) \quad (3.27)$$

και ο μετασχηματισμός του Fourier είναι:

$$S_{xx}(f) = \sum_{k=-\infty}^{\infty} \gamma_{xx}(k) e^{-j2\pi kf} \quad (3.28)$$

Αυτό δείχνει ότι η φασματική πυκνότητα ισχύει και λαμβάνεται από τον μετασχηματισμό Fourier της αυτοσυσχέτισης του σήματος $x(n)$. Περιορίζοντας την διάρκεια του $x(n)$ σε N σημεία, $0 \leq n \leq N - 1$, μοιάζει με την εφαρμογή ορθογώνιου παραθύρου στο σήμα:

$$\bar{x}(n) = \begin{cases} x(n)w(n) = x(n) & \text{if } 0 \leq n \leq N - 1 \\ 0 & \text{otherwise} \end{cases} \quad (3.29)$$

Ο πολλαπλασιασμός δύο αλληλουχιών ισοδυναμεί με μια συνέλιξη των φασμάτων τους, δηλαδή:

$$\bar{X}(f) = X(f) * W(F) = \int_{-1/2}^{1/2} X(\alpha) W(f - \alpha) d\alpha \quad (3.30)$$

Το φάσμα $\bar{X}(f)$ εξομαλύνεται λόγω της συνέλιξης της με το παράθυρο $W(f)$, με την προϋπόθεση ότι το φάσμα του $W(f)$ είναι στενότερο από το $\bar{X}(f)$, δηλαδή, $w(n)$ πρέπει να είναι αρκετά μεγάλο. Η στενότητα του $W(f)$ από το $\bar{X}(f)$ δεν βοηθά στη μείωση των πλευρικών λοβών στο φάσμα $\bar{X}(f)$. Αυτό το πρόβλημα διαρροής μπορεί να μειωθεί χρησιμοποιώντας ένα παράθυρο με ομαλή αποκοπή τομέα, σε αντίθεση με τα ορθογώνια παράθυρα. Αλλά έχει ως αποτέλεσμα αυξημένη απώλεια της ανάλυσης συχνότητας στο $\bar{X}(f)$, κάτι που δεν είναι επιθυμητό να διακρίνουμε τα στενά διαχωρισμένα στοιχεία σήματος στο φάσμα. Μια προσέγγιση του επιθυμητού φάσματος της ακολουθίας $x(n)$ δίνει την φασματική πυκνότητα ισχύος:

$$S_{\bar{x}\bar{x}}(f) = |\bar{X}(f)|^2 = \left| \sum_{n=0}^{N-1} \bar{x}(n) e^{-j2\pi fn} \right|^2 \quad (3.31)$$

Έτσι για $f = k/N$

$$S_{\bar{x}\bar{x}}(f) = S_{\bar{x}\bar{x}}(k/N) = \sum_{n=0}^{N-1} \bar{x}(n) e^{-j2\pi kn} \quad (3.32)$$

που μας δίνει μια παραμετροποιημένη έκδοση του πραγματικού φάσματος,

$$S_{\bar{x}\bar{x}}(k/N) = \left| \sum_{n=0}^{N-1} \bar{x}(n) e^{-j2\pi kn/N} \right|^2 \quad (3.33)$$

3.2.2 Η μη παραμετρική μέθοδος του Welch

Έχουν αναπτυχθεί αρκετές μέθοδοι για την εύρεση φασματικής πυκνότητας ισχύος όπου δεν χρησιμοποιούν καμία παραδοχή για τον τρόπο δημιουργίας των δεδομένων, επομένως είναι γνωστές ως μη παραμετρικές μέθοδοι. Οι συνεπείς εκτιμήσεις της φασματικής πυκνότητας ισχύος λαμβάνονται με εξομάλυνση ή υπολογίζοντας τον μέσο όρο των διαδικασιών στην αυτοσυσχέτιση. Οι μη παραμετρικές μέθοδοι μειώνουν τη διακύμανση στις εκτιμήσεις της φασματικής πυκνότητας ισχύος (καθιστώντας το μια συνεπή εκτίμηση) αλλά με το κόστος της ανάλυσης μειωμένης συχνότητας [57]. Μια δημοφιλής μέθοδος εκτίμησης της φασματικής πυκνότητας ισχύος είναι η μέθοδος Welch.

Η μέθοδος Welch είναι ένας εκτιμητής που εκμεταλλεύεται το περιόδγραμμα. Ουσιαστικά χωρίζει σε επικαλύπτομενα τμήματα την είσοδο (δεδομένα) και υπολογίζει την μέση τιμή των περιодоγραμμάτων [58]. Η επικάλυψη είναι συνήθως 50% ή 75% με την χρήση παραθύρων. Έστω L το μήκος των τμημάτων. Συμβολίζουμε με $\{x_i(n)\}_0^{L-1}$ και D το πλήθος διαδοχικών μετατοπισμένων τμημάτων. Τότε

$$N = L + D(K - 1) \quad (3.34)$$

όπου N ο συνολικός αριθμός των δειγμάτων και K ο συνολικός αριθμός ακολουθιών. Εάν δεν υπάρχουν επικαλύψεις τότε $K = N/L$ και εάν υπάρχει επικάλυψη 50%, τότε $K = 2N/L - 1$. Τότε η i -οστή ακολουθία ορίζεται ως:

$$x_i(n) = x(n + (i - 1)D), \quad n \in \{0, 1, \dots, L - 1\} \quad (3.35)$$

όπου $i = 1, 2, \dots, K$ και το περιόδγραμμα ορίζεται ως:

$$\bar{P}_M^{(i)}(f) = \frac{1}{L} \left| \sum_{n=0}^{L-1} w(n)x_i(n)e^{-j2\pi fn} \right|^2 \quad (3.36)$$

Το $\bar{P}_M^{(i)}(f)$ είναι το παραμετροποιημένο περιόδγραμμα καθώς στα δείγματα $x(x)$ έχουν εφαρμοστεί βάρη, τα μη ορθογώνια $w(n)$. Επομένως η εκτίμηση της φασματικής πυκνότητας ισχύος από τη μέθοδο Welch δίνεται από:

$$\bar{P}_B(f) = \frac{1}{K} \sum_{i=1}^K \bar{P}_M^{(i)}(f) \quad (3.37)$$

Με την μέθοδο Welch εάν διατηρούμε τον ίδιο αριθμό τμημάτων, η επικάλυψη μας επιτρέπει να έχουμε μεγαλύτερα τμήματα. Ο αυξημένος αριθμός τμημάτων μειώνει τη διακύμανση του εκτιμητή και τα μεγαλύτερα τμήματα βελτιώνουν την ανάλυσή του [59].

Κεφάλαιο 4

Πειραματική Διαδικασία και Μεθοδολογία Επεξεργασίας και Ανάλυσης Δεδομένων

4.1 Βιβλιογραφική Ανασκόπηση

Σε αυτή την ενότητα θα κάνουμε μια βιβλιογραφική ανασκόπηση και θα συζητήσουμε τι έχει μελετηθεί ήδη στην παρατήρηση της νοητικής κόπωσης.

Σε μια έρευνα [60] που πραγματοποιήθηκε προκειμένου να μελετηθεί η νοητική κόπωση βάση του πειράματος N-Back, οι συμμετέχοντες τους ζητήθηκε να βλέπουν σε μία οθόνη γράμματα της αλφαβήτου και πατώντας το αντίστοιχο κουμπί θα επέλεγαν εάν το συγκεκριμένο γράμμα είναι ο στόχος ή όχι. Εάν η κατάσταση του N-Back είναι 0, τότε το γράμμα είναι ο στόχος, εάν είναι 1, τότε είναι στόχος εάν το ακριβώς προηγούμενο γράμμα είναι το ίδιο κ.ο.κ. Προχώρησαν στην δημιουργία 5 μοντέλων ταξινόμησης.

1. Τα ERP's που εξήγαγαν για το πρώτο μοντέλο με συχνότητα δειγματοληψίας 100 Hz προέκυπταν από 7 κανάλια HEG και τα χρησιμοποίησαν σαν χαρακτηριστικά (features), δηλαδή $101(samples) \times 7 = 707 features$
2. Όσο αναφορά το μοντέλο που αφορά τα features που προκύπτουν από την φασματική πυκνότητα ισχύος πραγματοποίησαν ανάλυση Fourier από -500 έως 1500 ms σε σχέση με το ερέθισμα με μπάντες συχνοτήτων από 2 Hz έως 20 Hz με βήμα 0.5 Hz. Επομένως $7 \times 37(samples) = 259 features$.
3. Στο τρίτο μοντέλο συγχώνευσαν τα features των 2 παραπάνω μοντέλων, δηλαδή $707 + 250 = 966 features$.
4. Στο τέταρτο μοντέλο είναι όπως το ERP μοντέλο αλλά τα χαρακτηριστικά προέκυψαν για κάθε εποχή για στόχο ή μη στόχο, Επομένως είναι το διπλάσιο από το πρώτο άρα 1414 features.
5. Στο τελευταίο μοντέλο συγχώνευσαν το 2 και το 4, επομένως $1414 + 259 = 1673 features$.

Για το μοντέλο που χρησιμοποιεί ως χαρακτηριστικά την φασματική πυκνότητα ισχύος, πραγματοποιήθηκε ταξινόμηση μεταξύ 0-back και 2-back καταστάσεις, φάνηκαν διαφορές στις συχνότητες άλφα (8-12 Hz) στο ηλεκτρόδιο Pz και στα εμπρόσθια σημεία του εγκεφάλου στις συχνότητες θήτα (4-8 Hz). Στις κανονικοποιημένες τιμές τις φασματικής πυκνότητας παρατηρήθηκε διαφορά στις συχνότητες θήτα.

Σε μια άλλη έρευνα [61] με την ίδια μέθοδο N-Back με διαφορά ότι στην συγκεκριμένη χρησιμοποιήθηκαν εικόνες και όχι γράμματα συμμετείχαν 20 νέοι από 21-34 ετών. Τα αποτελέσματα στατιστικής ανάλυσης των ERP's έδειξε σημαντικότητα στην κορυφή P300 στην δυσκολία 2-Back

στα ηλεκτρόδια Fz, Cz και Pz. Αυτό σημαίνει ότι το εμπρόσθια ηλεκτρόδια έδειξε μεγαλύτερη διαφορά στην P300 μεταξύ νεότερων και μεγαλύτερων από τους συμμετέχοντες σε σχέση με τα πλευρικά ηλεκτρόδια. Η ανάλυση στην φασματική πυκνότητα που επικεντρώθηκε στα Fz, Cz και Pz, έδειξε σημαντική διαφορά στις άλφα και θήτα συχνότητες στο Cz. Επίσης οι διαφορές μεταξύ νεότερων και μεγαλύτερων από τους συμμετέχοντες βρέθηκαν στις άλφα συχνότητες στα Cz, FC2 και F4, δεδομένου ότι οι νεότεροι είχαν υψηλότερες τιμές φασματικής πυκνότητας ισχύος στις άλφα συχνότητες. Συμπερασματικά ανακάλυψαν διαφορές στην κορυφή P300 στις συχνότητες άλφα και θήτα όπου εκτιμήθηκε και η παράμετρος της ηλικίας. Συγκεκριμένα για τους μεγαλύτερους η κόπωση μπορεί να επηρεάσει την απόδοση τους στο πείραμα.

Σε έρευνα [62] που συμμετείχαν 28 άτομα με μέση ηλικία 21.5 και δεξιόχειρες κλήθηκαν να εκτελέσουν δύο εργασίες, μια N-back και μια αριθμητική. Τα ηλεκτροεγκεφαλογραφήματα καταγράφηκαν από 64 επιφανειακά ηλεκτρόδια με συχνότητα δειγματοληψίας 256Hz. Τα χαρακτηριστικά για την ταξινόμηση εξήχθησαν από τις φασματικές πυκνότητες ισχύος και έπειτα δημιουργήθηκαν οι λειτουργικές συνδέσεις μεταξύ περιοχών του εγκεφάλου. Συνολικά εξήχθησαν 12640 χαρακτηριστικά και εφαρμόστηκαν αλγόριθμοι επιλογής χαρακτηριστικών. Ως αποτέλεσμα της έρευνας και των δύο εργασιών επιλέχθηκαν δίκτυα που αφορούν κυρίως τις συχνότητες θήτα και βήτα στον εμπρόσθιο λοβό. Όσο αναφορά στην εργασία N-Back επιλέχθηκαν άλλες δύο συνδέσεις στις συχνότητες θήτα και άλφα, ενώ στην αριθμητική εργασία προστέθηκαν άλλες 6 συνδέσεις στις βήτα συχνότητες στο εμπρόσθιο μέρος του εγκεφάλου.

Τέλος σε έρευνα [63] που συμμετείχαν 10 νέοι άντρες ηλικίας 22 έως 28 ετών κλήθηκαν να εκτελέσουν 3 εργασίες N-Back νοητικής κόπωσης κλιμακωτής δυσκολίας. Οι εικόνες αναφέρονταν σε ένα πλέγμα 3×3 και ένα κουτάκι που κινείται σε αυτό. Στις επόμενες εργασίες προστέθηκε και ήχος. Μετά από μεθόδους εξαγωγής χαρακτηριστικών καταλήξαν σε 1680 features από HEG 16 καναλιών στις 5 μπάντες συχνοτήτων (δέλτα, θήτα, άλφα, βήτα, γάμμα). Μετά από ανάλυση των 3 πειραμάτων παρατήρησαν μικρή νοητική κόπωση στην εργασία 1ης δυσκολίας με 99.2% επιτυχία. Στην εργασία 2ης δυσκολίας ανέφεραν 95.8% επιτυχία και στην τελευταία με 54.6% επιτυχία. Η ανάλυση στα επιλεγμένα χαρακτηριστικά έδειξε σημαντικότητα στα O1, P4 και O3. Όλες οι μπάντες συχνοτήτων είχαν την ίδια σημασία στην ταξινόμηση. Συμπεράναν ότι η κόπωση που προκαλείται από συγκεκριμένες εργασίες μπορεί να έχει κάποιες διαφορές από την κόπωση στην καθημερινή εργασία, έτσι η σημασία των διαφόρων ειδών κόπωσης πρέπει να ερευνηθεί στο μέλλον.

4.2 Πειραματική Διαδικασία και Μεθοδολογία Επεξεργασίας και Ανάλυσης Δεδομένων

4.2.1 Πειραματική Διαδικασία

Στην έρευνα συμμετείχαν 40 άτομα μεταξύ 22-40 ετών: Ιατροί και νοσηλευτικό προσωπικό του 401 Γενικού Στρατιωτικού Νοσοκομείου Αθηνών. Από την έρευνα εξαιρούνται άτομα με τα ακόλουθα κριτήρια:

- Χρόνιες σωματικές ή ψυχιατρικές διαταραχές.
- Ιστορικό κατάχρησης φαρμάκων ή αλκοόλ.
- Μεταλλικά αντικείμενα στο σώμα.
- Κλειστοφοβία.
- Ιστορικό νευρολογικής βλάβης ή ασθένειας.

Οι πειραματικές εργασίες σχεδιάστηκαν για να ανιχνεύσουν την νοητική κόπωση μετά από στέρηση ύπνου. Οι συμμετέχοντες χωρίστηκαν σε δύο ομάδες, την ομάδα νοητικής κόπωσης (όπου περιλαμβάνονται άτομα μετά από εφημερία) και την ομάδα ελέγχου. Αμφότερες οι ομάδες πραγματοποίησαν τις ίδιες γνωστικές εργασίες, μία καταγραφή της κατάστασης ηρεμίας, μία εργασία Ψυχοκινητικής Επαγρύπνησης [Psychomotor Vigilance Test, PVT] και δύο εργασίες Λειτουργικής Μνήμης (ΛΜ) [N-Back, NB και Paced Auditory Serial Addition Test, PASAT], για την αξιολόγηση της απόδοσης τους σε δύο συνεδρίες.

Στην ομάδα νοητικής κόπωσης οι εργασίες υλοποιούνται πριν και μετά από εφημερία στο 401 Γενικό Στρατιωτικό Νοσοκομείο Αθηνών, ενώ η ομάδα ελέγχου πραγματοποιεί τις εργασίες δυο διαδοχικές μέρες προκειμένου να ελεγχθεί τυχόν παράγοντας εκπαίδευσης που μπορεί να βελτιώσει τα αποτελέσματα των εργασιών. Όσον αφορά τις εργασίες ΛΜ μια σύντομη εκπαίδευση έλαβε χώρα πριν από την έναρξη των καταγραφών των σημάτων ΗΕΓ και δεν δόθηκε ανατροφοδότηση στους συμμετέχοντες σχετικά με την ορθότητα της κάθε απάντησης. Επίσης, κατά την εργασία NB κάθε εικόνα παρουσιάστηκε στους συμμετέχοντες μόνο μία φορά σε όλο το πείραμα. Οι εργασίες εφαρμόστηκαν με την χρήση του πλαισίου Psychopy στη γλώσσα προγραμματισμού Python.

Συνολικά τα ΗΕΓ σήματα καταγράφηκαν για 20 περίπου λεπτά, ενώ πριν και μετά το πέρας των καταγραφών συμπληρώθηκε ένα σύντομο ερωτηματολόγιο της υποκείμενης κατάστασης των συμμετεχόντων [σύντομο ερωτηματολόγιο καταστάσεων άγχους, SSSQ] στην αρχή και στο τέλος κάθε συνεδρίας. Κατά την εκτέλεση των παραπάνω εργασιών έλαβαν μέρος ταυτόχρονα ηλεκτροφυσιολογικές καταγραφές (ΗΕΓ).


Οι εργασίες περιλαμβάνουν:

- **Καταγραφή κατάστασης ηρεμίας:** Διάρκεια 5 λεπτά, όπου ο συμμετέχων πρέπει να κοιτά ένα σταυρό στο κέντρο της οθόνης.
- **Εργασία ψυχοκινητικής επαγρύπνησης (Psychomotor Vigilance Test, PVT):** Είναι μια διανοητικά απαιτητική δοκιμασία χρόνου αντίδρασης, η οποία χρησιμοποιείται για την πρόκληση και την παρακολούθηση νοητικής κόπωσης, προβλέποντας σφάλματα που προκαλούνται με την κατάρπωση της προσοχής σχήμα (Σχήμα 4.1). Πιο αναλυτικά, κατά τη διάρκεια περιόδων συνεχώς αυξανόμενου γνωστικού φορτίου εργασίας παρατηρείται ότι η απόδοση χειροτερεύει με επακόλουθο βραδύτερους χρόνους αντίδρασης και αυξημένη αξιολόγηση κούρασης [64, 65, 66].

Σε αυτή την εργασία, ο κάθε συμμετέχων του ζητήθηκε να πατήσει ένα κουμπί, το συντομότερο δυνατόν, όταν ένας μετρητής εμφανίζεται στην οθόνη. Συγκεκριμένα, ο μετρητής εμφανίζεται μετά από ένα τυχαίο διάστημα, που ποικίλει από 2 έως 10 δευτερόλεπτα και παραμένει ενεργός μέχρι να δοθεί μια απάντηση ή να περάσουν 4 δευτερόλεπτα. Η εργασία αυτή εκτελείται για 5 λεπτά και η απάντηση του συμμετέχοντος καταγράφεται από τον κατάλληλο δείκτη. Επισημαίνουμε ότι συνήθως η διάρκεια της PVT είναι 10 έως 20 λεπτά [66], αλλά σε αυτές τις περιπτώσεις η PVT χρησιμοποιείται και για να προκαλέσει κόπωση. Η παρούσα έρευνα επικεντρώνεται στα αποτελέσματα των χρόνων απόκρισης της PVT και στις εγκεφαλικές καταγραφές κατά την διάρκεια της, καθώς ο μεγάλος βαθμός κόπωσης έχει επέλθει με 24ωρη στέρηση ύπνου.

Οι εργασίες Λειτουργικής Μνήμης είναι οι εξής:

- **N-Back:** Είναι μια χωροχρονική εργασία Λειτουργικής Μνήμης (ΛΜ), η οποία μπορεί να προσεγγίσει τον χειρισμό φορτίων ΛΜ από τον εγκέφαλο [67, 68]. Κατά την διάρκεια αυτής



Σχήμα 4.1: PVT, Η απόκριση μετρείται συνεχώς, σημειώνοντας τον χρόνο αντίδρασης, τη συχνότητα που πατιέται το κουμπί, την καθυστέρηση και τις περιπτώσεις λανθασμένων απαντήσεων.

της εργασίας, οι συμμετέχοντες κλήθηκαν να θυμηθούν την εικόνα που εμφανίζεται N φορές πριν και να την συγκρίνουν με την τρέχουσα [69, 70]. Η διαδοχική φύση της εργασίας απαιτεί ταυτόχρονη γνωστική αποθήκευση και επεξεργασία των γνωστικών διεργασιών, συμπεριλαμβανομένων των επιλογών, παρεμβολών και αναστολών που λαμβάνουν χώρα τη στιγμή που ένα οπτικό ερέθισμα κωδικοποιείται σχετικά με τη θέση και τον τύπο του, για να συγκριθεί στη συνέχεια με εκείνο που εμφανίζεται πίσω στην αλληλουχία [71].

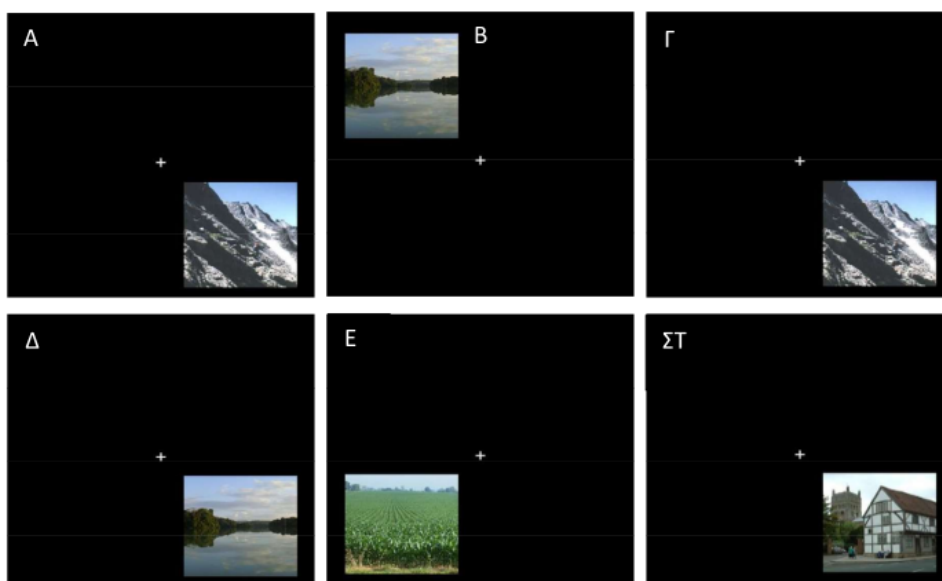
Στη παρούσα έρευνα $N = 2$, δηλαδή ο συμμετέχων πρέπει να θυμηθεί τις τελευταίες δύο εικόνες. Οι εικόνες εμφανίζονται στις τέσσερις γωνίες της οθόνης και υπάρχουν τέσσερις προϋποθέσεις τις οποίες ο συμμετέχων ζητείται να υποδείξει με το πάτημα του αντίστοιχο κουμπιού (Σχήμα 4.2).

- Ίδια εικόνα και ίδια θέση.
- Ίδια εικόνα (διαφορετική θέση).
- Ίδια θέση.
- Καμία ομοιότητα (διαφορετική εικόνα, διαφορετική θέση).

Το πείραμα αυτό αποτελείται από 72 δοκιμασίες (4 ισορροπημένες συνθήκες) και διαρκεί περίπου 5 λεπτά. Τα οπτικά ερεθίσματα απεικονίζονται για 2,5 δευτερόλεπτα και στη συνέχεια ένας σταθερός σταυρός για 1 δευτερόλεπτο. Κάθε υπόδειξη του συμμετέχοντος καθώς και τα οπτικά ερεθίσματα καταγράφονται με τους κατάλληλους δείκτες.


- **Ακουστική Δοκιμασία Σειριακής Πρόσθεσης (Paced Auditory Serial Addition Test, PASAT):** Είναι μια εργασία συνεχούς εκτέλεσης σειριακών προσθέσεων η οποία σχετίζεται με τη ΛΜ, την ταχύτητα επεξεργασίας πληροφοριών και την παρατεταμένη προσοχή [72, 73, 74, 75, 76].

Κατά την εκτέλεση της PASAT, ο συμμετέχων πρέπει να προσθέσει κάθε αριθμό στον αριθμό που ακολουθεί, έτσι ώστε ο πρώτος αριθμός να προστεθεί στον δεύτερο αριθμό, ο δεύτερος αριθμό να προστεθεί στον τρίτο αριθμό, κ.ο.κ. Ο συμμετέχων κατά αυτό τον τρόπο πρέπει να κατανοήσει την ακουστική είσοδο, να συγκρατήσει τον αριθμό στη ΛΜ και να προσθέσει τους δύο προηγούμενου αριθμούς, ανταποκρινόμενος προφορικά. Πραγματοποιείται για 4 λεπτά σε κάθε συνεδρία και περιλαμβάνει 60 δοκιμασίες όπου τα ακουστικά ερεθίσματα παρουσιάζονται για 1 δευτερόλεπτο το κάθε ένα, ενώ απέχουν μεταξύ τους 3 δευτερόλεπτα (Σχήμα 4.3)



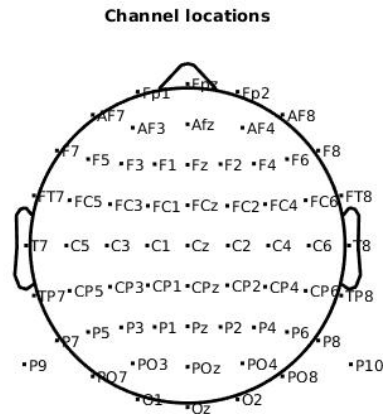
Σχήμα 4.2: PVT, Η απόκριση μετρείται συνεχώς, σημειώνοντας τον χρόνο αντίδρασης, τη συχνότητα που πατιέται το κουμπί, την καθυστέρηση και τις περιπτώσεις λανθασμένων απαντήσεων.

[77, 78, 79]. Στην παρούσα έρευνα, κάθε φορά που θα εκφωνείται ένας αριθμός ένας δείκτης θα καταγράφεται ταυτόχρονα στα δεδομένα εγκεφαλογραφήματος έτσι παρέχοντας τον ακριβή χρόνο για κάθε ακουστικό ερέθισμα. Ο συμμετέχων θα πατάει ένα κουμπί πριν δώσει την απάντησή του. Αυτό το κουμπί θα καταγράφει έναν άλλο δείκτη στις συνεχείς καταγραφές. Κατά την διάρκεια του πειράματος η οθόνη θα είναι κενή με ένα σταυρό στο κέντρο έτσι ώστε να αποφύγουμε την απόσπαση της προσοχής του συμμετέχοντα και τον πιθανό θόρυβο από κινήσεις των ματιών και της κεφαλής.



Σχήμα 4.3: Παράδειγμα εργασίας PASAT. Ο συμμετέχων καλείται να απαντήσει για το άθροισμα των δύο αριθμών που προηγήθηκαν.

Για την ανάλυση των καταστάσεων νοητικής κόπωσης πραγματοποιήθηκαν καταγραφές, οι οποίες αποθηκεύτηκαν σε ψηφιακή μορφή και περιλαμβάνουν **Καταγραφές Ηλεκτροεγκεφαλογραφήμα-**



63 of 63 electrode locations shown

Σχήμα 4.4: Τοπολογία των ηλεκτροδίων που χρησιμοποιήθηκε .

τος (HEΓ) υψηλής ανάλυσης από 64 κανάλια τοποθετημένα στο τριχωτό της κεφαλής σύμφωνα με το διεθνές σύστημα 10-20 (Σχήμα 4.4), με αναφορά στο μέσο όρο των καταγραφών στις μαστοειδείς αποφύσεις στα εσωτερικά των αυτιών (M1 και M2) [80]. Οι καταγραφές έλαβαν χώρα στο 401 Γενικό Στρατιωτικό Νοσοκομείο Αθηνών με χρήση του ηλεκτροεγκεφαλογράφου 64 καναλιών Biosemi ActiveTwo Mk2 with two-wire active electrodes του Εργαστηρίου Βιοϊατρικής Οπτικής και Εφαρμοσμένης Βιοφυσικής του Εθνικού Μετσόβιου Πολυτεχνείου.


Παρακάτω θα παρουσιάσουμε την μεθοδολογία που ακολουθήθηκε στην επεξεργασία και ανάλυση των δεδομένων που λήφθηκαν από την πειραματική διαδικασία. Για την επεξεργασία και ανάλυση των πειραματικών δεδομένων και οι υλοποιήσεις των αλγορίθμων χρησιμοποιήθηκαν η γλώσσα προγραμματισμού και εργαλείο **MATLAB** καθώς και η βιβλιοθήκη **EEGLAB**.

Αρχικά αφού λάβαμε τα δεδομένα, έγινε μια προεπεξεργασία για να απαλειφθεί τυχόν θόρυβος και να έρθουν στην μορφή όπως το σχήμα 4.5. Συχνότητα δειγματοληψίας των HEΓ ήταν 256Hz με 1024 χρονικές στιγμές που σημαίνει 4 δευτερόλεπτα καταγραφή για κάθε εποχή (epoch) του HEΓ. Η μέτρηση ξεκινάει -500ms πριν το ερέθισμα, επομένως το ερέθισμα συμβαίνει στο 0.

4.2.2 Εξαγωγή Χαρακτηριστικών - Feature Extraction

Για την εξαγωγή χαρακτηριστικών προκειμένου να γίνει η ταξινόμηση εξήχθη η φασματική πυκνότητα ισχύος (Power Spectral Density - PSD) για κάθε υποκείμενο (subject) προκειμένου να χρησιμοποιηθούν σαν χαρακτηριστικά (features) στο στάδιο της ταξινόμησης (classification). Η μέθοδος που χρησιμοποιήθηκε είναι η μέθοδος του Welch (*MATLAB function pwelch()*) που παρουσιάστηκε στην ενότητα 3.2.2. Αρχικά υπολογίστηκε το PSD για όλο το μήκος της χρονοσειράς και έπειτα σε συγκεκριμένα χρονικά παράθυρα που θεωρήσαμε σημαντικά προς περαιτέρω έρευνα. Στα επιλεγμένα χρονικά παράθυρα χρησιμοποιήθηκε παράθυρο μήκους 125 ms. Στο σχήμα 4.6 παρουσιάζεται ο αλγόριθμος που χρησιμοποιήθηκε για τον υπολογισμό της Φασματικής Πυκνότητας Ισχύος και στο σχήμα 4.7 φαίνεται ένα παράδειγμα της φασματικής πυκνότητας ισχύος για το ηλεκτρόδιο Cz για ένα subject. Επίσης υπολογίστηκαν και η **Σχετική Φασματική Πυκνότητα Ισχύος (Relative Power Spectral Density)** για την αποφυγή της κανονικοποίησης με βάση τον τύπο:

$$\frac{PSD_{freq_band}}{PSD_{delta} + PSD_{theta} + PSD_{alpha} + PSD_{beta} + PSD_{gamma}} \quad (4.1)$$



Σχήμα 4.5: Το EEG ενός subject. Στον οριζόντιο άξονα φαίνονται οι χρονικές στιγμές και στον κατακόρυφο τα 63 ηλεκτρόδια με τις αντίστοιχες απαγωγές ανά χρονική στιγμή.

```

for all ep in epochs do
  for all electrode in electrodes do
    compute pwelch(inputData(electrode,ep))
    compute mean of each frequency band per electrode
  end for
  compute mean of ep
end for

```


Σχήμα 4.6: Ο αλγόριθμος υπολογισμού Φασματικής Πυκνότητας Ισχύος

όπου,

$$freq_band \in \{delta, theta, alpha, beta, gamma\}$$

4.2.3 Επιλογή χαρακτηριστικών και Ταξινόμηση

Το επόμενο στάδιο ήταν η ταξινόμηση ή αλλιώς classification. Όπως αναφέραμε για την ταξινόμηση αρχικά εκτελούμε τους ταξινομητές για τα δεδομένα εκπαίδευσης (training data) και έπειτα κάνουμε προβλέψεις στα δεδομένα ελέγχου (testing data). Για training data είχαμε 20 subjects σε καταστάσεις νοητικής και μη κόπωσης αντίστοιχα και για testing data 19 subjects αντίστοιχα. Σαν χαρακτηριστικά χρησιμοποιήσαμε τα δεδομένα που προκύψαν από την φασματική πυκνότητα ισχύος. Δεδομένου λοιπόν 63 απαγωγών (64 ηλεκτρόδια) και 5 μάντες συχνοτήτων (delta, theta, alpha, beta, gamma) μας δίνουν συνολικά $63 \times 5 = 315$ χαρακτηριστικά (features). Οι ταξινομητές που χρησιμοποιήθηκαν είναι ο **Γραμμικός SVM** και ο **kNN** που παρουσιάστηκαν στις ενότητες 3.1.4 και 3.1.5 αντίστοιχα με την βοήθεια του *Classification Learner App* του *MATLAB* με **Cross-Validation k-fold** = 5. Προκειμένου όμως να αυξήσουμε την ακρίβεια των ταξινομητών εφαρμόστηκαν πρώτα αλγόριθμοι **Επιλογής Χαρακτηριστικών (Feature Selection)**.



Σχήμα 4.7: Φασματική Πυκνότητα Ισχύος του ηλεκτροδίου Cz ανελυμένο στα 4Hz.

Παρακάτω αναφέρουμε τους αλγορίθμους **Feature Selection** που χρησιμοποιήθηκαν [81].

1. Infinite Latent Feature Selection (ILFS)
2. Infinite Feature Selection (InfFS)
3. Eigenvector Centrality Feature Selection (ECFS)
4. Minimum Redundancy Maximum Relevance Feature Selection (mrmr)
5. Relief Based Feature Selection (relieff)
6. Mutual Information-Based Feature Selection (mutinffs)
7. FSV
8. Laplacian
9. Multi-Cluster Feature Selection (mcfs)
10. Recursive Feature Elimination (rfe)
11. L0-Norm Feature Selection (L0)
12. Fisher

13. Unsupervised Discriminative Feature Selection (UDFS)
14. Logical Learning Clustering Feature Selection (llcfs)
15. Correlation Based Feature Selection (cfs)
16. Unsupervised Feature Selection with Adaptive Structure Learning (fsasl)
17. Dependence Guided Unsupervised Feature Selection (dgufs)
18. Unsupervised Feature Selection with Ordinal Locality (ufsol)
19. Lasso Regression (lasso)

Στο επόμενο κεφάλαιο παρουσιάζουμε τα αποτελέσματα του classification με βάση τους αλγόριθμους Feature Selection από δύο ταξινομητές.

Κεφάλαιο 5

Παρουσίαση Αποτελεσμάτων

Παρακάτω παρουσιάζονται οι πίνακες με τα αποτελέσματα των ταξινομητών Linear SVM και KNN. Σε κάθε πίνακα φαίνονται ο αλγόριθμος Feature Selection που παρουσίασε το καλύτερο Accuracy, το Accuracy του ταξινομητή και τα ηλεκτρόδια (Features) που επιλέχθηκαν (*{electrode location}* – *{band waves}*). Ο χρονική στιγμή που ξεκινάει η μέτρηση είναι -500 ms και το ερέθισμα γίνεται στο 0. Τα διαγράμματα παρουσιάζουν την πρόοδο του accuracy συναρτήσει τον αριθμό των χαρακτηριστικών που εκπαιδευόταν το μοντέλο του ταξινομητή. Σε κάθε διάγραμμα σημειώνεται και το καλύτερο accuracy με έναν κόκκινο κύκλο. Υπενθυμίζουμε τις μπάντες συχνοτήτων:

- delta: 0.5 - 4 Hz
- theta: 4 - 7 Hz
- alpha: 8 -13 Hz
- beta: 13 - 30 Hz
- gamma: 31 - 45 Hz

5.1 N-Back

Με τον ταξινομητή Linear SVM για όλη την χρονοσειρά (Πίνακας 5.1) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλευρικά (parietal), και εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες δέλτα (Σχήμα A.1).

Feature Selection Algorithm	Accuracy	Features
fsasl	97.368%	Fpz-delta, Pz-delta, P9-delta, P10-delta, AF7-delta, C6-delta

Πίνακας 5.1: Πείραμα N-Back με Linear SVM για όλη τη χρονοσειρά

Με τον ταξινομητή KNN για όλη την χρονοσειρά (Πίνακας 5.2) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες δέλτα και θήτα (Σχήμα A.2).

Feature Selection Algorithm	Accuracy	Features
fisher	69.44%	C2-delta, FT8-theta, Cz-delta, FC1-delta, FC2-delta, CP2-theta, CP2-delta, Fz-delta, AF8-delta, CP1-delta, CPz-delta

Πίνακας 5.2: Πείραμα N-Back με KNN για όλη τη χρονοσειρά

Με τον ταξινομητή Linear SVM για όλη τη χρονοσειρά και Relatives PSD (Πίνακας 5.3) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλευρικά (parietal) , εμπρόσθια (frontal) και κεντρικά σημεία του εγκεφάλου στις συχνότητες δέλτα και άλφα (Σχήμα A.3).

Feature Selection Algorithm	Accuracy	Features
mcf5	69.44%	PO8-delta, FC1-delta, F2-delta, CP4-alpha, PO4-delta

Πίνακας 5.3: Πείραμα N-Back με Linear SVM για όλη τη χρονοσειρά και Relatives PSD

Με τον ταξινομητή KNN για όλη την χρονοσειρά (Πίνακας 5.4) χρησιμοποιώντας ως χαρακτηριστικά τα Relatives PSD, τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλευρικά (parietal) , εμπρόσθια (frontal) και στα κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες δέλτα και άλφα (Σχήμα A.4).

Feature Selection Algorithm	Accuracy	Features
mcf5	77.778%	PO8-delta, FC1-delta, F2-delta, CP4-alpha, PO4-delta, T7-delta, TP8-delta, C4-delta, PO4-alpha, CP5-delta

Πίνακας 5.4: Πείραμα N-Back KNN για όλη τη χρονοσειρά και Relatives PSD

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.5) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες θήτα (Σχήμα A.5).

Feature Selection Algorithm	Accuracy	Features
L0	95%	FT7-theta, P9-theta, F8-theta, O1-theta, AF3-theta

Πίνακας 5.5: Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.6) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες θήτα (Σχήμα A.6).

Feature Selection Algorithm	Accuracy	Features
fsv	95%	FT7-theta, P3-theta, P9-theta, CPz-theta, PO7-gamma, PO8-theta, AF3-theta, F8-theta, O1-theta, Pz-theta, CP5-theta, CP1-theta, F1-theta, F4-theta, Afz-theta, F2-theta, FC5-theta, Fpz-theta, CP2-theta

Πίνακας 5.6: Πείραμα N-Back KNN για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.7) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες δέλτα και γάμμα (Σχήμα A.7).

Feature Selection Algorithm	Accuracy	Features
dgufs	95%	FC1-gamma, O2-gamma, Fp1-delta, AF3-delta, F1-delta, F3-delta, F5-delta

Πίνακας 5.7: Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.8) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες θήτα (Σχήμα A.8).

Feature Selection Algorithm	Accuracy	Features
L0	95%	P9-alpha, FT7-theta, P5-theta, F8-theta, CP2-theta, FC5-theta

Πίνακας 5.8: Πείραμα N-Back KNN για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή N-Back Linear SVM για το χρονικό παράθυρο 312,5 - 437,5 ms (Πίνακας 5.9) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στον ινιακό λοβό του εγκεφάλου στις συχνότητες θήτα (Σχήμα A.9).

Feature Selection Algorithm	Accuracy	Features
ecfs	94.872%	O1-beta, O1-theta, O1-alpha, O1-delta, O1-gamma, F2-theta

Πίνακας 5.9: Πείραμα N-Back Linear SVM για το χρονικό παράθυρο 312,5 - 437,5 ms

Με τον ταξινομητή N-Back KNN για το χρονικό παράθυρο 312,5 - 437,5 ms (Πίνακας 5.10) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) σημεία του εγκεφάλου σε όλο το φάσμα συχνοτήτων (Σχήμα A.10).

Feature Selection Algorithm	Accuracy	Features
ufsol	74.359%	Fp1-delta, AF3-delta, AF3-theta, Fp1-theta, F2-theta, F2-alpha, F2-delta, O1-gamma, F8-theta, C4-beta, C4-alpha, C4-theta, Fp1-gamma, F8-alpha, Oz-theta

Πίνακας 5.10: Πείραμα N-Back KNN για το χρονικό παράθυρο 312,5 - 437,5 ms

Με τον ταξινομητή N-Back LinearSVM για το χρονικό παράθυρο 375-500 ms (Πίνακας 5.11) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες θήτα (Σχήμα A.11).

Feature Selection Algorithm	Accuracy	Features
fsv	84.615%	Afz-theta, F4-theta, P2-theta, AF3-theta

Πίνακας 5.11: Πείραμα N-Back LinearSVM για το χρονικό παράθυρο 375-500 ms

Με τον ταξινομητή N-Back KNN για το χρονικό παράθυρο 375-500 ms (Πίνακας 5.12) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα A.12).

Feature Selection Algorithm	Accuracy	Features
mrmr	84.615%	Fp1-alpha, O2-gamma, C5-gamma, PO4-gamma, P3-gamma, FC1-gamma, Afz-gamma, T7-gamma, TP7-gamma, P6-gamma, F7-gamma, P4-gamma, O2-beta, F5-gamma

Πίνακας 5.12: Πείραμα N-Back KNN για το χρονικό παράθυρο 375-500 ms

Με τον ταξινομητή N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5-312.5 ms (Πίνακας 5.13) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλευρικά (parietal) σημεία του εγκεφάλου και στον κροταφικό λοβό στις συχνότητες δέλτα και γάμμα (Σχήμα A.13).

Feature Selection Algorithm	Accuracy	Features
rfe	90%	P10-gamma, FC5-gamma, FC3-gamma, P6-gamma, FC1-gamma, P8-gamma, CP5-gamma, P10-theta, CP6-gamma, P10-delta, T7-gamma, O2-gamma, FC5-theta, PO4-gamma, PO8-gamma, TP8-gamma, FC5-delta, Cz-gamma

Πίνακας 5.13: Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5-312.5 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 250-375 ms (Πίνακας 5.14) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα πλάγια (parietal) και εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα A.14).

Feature Selection Algorithm	Accuracy	Features
rfe	100%	P10-gamma, FC5-gamma, FC3-gamma, P6-gamma, FC1-gamma, P8-gamma, CP5-gamma, P10-theta, CP6-gamma, P10-delta, T7-gamma, O2-gamma

Πίνακας 5.14: Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 187.5-312.5 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 250-375 ms (Πίνακας 5.15) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα πλάγια (parietal) και κεντρικά (central) σημεία του εγκεφάλου σε όλο το φάσμα συχνοτήτων (Σχήμα A.15).

Feature Selection Algorithm	Accuracy	Features
relieff	87.5%	P7-delta, P7-theta, P7-beta, P7-alpha, P7-gamma, CP1-beta

Πίνακας 5.15: Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 250-375 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 250-375 ms (Πίνακας 5.16) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα πλάγια (parietal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα A.16).

Feature Selection Algorithm	Accuracy	Features
InfFS	75%	P10-gamma, PO8-gamma, CP5-gamma, P8-gamma, PO4-gamma, FC5-gamma, FC3-gamma, O1-gamma, P6-gamma, FC1-gamma, PO7-gamma, TP8-gamma, CP6-gamma, Cz-gamma

Πίνακας 5.16: Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 250-375 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms (Πίνακας 5.17) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal), πλάγια (parietal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες γάμμα, βήτα, δέλτα και άλφα (Σχήμα A.17).

Feature Selection Algorithm	Accuracy	Features
cfs	84.615%	TP7-beta, FC4-delta, CP3-gamma, Fz-alpha

Πίνακας 5.17: Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms (Πίνακας 5.18) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα και δέλτα. (Σχήμα A.18).

Feature Selection Algorithm	Accuracy	Features
dgufs	89.744%	CP2-gamma, FC4-gamma, Fp1-delta, AF3-delta, F1-delta, F3-delta, F5-delta, F7-delta, FT7-delta, FC5-delta, FC3-delta

Πίνακας 5.18: Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 312.5-437.5 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 375-500 ms (Πίνακας 5.19) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal), κεντρικά (central) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες γάμμα. (Σχήμα A.19).

Feature Selection Algorithm	Accuracy	Features
rfe	76.923%	P10-gamma, FC3-gamma, CP5-gamma

Πίνακας 5.19: Πείραμα N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 375-500 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 375-500 ms (Πίνακας 5.20) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες άλφα και γάμμα. (Σχήμα A.20).

Feature Selection Algorithm	Accuracy	Features
udfs	79.487%	C2-alpha, F3-alpha, F3-gamma

Πίνακας 5.20: Πείραμα N-Back KNN με Relatives PSD για το χρονικό παράθυρο 375-500 ms

5.2 PASAT

Με τον ταξινομητή Linear SVM για όλη τη χρονοσειρά (Πίνακας 5.21) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal), πλευρικά (parietal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες άλφα, θήτα και γάμμα. (Σχήμα B.1).

Feature Selection Algorithm	Accuracy	Features
ILFS	86.111%	AF7-alpha, P7-gamma, C4-beta, F4-theta, FC1-beta, Fp2-gamma, CP2-gamma

Πίνακας 5.21: Πείραμα PASAT Linear SVM για όλη τη χρονοσειρά

Με τον ταξινομητή KNN για όλη τη χρονοσειρά (Πίνακας 5.22) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα εμπρόσθια (frontal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες δέλτα και θήτα (Σχήμα B.2).

Feature Selection Algorithm	Accuracy	Features
fisher	69.444%	C2-delta, FT8-theta, Cz-delta, FC1-delta, FC2-delta, CP2-theta, CP2-delta, Fz-delta, AF8-delta, CP1-delta, CPz-delta

Πίνακας 5.22: Πείραμα PASAT KNN για όλη τη χρονοσειρά

Με τον ταξινομητή Linear SVM με Relatives PSD για όλη τη χρονοσειρά (Πίνακας 5.23) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλάγια (parietal) σημεία του εγκεφάλου στις συχνότητες άλφα και θήτα (Σχήμα B.3).

Feature Selection Algorithm	Accuracy	Features
ILFS	100%	Pz-alpha, F5-alpha, C6-delta, AF8-alpha, P3-alpha, PO8-alpha, FCz-alpha, P4-alpha, FC6-theta, Afz-alpha, CP1-alpha, P5-alpha, F4-alpha, PO3-theta

Πίνακας 5.23: Πείραμα PASAT Linear SVM με Relatives PSD για όλη τη χρονοσειρά

Με τον ταξινομητή KNN με Relatives PSD για όλη τη χρονοσειρά (Πίνακας 5.24) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες δέλτα και γάμμα (Σχήμα Β.4).

Feature Selection Algorithm	Accuracy	Features
dgufs	69.444%	CP1-gamma, CPz-gamma, Fp1-delta, AF7-delta, AF3-delta, F1-delta, F3-delta, F5-delta, F7-delta, FT7-delta

Πίνακας 5.24: Πείραμα PASAT KNN με Relatives PSD για όλη τη χρονοσειρά

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.25) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται πλευρικά (parietal, temporal) σημεία του εγκεφάλου στις συχνότητες βήτα και γάμμα (Σχήμα Β.5).

Feature Selection Algorithm	Accuracy	Features
cfs	75%	O1-beta, P9-gamma, Cz-beta, T8-beta

Πίνακας 5.25: Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.26) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα κεντρικά (central) σημεία του εγκεφάλου στις συχνότητες βήτα και γάμμα (Σχήμα Β.6).

Feature Selection Algorithm	Accuracy	Features
mrmr	77.778%	F2-delta, CP4-gamma, CP3-gamma, C3-gamma, CP2-gamma, C1-gamma, C4-gamma, FC1-gamma, P4-gamma, F5-gamma, CP6-beta, CP2-beta, CP1-gamma, C6-gamma

Πίνακας 5.26: Πείραμα PASAT KNN με για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.27) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες θήτα και άλφα (Σχήμα Β.7).

Feature Selection Algorithm	Accuracy	Features
llcfs	88.889%	Fp2-theta, AF8-theta, Fp2-alpha, O1-theta, AF8-alpha, O1-alpha, PO3-theta, P10-beta, Fp2-delta, O1-beta, P10-alpha, P9-theta, CP5-theta

Πίνακας 5.27: Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.28) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και πλευρικά (parietal) σημεία του εγκεφάλου στις συχνότητες θήτα και άλφα (Σχήμα Β.8).

Feature Selection Algorithm	Accuracy	Features
llcfs	77.778%	Fp2-theta, AF8-theta, Fp2-alpha, O1-theta, AF8-alpha, O1-alpha, PO3-theta, P10-beta

Πίνακας 5.28: Πείραμα PASAT KNN για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms (Πίνακας 5.29) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες θήτα και άλφα (Σχήμα Β.9).

Feature Selection Algorithm	Accuracy	Features
rfe	87.5%	FC3-alpha, FC3-theta, FT8-theta, FT7-theta, C4-delta, FT8-alpha, Fz-theta, F6-theta, F8-theta, F7-theta

Πίνακας 5.29: Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 312.5 - 437.5 ms (Πίνακας 5.30) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) και στα πλευρικά σημεία του εγκεφάλου στις συχνότητες γάμμα βήτα και άλφα (Σχήμα Β.10).

Feature Selection Algorithm	Accuracy	Features
cfs	77.778%	AF7-alpha, P10-gamma, Fz-delta, C6-delta, CPz-theta, P7-gamma, FCz-alpha, Fp1-gamma, C6-alpha, FCz-beta, FC1-alpha, Fpz-gamma, P1-alpha, TP8-beta, AF8-delta

Πίνακας 5.30: Πείραμα PASAT KNN για το χρονικό παράθυρο 312.5 - 437.5 ms

Με τον ταξινομητή Linear SVM για το χρονικό παράθυρο 375 - 500 ms (Πίνακας 5.31) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες άλφα, θήτα και δέλτα. (Σχήμα Β.11).

Feature Selection Algorithm	Accuracy	Features
infFS	100%	FC4-theta, FC4-alpha, FC4-delta, P9-theta

Πίνακας 5.31: Πείραμα PASAT Linear SVM για το χρονικό παράθυρο 375 - 500 ms

Με τον ταξινομητή KNN για το χρονικό παράθυρο 375 - 500 ms (Πίνακας 5.32) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα πλευρικά (parietal) και εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες βήτα, θήτα και δέλτα. (Σχήμα Β.12).

Feature Selection Algorithm	Accuracy	Features
laplacian	69.444%	FC4-theta, FC4-alpha, FC4-delta, P9-theta, P9-alpha, FC4-beta, P9-delta, P9-beta, FC6-theta, FC6-alpha, FC6-delta, FC6-beta, Fpz-theta, P10-theta, P10-alpha

Πίνακας 5.32: Πείραμα PASAT KNN για το χρονικό παράθυρο 375 - 500 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.33) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται στα πλευρικά (parietal), κεντρικά (central), εμπρόσθια (frontal) σημεία του εγκεφάλου και του κροταφικού λοβού στις συχνότητες γάμμα. (Σχήμα B.13).

Feature Selection Algorithm	Accuracy	Features
L0	94.444%	T8-gamma, CP4-gamma, C6-gamma, Fp1-gamma, CP6-gamma, AF8-gamma, CP5-gamma, PO8-gamma, F5-gamma, FT7-gamma, P6-gamma, P9-gamma, FC1-gamma, Fp2-gamma, P4-gamma

Πίνακας 5.33: Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms (Πίνακας 5.34) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλευρικά (parietal), κεντρικά (central) και εμπρόσθια (pre-frontal, frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα και δέλτα (Σχήμα B.14).

Feature Selection Algorithm	Accuracy	Features
mcfcs	80.556%	P8-gamma, PO8-gamma, T8-gamma, P7-gamma, Fz-gamma, CP4-gamma, TP8-gamma, FC6-gamma, Oz-gamma, P4-gamma, P10-gamma, Fp1-gamma, FT8-gamma, TP7-gamma, C4-gamma, AF4-gamma, O2-gamma, P8-theta, AF7-gamma, FC1-gamma, C5-gamma, CP5-gamma, P8-delta, FT7-gamma, F4-gamma

Πίνακας 5.34: Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.35) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα κεντρικά (central) και εμπρόσθια (pre-frontal, frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα και βήτα (Σχήμα B.15).

Feature Selection Algorithm	Accuracy	Features
lasso	77.778%	CPz-gamma, C2-beta, CP6-beta, F3-gamma, Fpz-gamma

Πίνακας 5.35: Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms (Πίνακας 5.36) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλάγια (parietal), κεντρικά (central) και εμπρόσθια (pre-frontal, frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα B.16).

Feature Selection Algorithm	Accuracy	Features
L0	83.333%	CP6-gamma, C6-gamma, TP8-gamma, F3-gamma, P9-gamma, T8-gamma, C2-gamma, F4-gamma, CP4-gamma, P10-gamma, Oz-gamma, F5-gamma, FT8-gamma, T7-gamma, P8-gamma

Πίνακας 5.36: Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms (Πίνακας 5.37) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα πλάγια (parietal) σημεία του εγκεφάλου σε όλο το φάσμα συχνοτήτων (Σχήμα B.17).

Feature Selection Algorithm	Accuracy	Features
relieff	91.667%	P7-gamma, P7-alpha, P7-theta, P3-gamma, P7-delta, P3-alpha, P3-theta, P7-beta, P3-delta, P3-beta, P10-gamma, P10-alpha, P10-theta, P10-delta

Πίνακας 5.37: Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms (Πίνακας 5.38) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα B.18).

Feature Selection Algorithm	Accuracy	Features
rfe	80.556%	AF7-gamma, AF3-gamma, Fp1-gamma, F5-gamma, CP5-gamma, AF8-gamma, P7-gamma

Πίνακας 5.38: Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms

Με τον ταξινομητή Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms (Πίνακας 5.39) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως σημεία του κροταφικού και ινιακού λοβού στις συχνότητες γάμμα (Σχήμα B.19).

Feature Selection Algorithm	Accuracy	Features
llcfs	97.222%	O2-gamma, O1-gamma, TP8-gamma, P8-gamma, Oz-gamma, AF8-gamma, CP6-gamma, T8-gamma

Πίνακας 5.39: Πείραμα PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms

Με τον ταξινομητή KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms (Πίνακας 5.40) τα ηλεκτρόδια που επιλέχθηκαν αναφέρονται κυρίως στα εμπρόσθια (frontal) σημεία του εγκεφάλου στις συχνότητες γάμμα (Σχήμα B.20).

Feature Selection Algorithm	Accuracy	Features
rfe	83.33%	AF7-gamma, AF8-gamma, P9-gamma, C3-gamma, F5-gamma, Fp2-gamma, FC3-gamma, CP5-gamma, AF3-gamma, F7-gamma, C5-gamma

Πίνακας 5.40: Πείραμα PASAT KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms

Κεφάλαιο 6

Συμπεράσματα

Στην παρούσα εργασία εξετάσαμε την εκτίμηση της φασματικής πυκνότητας ισχύος του ΗΕΓ με επίκεντρο τη νοητική κόπωση. Χρησιμοποιήσαμε ως ταξινομητές τον γραμμικό SVM και τον KNN. Τα αποτελέσματα έδειξαν ότι και στο N-Back και στο PASAT υπάρχει σημαντική διαφορά στις συχνότητες δέλτα και θήτα ειδικά στα κεντρικά και πλάγια σημεία του εγκεφάλου. Επιβεβαιώνεται στην βιβλιογραφία [60, 82] καθώς επίσης αναφέρουν σημαντική διαφορά στις συχνότητες θήτα στα πλάγια και εμπρόσθια σημεία του εγκεφάλου. Αυτό προκύπτει λογικά διότι στις δέλτα και θήτα συχνότητες οι τιμές της φασματικής πυκνότητας ισχύος είναι μεγαλύτερες. Όσο αναφορά τις σχετικές φασματικές πυκνότητες ισχύος παρουσιάζεται διαφορά στις συχνότητες γάμμα ενώ στην βιβλιογραφία δεν βρέθηκε κάτι αντίστοιχο. Καλύτερες ακρίβειες στις ταξινομήσεις πετύχαμε με τον γραμμικό SVM. Αυτό μπορεί να συμβαίνει για δύο λόγους. Ο πρώτος λόγος είναι ότι ο KNN χρειάζεται μεγαλύτερο μέγεθος δεδομένων εκπαίδευσης του μοντέλου (training data set) απ ότι ο SVM για να πετύχει καλύτερες ακρίβειες πρόβλεψης στα δεδομένα δοκιμής (testing data set). Ο δεύτερος λόγος είναι ότι ο SVM λαμβάνει καλύτερα υπόψιν του ακραίες τιμές απ ότι ο KNN.

Σαν βελτίωση ή μελλοντική επέκταση της εργασίας θα μπορούσε να επιτευχθεί καλύτερη ακρίβεια στο στάδιο ταξινόμησης εάν χρησιμοποιούσαμε μεγαλύτερο χρονικό παράθυρο στην εκτίμηση της φασματικής πυκνότητας ισχύος. Επιπλέον θα μπορούσαν να χρησιμοποιηθούν αλγόριθμοι εξαγωγής χαρακτηριστικών προκειμένου να βρεθούν καλύτερα features. Ενδιαφέρον θα είχε να αναλυθούν και οι καταγραφές συμπεριφοράς από την εκάστοτε εργασία όπου θα περιλαμβάνει την ορθότητα των απαντήσεων. Τέλος σημαντικό θα είναι να υπάρχει μεγαλύτερο δείγμα και μικρότερο εύρος ηλικιών ή ακόμη και ξεχωριστές αναλύσεις για κάθε φύλο.

Βιβλιογραφία

- [1] R. Carter, *The Human Brain Book: An Illustrated Guide to its Structure, Function, and Disorders*. DK (January 8, 2019), 3rd ed., 2019.
- [2] J. L. Stone and J. R. Hughes, “Early History of Electroencephalography and Establishment of the American Clinical Neurophysiology Society,” *Journal of Clinical Neurophysiology*, vol. 30, pp. 28–44, feb 2013.
- [3] E. St. Louis and L. Frey, *Electroencephalography (EEG): An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants*. American Epilepsy Society, 2016.
- [4] D. Koutsouris, S. Paulopoulos, and A. Prentza, *Introduction to Biomedical Technology and Analysis of Medical Signals*. TZIOLA PUBLICATIONS, 2017.
- [5] A. d. R. Gesualdi and A. I. Franca, “Event-Related Brain Potentials (ERP): an Overview,” *Revista Linguística / Revista do Programa de Pós-Graduação em Linguística da Universidade Federal do Rio de Janeiro*, vol. 7, no. 2, 2011.
- [6] D. H. Blackwood and W. J. Muir, “Cognitive brain potentials and their application,” 1990.
- [7] N. N. Peterson, C. E. Schroeder, and J. C. Arezzo, “Neural generators of early cortical somatosensory evoked potentials in the awake monkey,” *Electroencephalography and Clinical Neurophysiology/ Evoked Potentials*, vol. 96, pp. 248–260, may 1995.
- [8] S. Sur and V. Sinha, “Event-related potential: An overview,” *Industrial Psychiatry Journal*, vol. 18, no. 1, p. 70, 2009.
- [9] P. L. Nunez and R. Srinivasan, *Electric Fields of the Brain: The Neurophysis of EEG*. OXFORD UNIVERSITY PRESS, 2006.
- [10] J. S. Ebersole, “Defining epileptogenic foci: Past, present, future,” 1997.
- [11] R. Cooper, A. L. Winter, H. J. Crow, and W. G. Walter, “Comparison of subcortical, cortical and scalp activity using chronically indwelling electrodes in man,” *Electroencephalography and Clinical Neurophysiology*, vol. 18, no. 3, pp. 217–228, 1965.
- [12] S. J. Luck, *An Introduction to the Event-Related Potential Technique*. Massachusetts Institute of Technology, 2014.
- [13] H. Helmholtz, “Ueber einige Gesetze der Vertheilung elektrischer Ströme in körperlichen Leitern, mit Anwendung auf die thierisch□elektrischen Versuche (Schluss.)” *Annalen der Physik*, vol. 165, pp. 353–377, jan 1853.
- [14] P. A. Davis, “EFFECTS OF ACOUSTIC STIMULI ON THE WAKING HUMAN BRAIN,” *Journal of Neurophysiology*, vol. 2, pp. 494–499, nov 1939.
- [15] W. G. Walter, R. Cooper, V. J. Aldridge, W. C. McCallum, and A. L. Winter, “Contingent negative variation : An electric sign of sensori-motor association and expectancy in the human brain,” *Nature*, vol. 203, no. 4943, pp. 380–384, 1964.

- [16] H. H. KORNHUBER and L. DEECKE, "HIRNPOTENTIALAENDERUNGEN BEI WILLKUERBEWEGUNGEN UND PASSIVEN BEWEGUNGEN DES MENSCHEN: BEREITSCHAFTSPOTENTIAL UND REAFFERENTE POTENTIALIAE.," *Pflügers Archiv für die gesamte Physiologie des Menschen und der Tiere*, vol. 284, pp. 1–17, may 1965.
- [17] G. F. Woodman, "A brief introduction to the use of event-related potentials in studies of perception and attention," *Attention, Perception & Psychophysics*, vol. 72, pp. 2031–2046, nov 2010.
- [18] T. Onitsuka, N. Oribe, and S. Kanba, "Neurophysiological findings in patients with bipolar disorder," in *Supplements to Clinical Neurophysiology*, vol. 62, pp. 197–206, Elsevier B.V., jan 2013.
- [19] J. R. Wolpaw and J. K. Penry, "A temporal component of the auditory evoked response," *Electroencephalography and Clinical Neurophysiology*, vol. 39, no. 6, pp. 609–620, 1975.
- [20] S. Makeig, M. Westerfield, J. Townsend, T. P. Jung, E. Courchesne, and T. J. Sejnowski, "Functionally independent components of early event-related potentials in a visual spatial attention task," *Philosophical Transactions of the Royal Society B: Biological Sciences*, vol. 354, pp. 1135–1144, jul 1999.
- [21] M. Eimer, "The Face-Sensitivity of the N170 Component," *Frontiers in Human Neuroscience*, vol. 5, p. 93, 2011.
- [22] B. Rossion and C. Jacques, "Does physical interstimulus variance account for early electrophysiological face sensitive responses in the human brain? Ten lessons on the N170," feb 2008.
- [23] J. E. Hoffman, R. F. Simons, and M. R. Houck, "Event-Related Potentials During Controlled and Automatic Target Detection," *Psychophysiology*, vol. 20, pp. 625–632, nov 1983.
- [24] M. Kutas and K. D. Federmeier, "Thirty years and counting: Finding meaning in the N400 component of the event-related brain potential (ERP)," *Annual Review of Psychology*, vol. 62, pp. 621–647, jan 2011.
- [25] G. B. Remijn, E. Hasuo, H. Fujihira, and S. Morimoto, "An introduction to the measurement of auditory event-related potentials (ERPs)," *Acoustical Science and Technology*, vol. 35, pp. 229–242, may 2014.
- [26] S. A. Hillyard and T. W. Picton, "Electrophysiology of Cognition," in *Comprehensive Physiology*, pp. 519–584, Hoboken, NJ, USA: John Wiley & Sons, Inc., jan 2011.
- [27] C. D. Yingling and G. E. Nethercut, "Evoked responses to frequency shifted tones: Tonotopic and contextual determinants," *International Journal of Neuroscience*, vol. 22, no. 1-2, pp. 107–118, 1983.
- [28] S. J. Luck, "The Operation of Attention—Millisecond by Millisecond—Over the First Half Second.," *The first half second: The microgenesis and temporal dynamics of unconscious and conscious visual processes*, pp. 187–206, 2006.
- [29] N. Kamel and A. S. Malik, *EEG/ERP Analysis. Methods and Applications*. Taylor & Francis Group, LLC, 2015.
- [30] E. Donchin, D. Karis, T. R. Bashore, M. Coles, and G. Gratton, "Cognitive Psychophysiology and Human Information Processing," *undefined*, 1986.

- [31] D. Friedman and R. Johnson, “Event-related potential (ERP) studies of memory encoding and retrieval: A selective review,” oct 2000.
- [32] F. Delogu, H. Brouwer, and M. W. Crocker, “Event-related potentials index lexical retrieval (N400) and integration (P600) during language comprehension,” *Brain and Cognition*, vol. 135, p. 103569, oct 2019.
- [33] S. Shalev-Shwartz and S. Ben-David, *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press, 2014.
- [34] S. Kotsianis, “Supervised Machine Learning: A Review of Classification Techniques,” *Informatica (Slovenia)*, vol. 31, 2007.
- [35] F. Osisanwo, J. Akinsola, O. Awodele, J. Hinmikaiye, O. Olakamni, and J. Akinjobi, “Supervised Machine Learning Algorithms: Classification and Comparison,” *International Journal of Computer Trends and Technology (IJCTT)*, vol. 48, 2017.
- [36] B. B. Prakash and S. Prasad, “An Overview of Recent Machine Learning Strategies in Data Mining,” *International Journal of Advanced Computer Science and Applications(IJACSA)*, vol. 4, no. 3, 2013.
- [37] L. Rokach and O. Maimon, *Data Mining with Decision Trees*. World Scientific Publishing Co. Pte. Ltd., 2015.
- [38] V. Jakkula, “Tutorial on Support Vector Machine (SVM),” tech. rep.
- [39] R. Duda and P. Hart, *Pattern Classification and Scene Analysis*. Wiley, 1973.
- [40] N. Cristianini and J. Shawe-Taylor, *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press, mar 2000.
- [41] A. C. Gay Thome, “SVM Classifiers – Concepts and Applications to Character Recognition,” in *Advances in Character Recognition*, InTech, nov 2012.
- [42] L. Ladicky and P. Torr, “Locally Linear Support Vector Machines,” pp. 985–992, 2011.
- [43] K. Koutroumbas and S. Theodoridis, *Pattern Recognition*. Academic Press, 2009.
- [44] B. E. Boser, I. M. Guyon, and V. N. Vapnik, “A training algorithm for optimal margin classifiers,” in *Proceedings of the fifth annual workshop on Computational learning theory - COLT '92*, (New York, New York, USA), pp. 144–152, ACM Press, 1992.
- [45] N. Stanevski and D. Tsvetkov, “Using Support Vector Machine as a Binary Classifier,” 2005.
- [46] C. Bishop, *Pattern Recognition and Machine Learning*. Springer, 2006.
- [47] T. Cover, “Rates of convergence for nearest neighbor procedures,” in *Hawaii International Conference on System Sciences*, pp. 413–415, 1968.
- [48] L. Devroye, “On the equality of Cover and Hart in nearest neighbor discrimination,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 3, pp. 75–78, 1981.
- [49] L. Devroye and T. Wagner, *Nearest neighbor methods in discrimination, In Classification, Pattern Recognition and Reduction of Dimensionality*. North-Holland, Amsterdam, 1982.
- [50] E. Fix and J. L. Hodges, “Discriminatory Analysis. Nonparametric Discrimination: Consistency Properties,” *International Statistical Review / Revue Internationale de Statistique*, vol. 57, p. 238, dec 1989.


- [51] S. B. Imandoust and M. Bolandraftar, "Application of K-Nearest Neighbor (KNN) Approach for Predicting Economic Events: Theoretical Background," *S B Imandoust et al. Int. Journal of Engineering Research and Applications*, vol. 3, no. 5, pp. 605–610, 2013.
- [52] G. Guo, H. Wang, D. Bell, and Y. Bi, "Using kNN model for automatic text categorization," *Soft Computing*, vol. 10, 2006.
- [53] J. Gou, L. Du, Y. Zhang, and T. Xiong, "A New Distance-weighted k -nearest Neighbor Classifier," *J. Inf. Comput. Sci.*, vol. 9, 2011.
- [54] J. Proakis and D. Manolakis, "Digital Signal Processing: Principles, Algorithms, and Applications," *Prentice-Hall*, 1992.
- [55] P. Stoica and R. Moses, *Spectral Analysis of Signals*. Pearson Prentice Hall, 2005.
- [56] A. Zaknich, *Principles of Adaptive Filters and Self-learning Systems*. Springer, 2005.
- [57] D. Manolakis, V. Ingle, and S. Kogon, *Statistical and Adaptive Signal Processing: Spectral Estimation, Signal Modeling, Adaptive Filtering and Array Processing*. Artech House, 2005.
- [58] P. D. Welch, "The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms," *IEEE Transactions on Audio and Electroacoustics*, vol. 15, no. 2, pp. 70–73, 1967.
- [59] M. H. Hayes, *Statistical Digital Signal Processing and Modeling*. John Wiley & Sons, 1996.
- [60] A. M. Brouwer, M. A. Hogervorst, J. B. Van Erp, T. Heffelaar, P. H. Zimmerman, and R. Oostenveld, "Estimating workload using EEG spectral power and ERPs in the n-back task," *Journal of Neural Engineering*, vol. 9, p. 045008, aug 2012.
- [61] V. Pergher, B. Wittevrongel, J. Tournoy, B. Schoenmakers, and M. M. Van Hulle, "Mental workload of young and older adults gauged with ERPs and spectral power during N-Back task performance," *Biological Psychology*, vol. 146, p. 107726, sep 2019.
- [62] G. N. Dimitrakopoulos, I. Kakkos, Z. Dai, J. Lim, J. J. Desouza, A. Bezerianos, and Y. Sun, "Task-Independent Mental Workload Classification Based Upon Common Multiband EEG Cortical Connectivity," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 25, pp. 1940–1949, nov 2017.
- [63] P. Zhang, X. Wang, X. Li, and P. Dai, "EEG feature selection based on weighted-normalized mutual information for mental fatigue classification," in *Conference Record - IEEE Instrumentation and Measurement Technology Conference*, vol. 2016-July, Institute of Electrical and Electronics Engineers Inc., jul 2016.
- [64] J. Dorrian, G. D. Roach, A. Fletcher, and D. Dawson, "Simulated train driving: Fatigue, self-awareness and cognitive disengagement," *Applied Ergonomics*, vol. 38, no. 2, pp. 155–166, 2007.
- [65] M. Basner and J. Rubinstein, "Fitness for duty: A 3-minute version of the psychomotor vigilance test predicts fatigue-related declines in luggage-screening performance," *Journal of Occupational and Environmental Medicine*, vol. 53, no. 10, pp. 1146–1154, 2011.
- [66] Y. Sun, J. Lim, K. Kwok, and A. Bezerianos, "Functional cortical connectivity analysis of mental fatigue unmasks hemispheric asymmetry and changes in small-world networks," *Brain and Cognition*, vol. 85, pp. 220–230, mar 2014.

- [67] A. R. Conway, M. J. Kane, M. F. Bunting, D. Z. Hambrick, O. Wilhelm, and R. W. Engle, “Working memory span tasks: A methodological review and user’s guide,” *Psychonomic Bulletin and Review*, vol. 12, no. 5, pp. 769–786, 2005.
- [68] M. J. Kane and R. W. Engle, “The role of prefrontal cortex in working-memory capacity, executive attention, and general fluid intelligence: An individual-differences perspective,” *Psychonomic Bulletin and Review*, vol. 9, no. 4, pp. 637–671, 2002.
- [69] S. M. Jaeggi, M. Buschkuhl, W. J. Perrig, and B. Meier, “The concurrent validity of the N-back task as a working memory measure,” *Memory*, vol. 18, pp. 394–412, may 2010.
- [70] A. Diamond, “Executive Functions,” *Annual Review of Psychology*, vol. 64, pp. 135–168, jan 2013.
- [71] E. E. Smith and J. Jonides, “Working memory: A view from neuroimaging,” *Cognitive Psychology*, vol. 33, no. 1, pp. 5–42, 1997.
- [72] D. M. Gronwall, “Paced auditory serial addition task: A measure of recovery from concussion,” *Perceptual and Motor Skills*, vol. 44, no. 2, pp. 367–373, 1977.
- [73] J. DeLuca, S. K. Johnson, and B. H. Natelson, “Information Processing Efficiency in Chronic Fatigue Syndrome and Multiple Sclerosis,” *Archives of Neurology*, vol. 50, no. 3, pp. 301–304, 1993.
- [74] M. D’Esposito, “Working memory impairments in multiple sclerosis: Evidence from a dual-task paradigm,” *Neuropsychology*, vol. 10, no. 1, pp. 51–56, 1996.
- [75] B. J. Diamond, J. DeLuca, H. Kim, and S. M. Kelley, “The question of disproportionate impairments in visual and auditory information processing in multiple sclerosis,” *Journal of Clinical and Experimental Neuropsychology*, vol. 19, no. 1, pp. 34–42, 1997.
- [76] J. D. Fisk and C. J. Archibald, “Limitations of the Paced Auditory Serial Addition Test as a measure of working memory in patients with multiple sclerosis,” *Journal of the International Neuropsychological Society*, vol. 7, no. 3, pp. 363–372, 2001.
- [77] J. L. Shucard, J. Parrish, D. W. Shucard, D. C. McCabe, R. H. Benedict, and J. Ambrus, “Working memory and processing speed deficits in systemic lupus erythematosus as measured by the paced auditory serial addition test,” *Journal of the International Neuropsychological Society*, vol. 10, no. 1, pp. 35–45, 2004.
- [78] E. M. Sherman, E. Strauss, and F. Spellacy, “Validity of the Paced Auditory Serial Addition Test (PASAT) in adults referred for neuropsychological assessment after head injury,” *Clinical Neuropsychologist*, vol. 11, no. 1, pp. 34–45, 1997.
- [79] C. Forn, A. Belenguer, V. Belloch, A. Sanjuan, M. A. Parcet, and C. Ávila, “Anatomical and functional differences between the paced auditory serial addition test and the symbol digit modalities test,” *Journal of Clinical and Experimental Neuropsychology*, vol. 33, pp. 42–50, jan 2011.
- [80] H. Jasper, “The ten-twenty electrode system of the international federation,” *Electroencephalogr. Clin. Neurophysiol.*, vol. 10, pp. 371–375, 1958.
- [81] Giorgio, “Feature Selection Library (<https://www.mathworks.com/matlabcentral/fileexchange/56937-feature-selection-library>),” 2020.
- [82] Z. Yin and J. Zhang, “Cross-session classification of mental workload levels using EEG and an adaptive deep learning model,” *Biomedical Signal Processing and Control*, vol. 33, pp. 30–47, mar 2017.

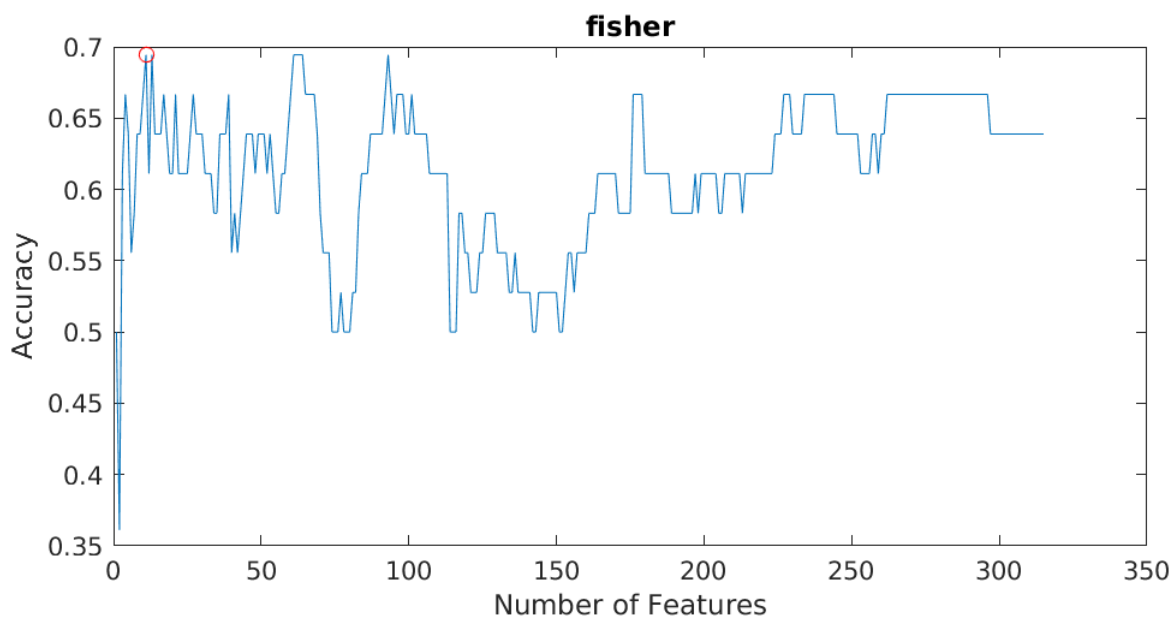
- [83] H. H. Kornhuber and L. Deecke, "Brain potential changes in voluntary and passive movements in humans: readiness potential and reafferent potentials," jul 2016.
- [84] A. Haider and R. Fazel-Rezai, "Application of P300 Event-Related Potential in Brain-Computer Interface," in *Event-Related Potentials and Evoked Potentials*, InTech, nov 2017.

Παράρτημα Α

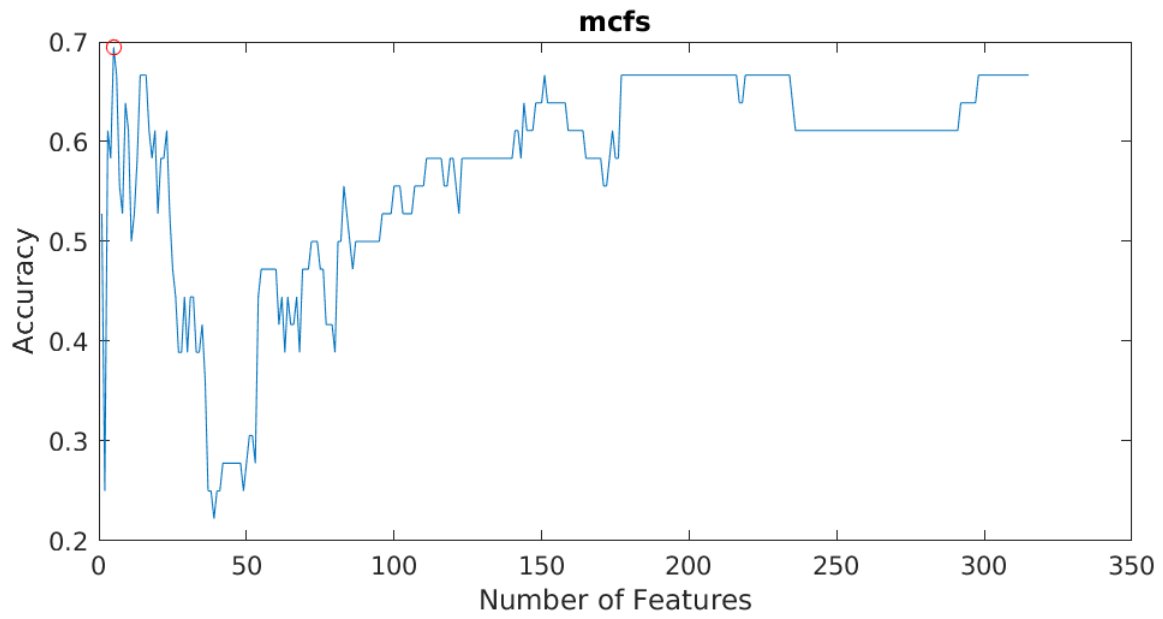
Διαγράμματα Αποτελεσμάτων N-Back



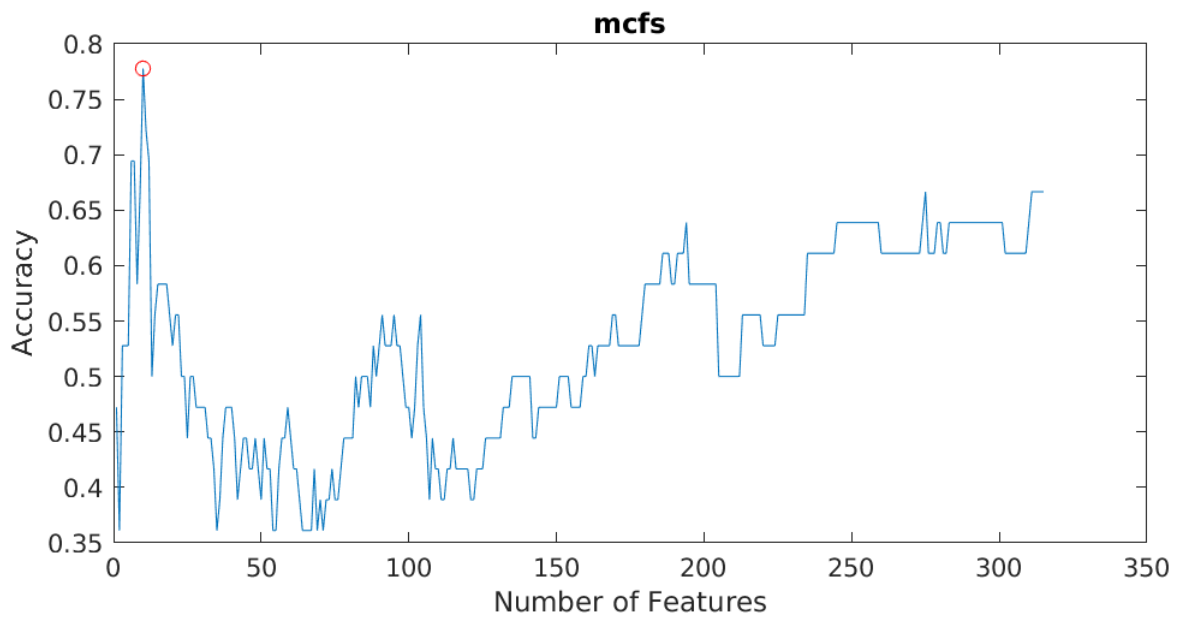
Σχήμα Α.1: N-Back Linear SVM για όλη τη χρονοσειρά



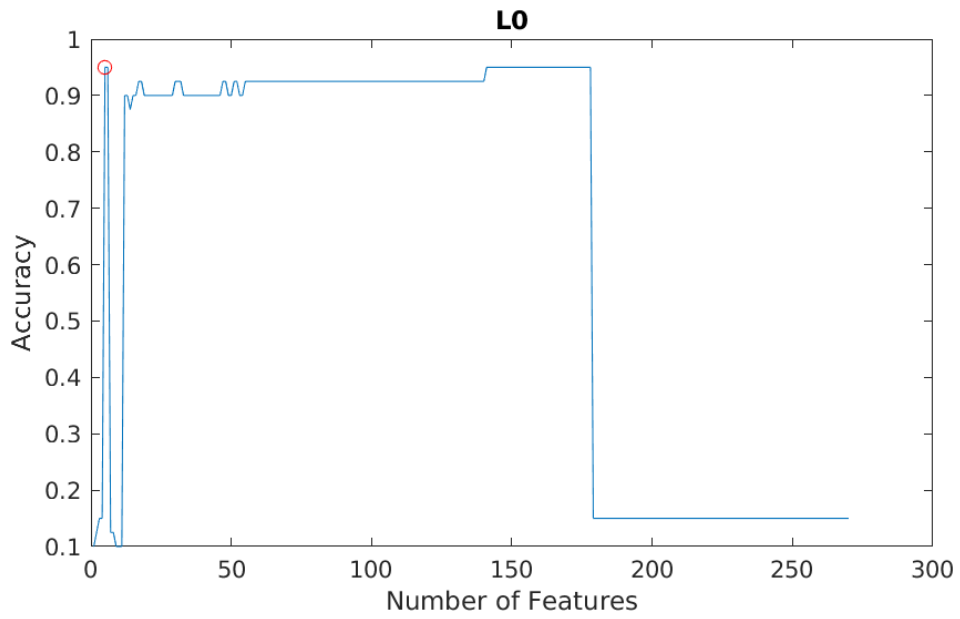
Σχήμα Α.2: N-Back KNN για όλη τη χρονοσειρά



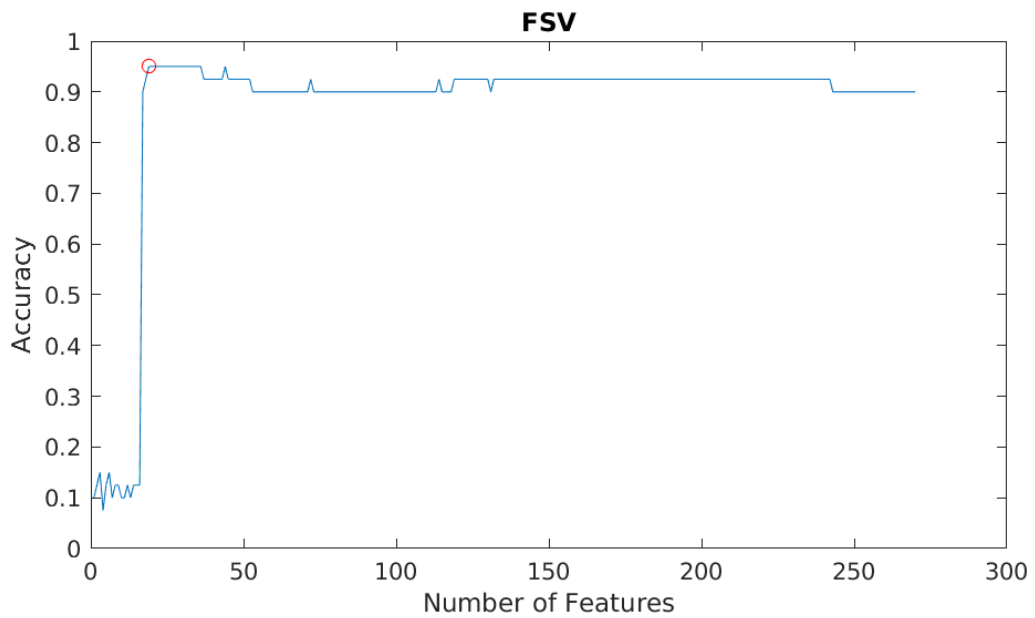
Σχήμα A.3: N-Back Linear SVM με Relatives PSD για όλη τη χρονοσειρά



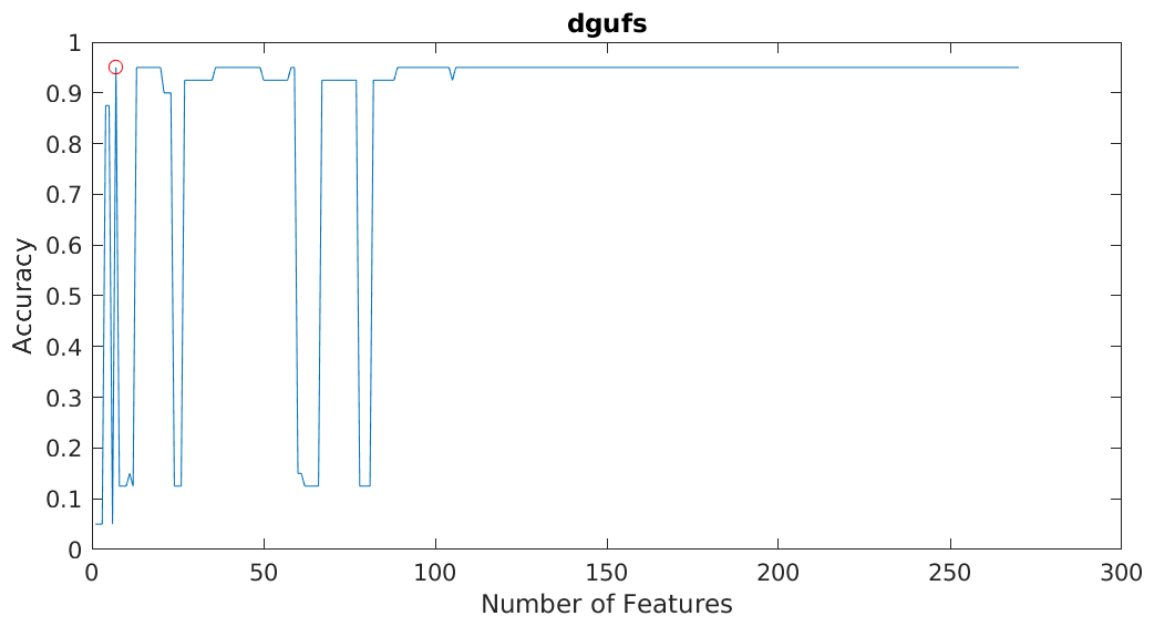
Σχήμα A.4: N-Back KNN με Relatives PSD για όλη τη χρονοσειρά



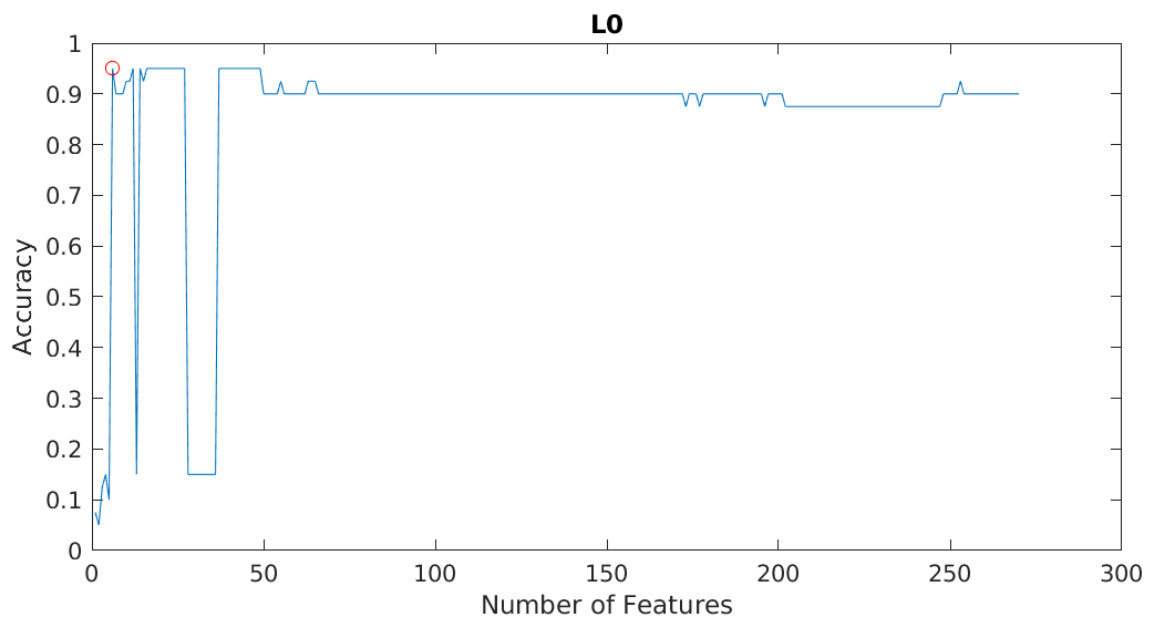
Σχήμα A.5: N-Back Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms



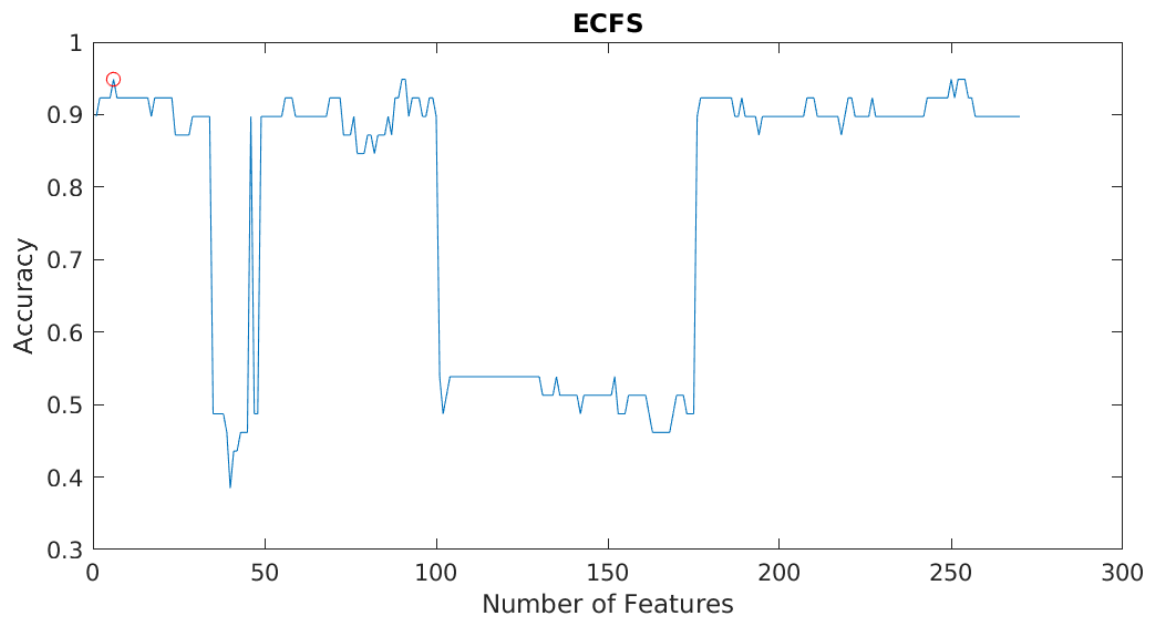
Σχήμα A.6: N-Back KNN για το χρονικό παράθυρο 187.5 - 312.5 ms



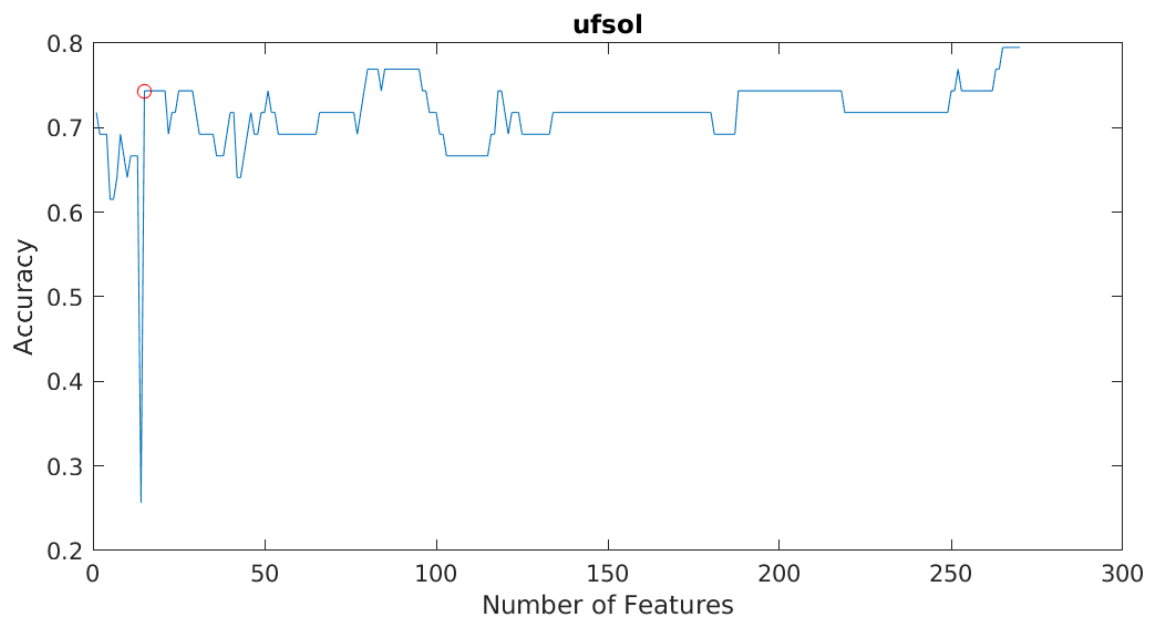
Σχήμα A.7: N-Back Linear SVM για το χρονικό παράθυρο 250 - 375 ms



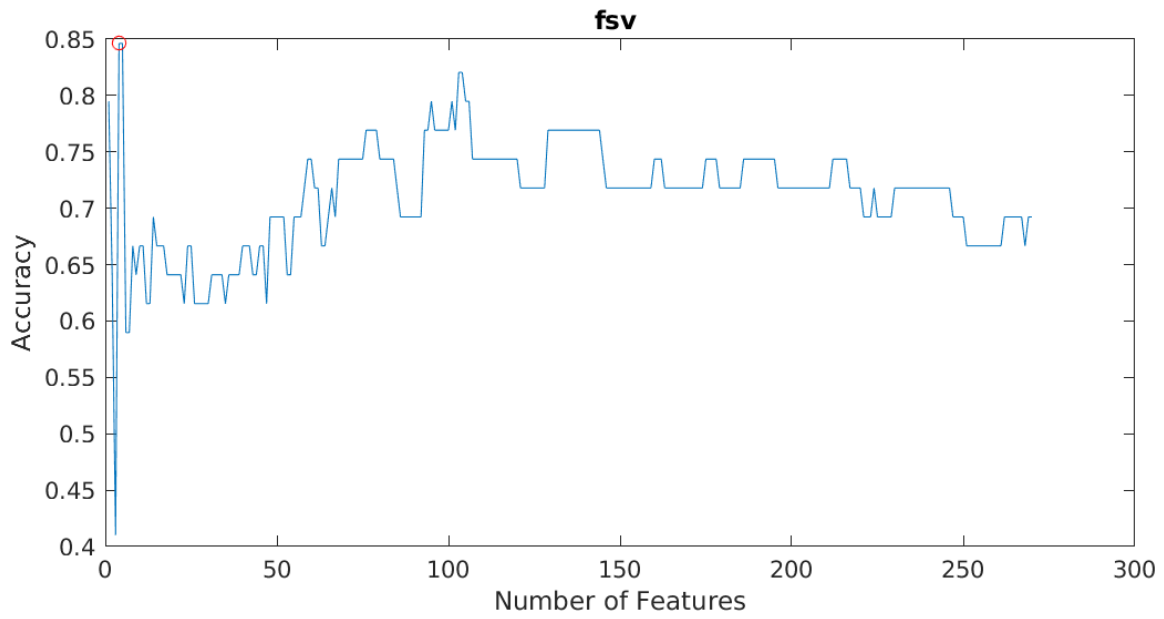
Σχήμα A.8: N-Back KNN για το χρονικό παράθυρο 250 - 375 ms



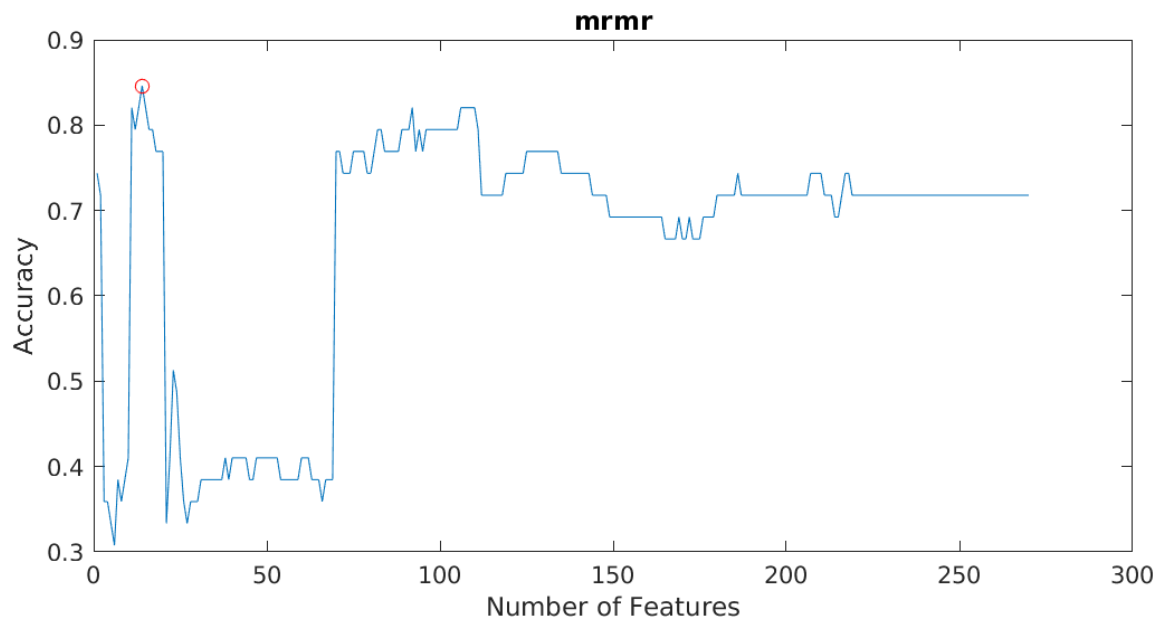
Σχήμα A.9: N-Back Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms




Σχήμα A.10: N-Back KNN για το χρονικό παράθυρο 312.5 - 437.5 ms




Σχήμα A.11: N-Back Linear SVM για το χρονικό παράθυρο 375 - 500 ms




Σχήμα A.12: N-Back KNN για το χρονικό παράθυρο 375 - 500 ms




Σχήμα A.13: N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms




Σχήμα A.14: N-Back KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms




Σχήμα A.15: N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms




Σχήμα A.16: N-Back KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms




Σχήμα A.17: N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms



Σχήμα A.18: N-Back KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms




Σχήμα A.19: N-Back Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms




Σχήμα A.20: N-Back KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms

Παράρτημα Β


Διαγράμματα Αποτελεσμάτων PASAT



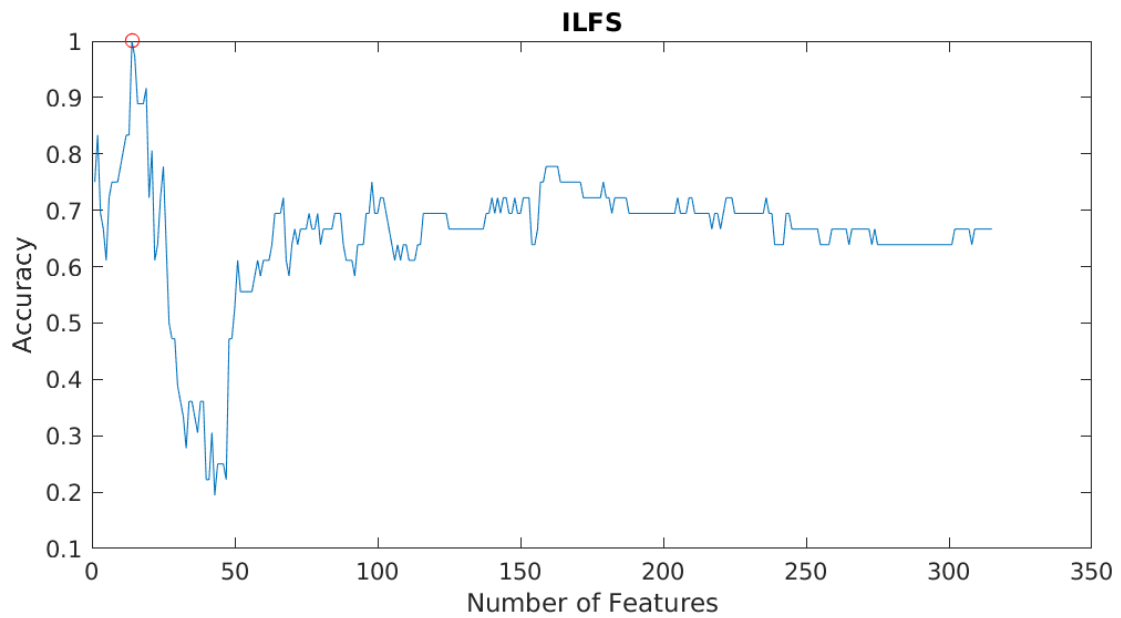
Σχήμα Β.1: PASAT Linear SVM για όλη τη χρονοσειρά




Σχήμα Β.2: PASAT KNN για όλη τη χρονοσειρά




Σχήμα Β.3: PASAT Linear SVM με Relatives PSD για όλη τη χρονοσειρά




Σχήμα Β.4: PASAT KNN με Relatives PSD για όλη τη χρονοσειρά




Σχήμα Β.5: PASAT Linear SVM για το χρονικό παράθυρο 187.5 - 312.5 ms




Σχήμα Β.6: PASAT KNN για το χρονικό παράθυρο 187.5 - 312.5 ms




Σχήμα Β.7: PASAT Linear SVM για το χρονικό παράθυρο 250 - 375 ms




Σχήμα Β.8: PASAT KNN για το χρονικό παράθυρο 250 - 375 ms




Σχήμα Β.9: PASAT Linear SVM για το χρονικό παράθυρο 312.5 - 437.5 ms




Σχήμα Β.10: PASAT KNN για το χρονικό παράθυρο 312.5 - 437.5 ms




Σχήμα Β.11: PASAT Linear SVM για το χρονικό παράθυρο 375 - 500 ms




Σχήμα Β.12: PASAT KNN για το χρονικό παράθυρο 375 - 500 ms




Σχήμα Β.13: PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms



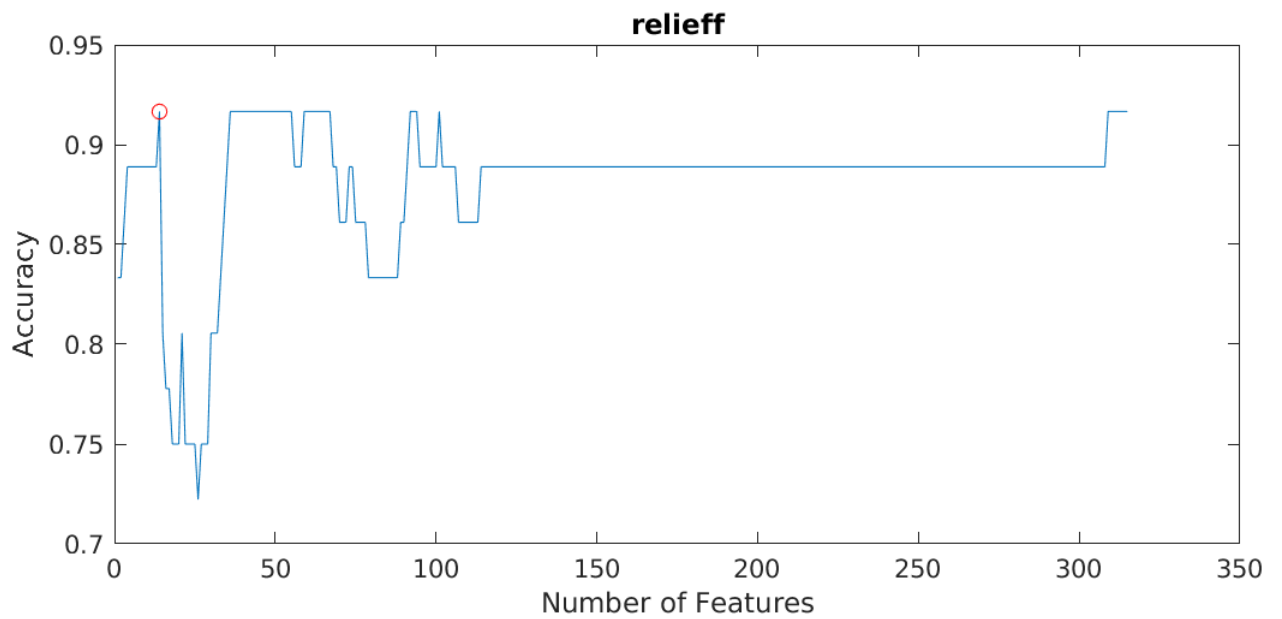
Σχήμα Β.14: PASAT KNN με Relatives PSD για το χρονικό παράθυρο 187.5 - 312.5 ms




Σχήμα Β.15: PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms




Σχήμα Β.16: PASAT KNN με Relatives PSD για το χρονικό παράθυρο 250 - 375 ms



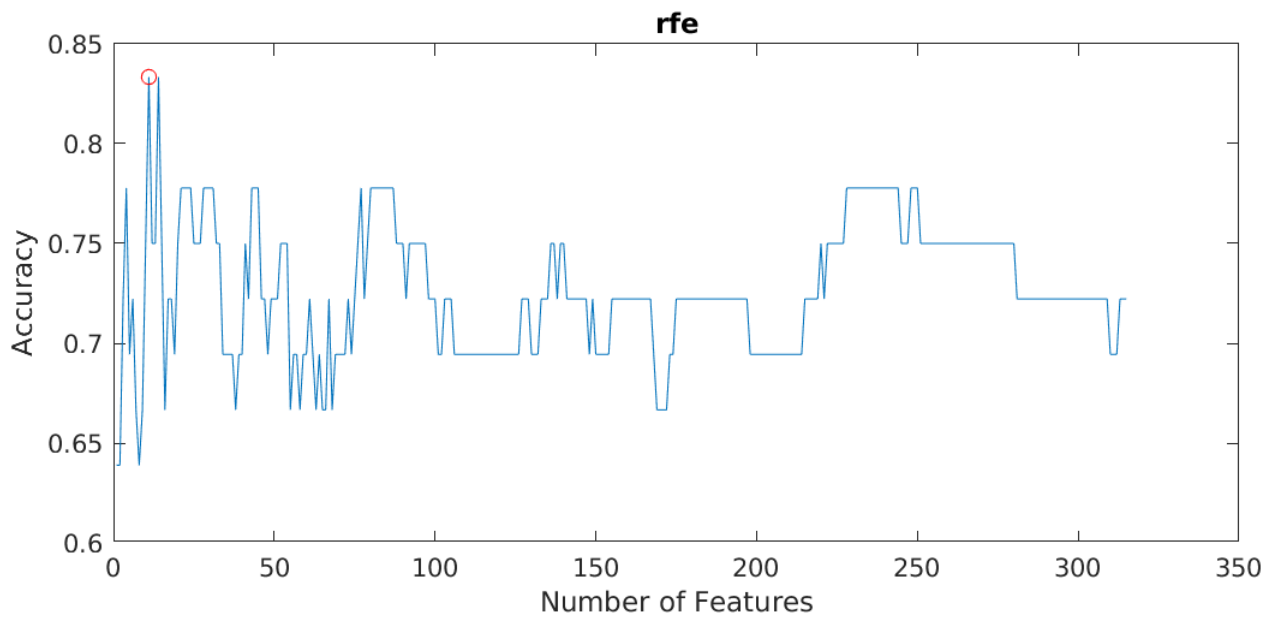
Σχήμα Β.17: PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms



Σχήμα Β.18: PASAT KNN με Relatives PSD για το χρονικό παράθυρο 312.5 - 437.5 ms



Σχήμα Β.19: PASAT Linear SVM με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms



Σχήμα Β.20: PASAT KNN με Relatives PSD για το χρονικό παράθυρο 375 - 500 ms